



## تخمین هدایت الکتریکی رودخانه‌ها با استفاده از شبکه عصبی موجک (مطالعه موردی: رودخانه کاکارضا)

محمدعلی قربانی<sup>۱</sup> و رضا دهقانی<sup>۲</sup>

۱- دانشیار، گروه مهندسی آب، دانشگاه تبریز  
۲- کارشناس ارشد گروه مهندسی آب، دانشگاه تبریز، (نویسنده مسؤل: reza.dehghani26@gmail.com)  
تاریخ دریافت: ۹۳/۱۰/۴ تاریخ پذیرش: ۹۴/۴/۱

### چکیده

هدایت الکتریکی (EC) عامل مهمی در مهندسی رودخانه و بویژه مطالعه کیفی آب رودخانه‌ها می‌باشد. در این پژوهش کاربرد شبکه عصبی موجک، جهت پیش‌بینی هدایت الکتریکی رودخانه کاکارضا مورد بررسی و ارزیابی قرار گرفت و نتایج آن با مدل شبکه عصبی مصنوعی مقایسه شد. که برای این منظور هیدروژن کربنات، کلرید، سولفات، کلسیم، منیزیم، سدیم و دی‌جریان در مقیاس زمانی ماهانه در طی دوره آماری (۱۳۹۳-۱۳۴۷) بعنوان ورودی و هدایت الکتریکی به‌عنوان پارامتر خروجی انتخاب گردید. معیارهای ضریب همبستگی، ریشه میانگین مربعات خطا و ضریب نش ساتکلیف برای ارزیابی و عملکرد مدل مورد استفاده قرار گرفت. نتایج حاصله نشان داد مدل شبکه عصبی موجک دارای بیشترین ضریب همبستگی (۰/۹۷۷)، کمترین ریشه میانگین مربعات خطا (۰/۰۳۲ ds/m) و نیز بیشترین معیار نش ساتکلیف (۰/۸۴۷) در مرحله صحت سنجی در اولویت قرار گرفت. در مجموع نتایج نشان داد مدل شبکه عصبی موجک در تخمین مقادیر حداقل و حداکثر دقت بالایی از خود نشان داده است. نتایج حاکی از توانمندی قابل قبول مدل شبکه عصبی موجک در تخمین هدایت الکتریکی آب رودخانه‌ها است. کلمات کلیدی: شبکه عصبی موجک، شبکه عصبی مصنوعی، کاکارضا، مدل، هدایت الکتریکی

### مقدمه

رودخانه‌ها به‌عنوان مهم‌ترین منابع تأمین و انتقال آب مصرفی بخش‌های صنعت، کشاورزی و شرب از اهمیت خاصی برخوردار هستند. توسعه روزافزون فعالیت‌های کشاورزی و صنعتی و افزایش حجم فاضلاب‌های شهری موجب آلودگی رودخانه‌ها گشته، به‌نحوی که کیفیت این منابع حیاتی آب را مورد مخاطره جدی قرار داده است. همچنین به دلیل ورود پساب‌های صنعتی، کشاورزی و غیر کشاورزی (ناشی از اجرای طرح‌های توسعه کشاورزی و پرورش ماهی) و فاضلاب شهری به رودخانه‌ها و نیز کاهش نزولات جوی و افزایش مصرف آب در سال‌های اخیر، مشکل عمده آب رودخانه‌ها افزایش کلرور و شوری می‌باشد (۵). امروزه سیستم‌های هوشمند به‌طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرد، که مدل شبکه عصبی موجک و شبکه عصبی مصنوعی از جمله این مدل‌ها است. شبکه‌های عصبی مصنوعی با الهام از سیستم پردازش اطلاعات مغز طراحی که توانایی آن در تقریب الگوهای یک مساله سبب افزایش دامنه کاربرد این شبکه‌ها شده است (۷،۱۳). طی سال‌های اخیر استفاده از روش شبکه‌های عصبی در مطالعات کیفیت آب رودخانه مورد توجه محققین قرار گرفته است، که از جمله می‌توان به موارد ذیل اشاره نمود:

در پژوهشی یارمحمدی و همکاران (۱۹) جهت شبیه‌سازی کیفیت آب رودخانه کرخه با استفاده از شبکه عصبی مصنوعی، پارامترهای روز سال، دی، اشل سطح آب و دمای آب اندازه‌گیری شده را به‌عنوان ورودی‌های مدل در نظر گرفته و پارامترهای هدایت الکتریکی و نسبت جذب سدیم را تخمین زدند و با توجه به نتایج، توانایی بالای این مدل را به تأیید

رساندند. تکلیفی و اسدالهی (۱۶) از سوی دیگر در پژوهشی جهت پیش‌بینی هدایت الکتریکی رودخانه آجی چای دو روش شبکه عصبی دینامیکی از نوع بازگشتی (RNN) و شبکه عصبی استاتیکی چند لایه (mlp) مورد مقایسه قرار داده و نتایج حاصله نشان داد مدل شبکه عصبی مصنوعی دارای عملکردی قابل قبول و یک ابزار کارآمد جهت مدیریت کیفی و بهره‌برداری از آب این رودخانه‌ها می‌باشد. در پژوهشی بانژاد و همکاران (۱) پارامترهای کیفی رودخانه جاجرود و قره‌سو را با استفاده از شبکه عصبی موجک مورد بررسی قرار داده و به این نتیجه رسیدند که مدل شبکه عصبی موجک خطای پایین در تخمین پارامترهای کیفی دارد. ماریر و دندی (۱۰) میزان شوری رودخانه ماری را با استفاده از شبکه عصبی تخمین زدند و به این نتیجه رسیدند که مدل شبکه عصبی و شبکه‌های انتشار برگشتی ابزاری دقیق در تخمین میزان افت کیفیت این رودخانه بوده است. سینگ (۱۵) مدل شبکه عصبی را برای تخمین میزان غلظت اکسیژن محلول و اکسیژن خواهی بیوشیمیایی بر اساس ۱۱ پارامتر کیفی ماهانه آب در ایستگاه‌های مختلف هند توسعه داد. نتایج حاصل از این تحقیق نشان داد، مدل شبکه عصبی مصنوعی تطبیق خوبی با مقادیر اندازه‌گیری شده و مورد انتظار برای غلظت‌های رودخانه دارد. در پژوهشی دیگر نجاح و همکاران (۱۱) با استفاده از شبکه‌های عصبی به تخمین مواد جامد محلول، هدایت الکتریکی و کدورت رودخانه جوهور در مالزی نشان دادند که مدل‌های شبکه عصبی توانایی بالایی برای تخمین پارامترهای کیفی دارد. همچنین گرز و همکاران (۶) از شبکه عصبی پرسپترون چندلایه برای تخمین شاخص کیفیت آب در رودخانه کینتا واقع در مالزی استفاده کردند. نتایج نشان

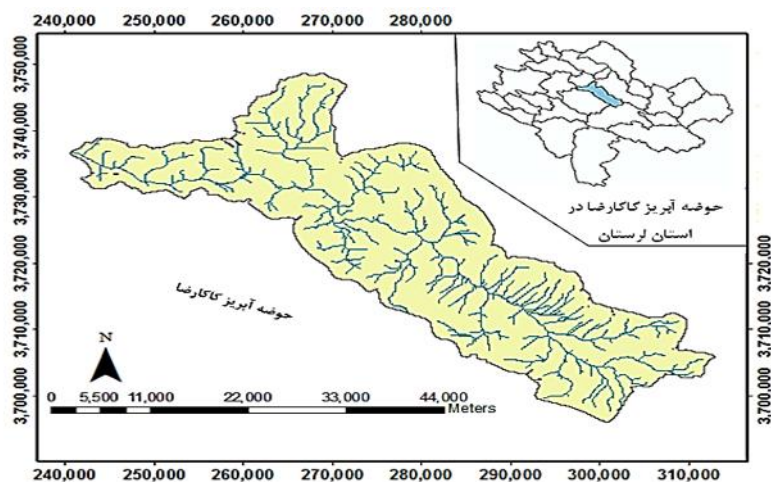
لرستان می‌باشد. این رودخانه از رودخانه‌های دائمی استان لرستان بوده و از کوه‌های جنوب شرقی شهرستان الشتر و بخش چغلوندی (هرود) سرچشمه گرفته و در محدوده شهرستان الشتر بنام کاکارضا معروف است. این رودخانه بین ۱۵° ۴۸' تا ۴۹° درجه طول شرقی و ۲۲° ۳۳' الی ۵۲° ۳۳' درجه عرض شمالی و در استان لرستان و شرق شهرستان خرم‌آباد واقع شده است و قسمتی از سرشاخه‌های رودخانه کرخه را در زاگرس تشکیل می‌دهد. که در شکل ۱ موقعیت جغرافیایی منطقه مورد مطالعه نشان داده شده است.

داد که مدل شبکه عصبی می‌تواند جایگزین مناسبی برای محاسبات طولانی شاخص کیفیت آب باشد. در مجموع با توجه به پژوهش‌های انجام شده و همچنین اهمیت مدل‌سازی هدایت الکتریکی آب رودخانه کاکارضا واقع در لرستان و اقدامات مدیریتی جهت بهبود کیفیت آب آن بیش‌ازپیش ضروری است. لذا هدف از این تحقیق تخمین هدایت الکتریکی آب رودخانه‌ها با استفاده از مدل شبکه عصبی موجک و مقایسه نتایج این شبکه با مدل شبکه عصبی مصنوعی می‌باشد.

## مواد و روش‌ها

### منطقه مورد مطالعه و داده‌های مورد استفاده

منطقه مورد مطالعه رودخانه کاکارضا واقع در استان



شکل ۱- موقعیت حوزه آبخیز منطقه مورد مطالعه  
Figure 1. Study area

انعطاف‌پذیری‌ها و مبانی ریاضی مستحکم ویولتها و آنالیز چند مقیاسی را دارا می‌باشند. در ویونت‌ها از دودسته توابع ویولت و توابع مقیاس (scaling functions) استفاده می‌شود. یک خانواده از توابع مقیاس  $W(x)$  به صورت زیر معرفی می‌شوند:

$$W_{m,k}(x) = 2^{-m/2} W(2^{-m}x - k) \quad m, k \in \mathbb{Z} \quad (1)$$

اگر  $W(x)$  را یک تابع مقیاس مادر در نظر بگیریم، مقادیر  $2^{-m}$  و  $k$  به ترتیب مربوط به گسترش و انتقال تابع مقیاس مادر هستند. توابع مقیاس رزولوشن  $m$ ،  $W_{m,k}(x)$  در اصل پایه‌های متعام فضای برداری  $V_m$  در رزولوشن  $m$  می‌باشند. به عبارتی فضای برداری  $V_m$  حاوی کلیه تقریب‌های تابع  $f(x)$  با رزولوشن  $m$  و توسط توابع  $W_{m,k}(x)$  می‌باشد. بنابراین فضاهای برداری  $\{V_m\}$  حاوی تقریب‌های مختلف تابع  $f(x)$  در رزولوشن‌های مختلف می‌باشند. حال اگر  $wm$  را

رودخانه کاکارضا در ارتفاع ۱۵۵۰ متری از سطح آب‌های آزاد قرار دارد. مساحت حوزه کاکارضا ۱۱۴۸ کیلومترمربع و دارای رودخانه‌ای بطول ۸۵ کیلومتر می‌باشد. رودخانه کاکارضا پس از پیوستن به رودخانه‌های کشکان، سیمره و کرخه، در نهایت به خلیج فارس می‌ریزد. در این تحقیق داده‌های متغیرهای کمی و کیفی در مقیاس زمانی ماهانه شامل هیدروژن کربنات ( $\text{HCO}_3$ )، کلرید ( $\text{Cl}$ )، سولفات ( $\text{SO}_4$ )، کلسیم ( $\text{Ca}$ )، منیزیم ( $\text{Mg}$ )، سدیم ( $\text{Na}$ ) برحسب میلی‌گرم بر لیتر ( $\text{mg/lit}$ ) و دبی جریان ( $Q$ ) برحسب  $\text{lit/s}$  و نیز هدایت الکتریکی ( $\text{EC}$ ) برحسب دسی‌زیمنس بر متر ( $\text{ds/m}$ ) مربوط به ایستگاه هرود (کاکارضا) از سال ۱۳۴۷ تا ۱۳۹۳ که در شرکت آب منطقه‌ای استان لرستان در دسترس بود، استفاده شد. این رودخانه، فاقد داده‌های مفقود بوده و آزمون تصادفی بودن داده‌ها قبل از تحلیل و مدل‌سازی انجام گرفت.

### شبکه عصبی موجک

شبکه‌های عصبی مبتنی بر ویولت که ویونت نامیده می‌شوند از ترکیب دو تئوری ویولتها و شبکه‌های عصبی بوجود آمده‌اند (۱۸). این شبکه‌ها هم از مزایا و ویژگی‌های شبکه‌های عصبی برخوردارند و هم جذابیت‌ها و

شبکه عصبی ویولت بر مبنای روابط (۳) و (۴) شکل می‌گیرد و دارای الگوریتم‌های آموزش مخصوص خود می‌باشد که در پژوهش وانگ و همکاران (۱۸) به صورت کامل مورد بررسی قرار گرفته است. لازم به ذکر است در حالت کلی خانواده ویولتهای پیوسته نیز به صورت زیر بیان می‌شود:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad a, b \in R \quad (5)$$

و تبدیل ویولت برای توابع پیوسته به وسیله رابطه زیر محاسبه می‌شود:

$$W_{a,b}(f) = \tilde{f}_{(a,b)} = \langle \psi_{a,b}(t), f(t) \rangle = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (6)$$

در اینجا پارامتر  $a$  بعنوان پارامتر گسترش و متناسب با فرکانس می‌باشد (بعبارت دیگر پارامتر تأخیر کوچک متناظر با فرکانس بالا و پارامتر تأخیر بزرگ متناظر با فرکانس پایین می‌باشد) و پارامتر  $b$  بعنوان پارامتر انتقال و متناسب با زمان می‌باشد. نمونه ایی از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۲ نشان داده شده است.

فضای برداری متعامد با  $V^m$  در رزولوشن  $m$  فرض کنیم آنگاه می‌توان دسته‌ای دیگر از پایه‌های متعامد فضای  $w^m$  که ویولت  $\psi(x)$  نامیده می‌شوند را نیز بصورت زیر بیان نمود:

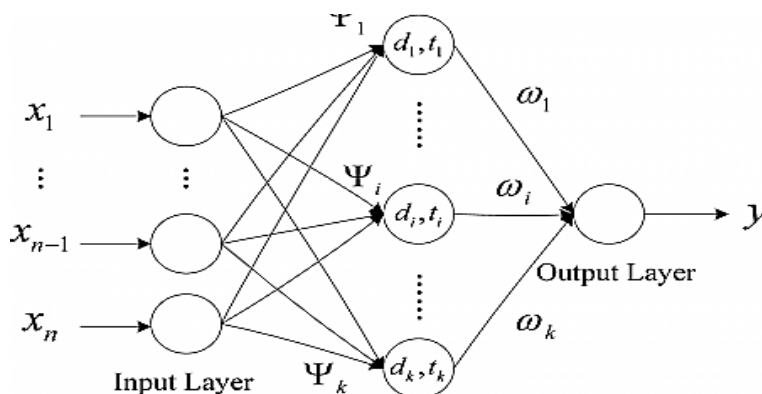
$$\psi_{m,k}(x) = 2^{-m/2} \psi(2^{-m}x - k) \quad m, k \in Z \quad (2)$$

در حالت کلی همه توابع فیزیکی را می‌توان به کمک ویولت‌ها و توابع مقیاس بصورت زیر بیان نمود:

$$f(x) = f_0(x) + \sum_{m=-\infty}^0 \sum_{k=-\infty}^{\infty} d_{m,k} \psi_{m,k}(x) \quad (3)$$

$$f_0(x) = \sum_k a_{0,k} \phi_{0,k}(x) \quad (4)$$

روابط فوق بیان می‌دارند که هر تابع فیزیکی را می‌توان ابتدا به کمک تعدادی توابع مقیاس در رزولوشن صفر تقریب زد و سپس به کمک توابع ویولت در رزولوشن‌های مختلف آن تقریب را تا میزان دقت مورد نظر ادامه داد.



شکل ۲- نمای کلی یک شبکه عصبی موجک سه لایه‌ای  
Figure 2. A three-layer Wavelet neural network overview

انتقال و مقیاس مناسب به موجک فرزند تبدیل می‌شود. ج- توابع فعال‌سازی نرون‌های لایه پنهان شبکه عصبی با انواع موجک‌های فرزند جایگزین می‌شود. د- شبکه عصبی ویولت ایجاد شده با استفاده از مجموعه داده‌های مربوط به آموزش شبکه، آموزش داده می‌شود. ه- عملکرد کلی شبکه موجک با تجزیه و تحلیل نحوه تخمین داده‌های صحت سنجی مورد بررسی قرار می‌گیرد. و با رضایت بخش بودن عملکرد شبکه مرحله آموزش به اتمام می‌رسد. در غیر این صورت مراحل قبل تا دستیابی به بهترین حالت مورد ارزیابی قرار می‌گیرد (۹).

#### شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی با الهام از سیستم پردازش اطلاعات مغز طراحی و به عرصه ظهور رسیده‌اند که به کمک فرآیند یادگیری<sup>۱</sup> و با استفاده از پردازشگرهایی به نام نرون تلاش می‌کند با شناخت روابط ذاتی بین داده‌ها، نگاهی میان


#### الگوریتم ویولت

تلفیق تئوری موجک با مفاهیم شبکه عصبی منجر به ایجاد شبکه عصبی موجک می‌گردد و بکارگیری آن می‌تواند جایگزین مناسبی در شبکه‌های عصبی پیشخور جهت تخمین و تقریب توابع غیرخطی اختیاری باشد. شبکه‌های عصبی پیشخور، دارای تابع فعال‌سازی سیگموئید در لایه پنهان می‌باشد در حالیکه در شبکه‌های عصبی موجک، توابع موجک بعنوان تابع فعال‌سازی لایه پنهان شبکه پیشخور در نظر گرفته می‌شوند در این شبکه‌ها هر دو پارامتر انتقال و تغییر مقیاس موجک‌ها در کنار وزن‌هایشان بهینه می‌گردند. در مجموع گام‌های مهم در آموزش و صحت سنجی شبکه عصبی موجک بصورت زیر است.

الف- داده‌های ورودی به دودسته جهت آموزش شبکه و صحت سنجی مورد استفاده قرار می‌گیرند.

ب- موجک مادر با احراز شرایط یاد شده پس از اعمال ضرایب

فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. لایه یا لایه‌های مخفی، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهند. نمونه ایی از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۳ نشان داده شده است.



شکل ۳- نمای کلی یک شبکه عصبی مصنوعی سه لایه  
Figure 3. A three-layer artificial neural network overview

### معیارهای ارزیابی

در این تحقیق به منظور ارزیابی دقت و کارایی مدل‌ها، از نمایه‌های ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE) و ضریب نش ساتکلیف (NS) طبق روابط زیر استفاده گردید. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و یک می‌باشد.

$$CC = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad (7)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (8)$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad -\infty \leq NS \leq 1 \quad (9)$$

در روابط بالا،  $x_i$  و  $y_i$  به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی  $i$ ام،  $N$  تعداد گام‌های زمانی،  $\bar{x}$  و  $\bar{y}$  نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی - محاسباتی نسبت به زمان نیز جهت تحلیل بیشتر نتایج استفاده شده است. یک نکته مهم در آموزش شبکه‌های عصبی نرمال‌سازی داده‌ها قبل از استفاده در مدل می‌باشد این عمل خصوصاً وقتی دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. اصولاً وارد کردن داده‌ها بصورت خام باعث کاهش سرعت و دقت شبکه می‌شود (۲۰). برای نرمال‌سازی داده‌های تحقیق از رابطه ۱۰ استفاده شده است:

$$X_n = 0.1 + 0.8 \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (10)$$

که در آن  $X_n$  مقدار نرمال شده ورودی  $X_i$ ،  $X_{min}$  و  $X_{max}$  به ترتیب حداکثر و حداقل داده‌ها می‌باشد.

با توجه به ساختار شبکه عصبی مصنوعی، ویژگی‌های عمده آن سرعت بالای پردازش، توانایی یادگیری الگو، توانایی تعمیم الگو پس از یادگیری، انعطاف‌پذیری در برابر خطاهای ناخواسته و عدم ایجاد اختلال قابل توجه در صورت بروز اشکال در بخشی از اتصال‌ها به دلیل توزیع وزن‌های شبکه است. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چندلایه<sup>۱</sup> انجام گرفت. برای آموزش این شبکه معمولاً از الگوریتم پس انتشار (BP)<sup>۲</sup> استفاده می‌شود که اساس این الگوریتم بر پایه قانون یادگیری اصلاح خطا می‌باشد که از دو مسیر اصلی رفت و برگشت تشکیل می‌شود. تنظیم پارامترها در شبکه پرسپترون چندلایه توسط سیگنال خطا و سیگنال ورودی صورت می‌گیرد. تعیین تعداد لایه‌ها و نرون‌های موجود در آنها از مهم‌ترین مسائل در شبیه‌سازی با شبکه عصبی مصنوعی است. رایج‌ترین توابع محرک استفاده شده در شبکه‌های انتشار برگشتی را توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کردند (۸). در طی آموزش شبکه MLP به کمک الگوریتم یادگیری BP، ابتدا محاسبات از ورودی به سوی خروجی شبکه انجام می‌شود، سپس مقادیر خطای محاسبه شده به لایه‌های قبل انتشار می‌یابد. در ابتدا محاسبه خروجی به صورت لایه به لایه انجام می‌شود و خروجی هر لایه، ورودی لایه بعدی خواهد بود که مراحل آموزش به کمک این الگوریتم عبارتند از (۳ و ۱۷):  
(الف) اختصاص ماتریس وزن به هر یک از اتصالات؛ (ب) انتخاب بردار ورودی و خروجی متناسب با آن؛ (پ) محاسبه خروجی نرون در هر لایه و در نتیجه محاسبه خروجی نرون‌ها در لایه خروجی؛ (ت) بهنگام سازی وزن‌ها به روش انتشار خطای شبکه به لایه‌های قبل که خطای یادشده ناشی از اختلاف بین خروجی واقعی و خروجی محاسبه شده است؛ (ث) ارزیابی عملکرد شبکه آموزش دیده به کمک برخی شاخص‌های تعریف شده مانند جذر میانگین مربعات خطا (MSE)، سرانجام برگشت به مرحله (پ) یا پایان آموزش.

## نتایج و بحث

در این پژوهش به منظور مدل سازی کیفی هدایت الکتریکی از مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی استفاده شد. پارامترهای هیدروژن کربنات ( $\text{HCO}_3$ )، کلرید ( $\text{Cl}$ )، سولفات ( $\text{SO}_4$ )، کلسیم ( $\text{Ca}$ )، منیزیم ( $\text{Mg}$ )، سدیم ( $\text{Na}$ ) و دبی جریان ( $Q$ ) بعنوان ورودی و هدایت

الکتریکی آب ( $\text{EC}$ ) بعنوان پارامتر خروجی مدل بکار برده شد که در جدول ۱ خصوصیات آماری پارامترهای استفاده شده، مشاهده می‌شود. در ادامه نتایج مدل مورد استفاده ارائه می‌گردد. که در این میان ۸۰ درصد از داده‌ها (۱۹۰ رکورد)، به منظور آموزش و ۲۰ درصد مابقی (۴۷ رکورد)، برای صحت سنجی انتخاب گردید.

جدول ۱- مشخصات آماری متغیرهای کیفیت رودخانه کاکارضا

Table 1. Statistical properties of qualitative variables for Kakareza River

پارامتر	آموزش		صحت سنجی	
	مینیمم	میانگین	مینیمم	میانگین
پارامتر ورودی	۰/۱۰	۰/۳۱۵	۰/۱۰	۰/۱۷۴
	۰/۲۰۰	۲/۹۱۱	۰/۳۵۰	۱/۳۵۱
پارامتر خروجی	۰	۱/۶۱۲	۰	۱/۴۱۵
	۰/۰۵۰	۰/۴۰۳	۰/۰۵۰	۰/۲۰۲
پارامتر ورودی	۰/۹۰۰	۲/۱۴۵	۱/۳۰۰	۲/۹۱۴
	۰/۱۰۰	۰/۹۷۶	۰/۲۰۰	۱/۲۴۸
پارامتر خروجی	۰/۰۳۰	۰/۲۰۶	۰/۰۳۰	۰/۲۴۴
	۸۶	۳۶۲/۸۹۲	۷۹	۱۷۸/۰۵۷

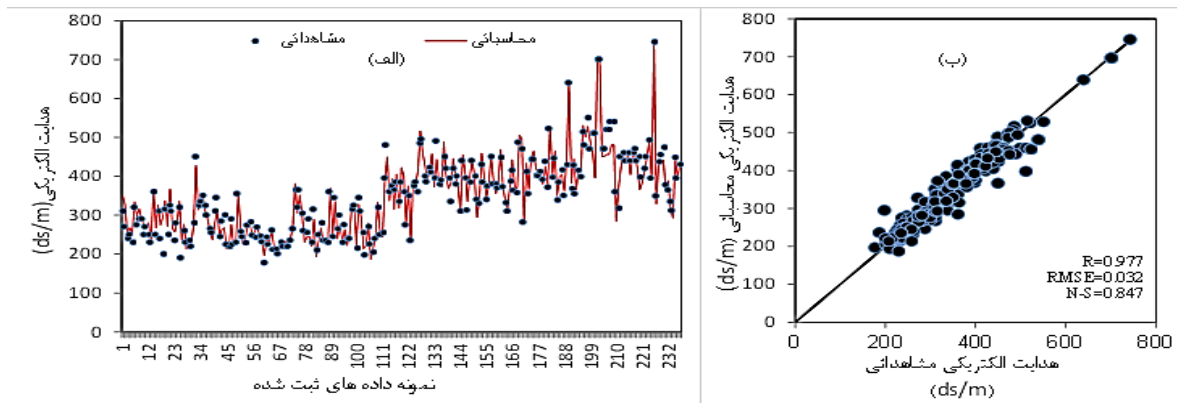
## نتایج شبکه عصبی موجک

به منظور مدل سازی هدایت الکتریکی آب رودخانه کاکارضا از مدل شبکه عصبی موجکی با لایه‌های پنهان و با تعداد نرون‌های متفاوت استفاده شده است. در مدل عصبی موجکی ابتدا موجک مناسب (سیملت) انتخاب گردید. سپس با اعمال تبدیل روی داده‌ها، ضرایب تقریب و جزئیات آنها استخراج گردید و داده‌ها بوسیله تابع موجک کلاسه مکزیکی به عنوان توابع فعال سازی که مشتق دوم تابع گوسی بوده، تبدیل می‌یابند. جهت آموزش شبکه از الگوریتم گرادیان نزولی که در یادگیری شبکه‌های عصبی و حداقل سازی مقدار خطای و تنظیم پارامترهای شبکه استفاده می‌شود، بکار گرفته شد. همان طور که در جدول ۲ مشاهده می‌شود ساختار شماره ۳ با ضریب همبستگی ۰/۹۷۷ و کمترین ریشه میانگین مربعات خطا ۰/۰۳۲ دسی زیمنس بر متر و ضریب نش ساتکلیف ۰/۸۴۷ در مرحله صحت سنجی نسبت به سایر ساختارها جهت مدل سازی شوری آب رودخانه درمقیاس زمانی ماهانه مناسب تر خواهد بود. در شکل ۴ نمودار بهترین مدل

حاصل شده برای داده‌های بخش صحت سنجی نشان داده شده است. که در این شکل تغییرات مقادیر محاسباتی و مشاهداتی نسبت به زمان قابل مشاهده است، همانطور که مشاهده می‌شود مدل شبکه عصبی موجکی در تخمین اکثر مقادیر عملکرد قابل قبولی داشته است و نیز در شکل ۴-ب تطابق مقادیر محاسباتی هدایت الکتریکی مربوط به مرحله صحت سنجی مدل شبکه عصبی موجک با مقادیر مشاهداتی وجود دارد. که با نتایج با نژاد و همکاران (۱) همخوانی دارد در تبیین این نتایج می‌توان بیان نمود تبدیل موجکی با جدا نمودن سیگنال به فرکانس‌های بالا و پائین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی، بالا می‌برد. سیگنال‌های بالا گذر و پایین گذر حاصل از تجزیه موجک، برازش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر می‌شود، دقت کار افزایش می‌یابد بسامدهای مراحل پایین تر تجزیه، نویز بیشتری دارند، ولی با افزایش سطح تجزیه از میزان نویز کاسته شده و سیگنال نرم تر می‌شود.

جدول ۲- نتایج حاصل از مدل شبکه‌های عصبی موجک در مراحل آموزش و صحت سنجی  
Table 2. The results of Wavelet neural network training and validation

شماره	ساختار	تابع محرک		آموزش			صحت سنجی		
		لایه پنهان	لایه خروجی	R	RMSE (ds/m)	NS	R	RMSE (ds/m)	NS
۱	۷-۲-۱	کلاه مکزیکی	خطی	-۰/۸۰۰	-۰/۰۷۱	-۰/۸۸۳	-۰/۸۴۷	-۰/۰۴۷	-۰/۸۲۶
۲	۷-۳-۱	کلاه مکزیکی	خطی	-۰/۸۰۰	-۰/۰۷۲	-۰/۸۲۲	-۰/۸۶۴	-۰/۰۴۷	-۰/۸۲۷
۳	۷-۴-۱	کلاه مکزیکی	خطی	-۰/۸۰۱	-۰/۰۷۱	-۰/۸۲۰	-۰/۹۷۷	-۰/۰۳۲	-۰/۸۴۷
۴	۷-۵-۱	کلاه مکزیکی	خطی	-۰/۷۸۹	-۰/۰۷۴	-۰/۸۷۰	-۰/۹۲۷	-۰/۰۴۶	-۰/۸۴۰
۵	۷-۷-۱	کلاه مکزیکی	خطی	-۰/۷۹۹	-۰/۰۷۲	-۰/۸۴۳	-۰/۹۲۷	-۰/۰۳۸	-۰/۸۴۵
۶	۷-۸-۱	کلاه مکزیکی	خطی	-۰/۷۹۵	-۰/۰۷۵	-۰/۹۶۳	-۰/۹۵۱	-۰/۰۴۸	-۰/۷۸۰
۷	۷-۹-۱	کلاه مکزیکی	خطی	-۰/۷۹۵	-۰/۰۷۱	-۰/۹۱۶	-۰/۹۶۰	-۰/۰۴۴	-۰/۸۲۳
۸	۷-۱۰-۱	کلاه مکزیکی	خطی	-۰/۷۸۰	-۰/۰۸۰	-۰/۹۴۵	-۰/۹۷۱	-۰/۰۳۵	-۰/۸۱۶
۹	۷-۱۲-۱	کلاه مکزیکی	خطی	-۰/۷۸۰	-۰/۰۷۸	-۰/۹۴۱	-۰/۹۵۸	-۰/۰۴۸	-۰/۷۵۰
۱۰	۷-۱۴-۱	کلاه مکزیکی	خطی	-۰/۸۰۰	-۰/۰۷۴	-۰/۸۸۷	-۰/۹۲۰	-۰/۰۴۵	-۰/۷۵۱
۱۱	۷-۱۵-۱	کلاه مکزیکی	خطی	-۰/۷۹۵	-۰/۰۱۶	-۰/۹۲۶	-۰/۹۶۴	-۰/۰۴۴	-۰/۷۴۶



شکل ۴- نمودار حاصل از مقادیر بهینه مدل شبکه عصبی موجک برای داده‌های ثبت شده مرحله آموزش و صحت سنجی  
الف) مقادیر محاسباتی و مشاهداتی نسبت به زمان ب) نمودار پراکنش میان مقادیر مشاهداتی و محاسباتی  
Figure 4. Diagram of optimal values of Wavelet neural network model for recorded data in validation phase  
A) The observed and computed values over time B) scattered plot of observed and computed values

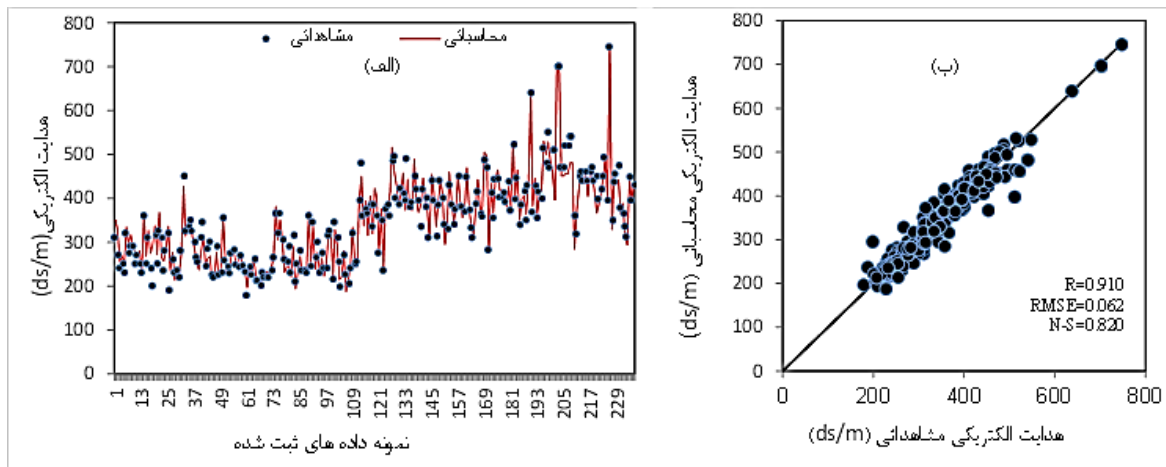
### نتایج شبکه عصبی مصنوعی

همچنین جهت مقایسه و ارزیابی نتایج شبکه عصبی موجک، از مدل شبکه عصبی مصنوعی استفاده شد. تابع تانژانت هیپربولیک متداول‌ترین شکل از توابع محرک است، که در این تحقیق از آن برای ساخت لایه خروجی شبکه‌های عصبی مصنوعی استفاده گردید. آموزش شبکه‌های پرسپترون چندلایه با استفاده از الگوریتم آموزش پس انتشار خطا بنام الگوریتم لونیگ - مارکواریت به دلیل همگرایی سریع‌تر در آموزش شبکه، استفاده شد. همچنین از ترکیبات مختلف توابع محرک در لایه (های) مخفی استفاده گردید. تعداد تکرارهای لازم در فرآیند یادگیری شبکه ۱۰۰۰ در نظر گرفته شده و عملکرد شبکه به کمک معیار میانگین مربعات خطا مورد ارزیابی قرار گرفته است. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مساله مورد بررسی مشخص شده، حال آنکه تعداد نرون‌های موجود در لایه پنهان با سعی و خطا در جهت کاهش مقدار خطا مشخص گردید. روند کار با تعداد نرون‌های کم آغاز و افزودن نرون‌های اضافی تا زمانی ادامه می‌یابد که افزایش نرون‌های بیشتر تأثیری در بهبود خطا نداشته باشد، که شبکه‌ای با ۱۴ نرون در لایه پنهان اول به‌عنوان بهترین شبکه در فرآیند مدل‌سازی حاصل شد. در جدول ۳ نتایج حاصل از مقایسه عملکرد ساختارهای مختلف به‌کاررفته به همراه پارامترهای آماری

داده‌های بخش آموزش و صحت‌سنجی ارائه شده است. همانطور که در جدول ۳ مشاهده می‌شود ساختار شماره ۱۰ با بیشترین ضریب همبستگی ۰/۹۱۰ و کمترین ریشه میانگین مربعات خطا ۰/۰۶۲ دسی زمینس بر متر و ضریب نش ساتکلیف ۰/۸۲۰ در مرحله صحت سنجی نسبت به سایر ساختارها جهت مدل‌سازی هدایت الکتریکی آب رودخانه کاکارضا مناسب‌تر خواهد بود. همان‌طور که در شکل ۵ مشخص است تطابق مقادیر محاسباتی هدایت الکتریکی مربوط به مرحله صحت سنجی مدل شبکه عصبی مصنوعی با مقادیر مشاهداتی وجود دارد. همان‌طور که در این شکل نشان داده شده است مدل شبکه عصبی مصنوعی در تخمین برخی مقادیر کمینه و بیشینه عملکرد خوبی داشته، به‌طوری‌که این مقادیر را نزدیک به مقدار واقعی‌شان تخمین زده است. که با نتایج تحقیق قربانی و دهقانی (۷)، عشقی و همکاران (۴) و دستورانی و همکاران (۲) مطابقت دارد در تبیین این نتایج می‌توان بیان نمود با توجه به ساختار شبکه‌های عصبی مصنوعی، ویژگی عمده آن سرعت بالای پردازش، توانایی یادگیری الگو، توانایی تعمیم الگو پس از یادگیری، انعطاف‌پذیری در برابر خطاهای ناخواسته و عدم ایجاد اختلال قابل‌توجه در صورت بروز اشکال در بخشی از اتصال‌ها به دلیل توزیع وزن‌های شبکه است.

جدول ۳- نتایج حاصل از مدل شبکه‌های عصبی مصنوعی در مراحل آموزش و صحت سنجی  
Table 3. The results of artificial neural network training and validation

شماره	ساختار	تابع محرک لایه پنهان	لایه خروجی	آموزش			صحت سنجی		
				R	RMSE (ds/m)	NS	R	RMSE (ds/m)	NS
۱	۷-۲-۱	تانژانت هیپربولیک	خطی	۰/۹۸۵	۰/۱۲۴	۰/۹۸۰	۰/۸۱۳	۰/۰۹۴	۰/۹۰۲
۲	۷-۳-۱	تانژانت هیپربولیک	خطی	۰/۹۸۵	۰/۱۲۰	۰/۹۹۰	۰/۸۱۲	۰/۰۸۸	۰/۹۰۲
۳	۷-۴-۱	تانژانت هیپربولیک	خطی	۰/۹۸۴	۰/۱۱۸	۰/۹۸۹	۰/۸۱۳	۰/۰۸۵	۰/۹۰۲
۴	۷-۵-۱	تانژانت هیپربولیک	خطی	۰/۹۸۵	۰/۱۱۸	۰/۹۹۱	۰/۸۱۳	۰/۰۸۶	۰/۹۰۶
۵	۷-۷-۱	تانژانت هیپربولیک	خطی	۰/۹۸۴	۰/۱۱۷	۰/۹۹۱	۰/۸۱۲	۰/۰۸۴	۰/۹۰۱
۶	۷-۸-۱	تانژانت هیپربولیک	خطی	۰/۹۸۴	۰/۱۱۸	۰/۹۹۱	۰/۸۱۲	۰/۰۷۶	۰/۹۰۷
۷	۷-۹-۱	تانژانت هیپربولیک	خطی	۰/۹۸۵	۰/۱۱۶	۰/۹۹۱	۰/۸۱۳	۰/۰۷۷	۰/۹۰۱
۸	۷-۱۲-۱	تانژانت هیپربولیک	خطی	۰/۹۸۵	۰/۱۱۷	۰/۹۹۲	۰/۸۱۳	۰/۰۷۰	۰/۹۰۱
۹	۷-۱۳-۱	تانژانت هیپربولیک	خطی	۰/۹۸۴	۰/۱۱۶	۰/۹۹۲	۰/۸۱۲	۰/۰۷۶	۰/۹۰۵
۱۰	۷-۱۴-۱	تانژانت هیپربولیک	خطی	۰/۹۸۵	۰/۱۱۸	۰/۹۹۳	۰/۸۲۰	۰/۰۶۲	۰/۹۱۰
۱۱	۷-۱۵-۱	تانژانت هیپربولیک	خطی	۰/۹۸۴	۰/۱۱۷	۰/۹۹۲	۰/۸۱۳	۰/۰۷۰	۰/۹۰۲

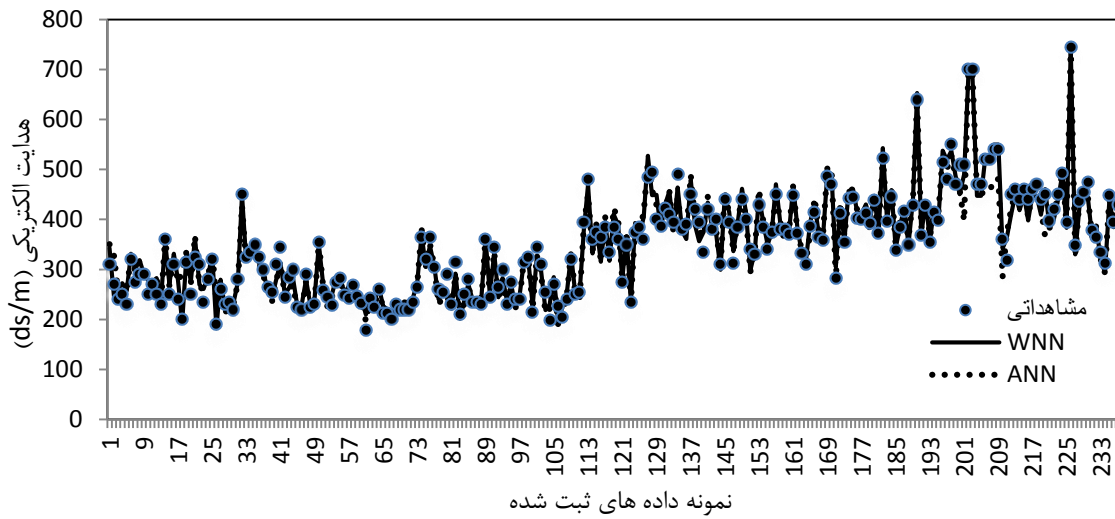


شکل ۵- نمودار حاصل از مقادیر بهینه مدل شبکه عصبی مصنوعی برای داده‌های ثبت شده مرحله آموزش و صحت سنجی  
(الف) مقادیر محاسباتی و مشاهداتی نسبت به زمان (ب) نمودار پراکنش میان مقادیر مشاهداتی و محاسباتی  
Figure 5. Diagram of optimal values of artificial neural network model for recorded data in validation phase  
A) The observed and computed values over time B) scattered plot of observed and computed values

نقش بسزایی دارد. در نهایت اختلاف مقادیر مشاهداتی هدایت الکتریکی و محاسباتی بهینه دو مدل به صورت درصدی از میانگین مقادیر مشاهداتی (مقدار خطا)، محاسبه و نمودار آن نسبت به نمونه داده‌های ثبت شده دوره آماری ترسیم گردید (شکل ۷). همانطور که در این شکل دیده می‌شود برای مدل‌های مذکور (شبکه عصبی موجک و شبکه عصبی مصنوعی) بیشتر خطا در باند  $\pm 10\%$  در صد قرار گرفته است. و بیشترین میزان خطای مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی به ترتیب  $18/693\%$  و  $21/022\%$  درصد از میانگین مقادیر مشاهداتی می‌باشد.


### مقایسه عملکرد مدل‌ها

در ادامه با انتخاب جواب بهینه هر کدام از مدل‌ها و مقایسه آن‌ها با یکدیگر مشخص شد، هر دو مدل با دقت خوبی می‌توانند هدایت الکتریکی آب رودخانه کاکارضا را شبیه‌سازی کنند. همانطور که در شکل ۵ نتایج هر دو مدل نسبت به مقادیر مشاهداتی در طی زمان نشان داده شده است مدل شبکه عصبی موجک در تخمین اکثر مقادیر عملکرد قابل قبولی دارد به گونه ای که کلیه مقادیر را نزدیک به مقدار واقعی تخمین زده است. که این نتایج با نتایج وانگ و همکاران (۱۸) همخوانی دارد در تبیین این نتایج می‌توان بیان نمود تجزیه موجک در جهت افزایش قدرت تفکیک سیگنال



شکل ۶- نمودار پراکنش و مشاهداتی - محاسباتی مقادیر بهینه مدل شبکه عصبی موجک و شبکه عصبی مصنوعی برای داده‌های ثبت شده مرحله آموزش و صحت سنجی

Figure 6. Diagram scatters plot and observations – computational optimal Wavelet neural network and artificial neural network models for recorded data validation phase



شکل ۷- نمودار خطای بهینه هر دو مدل به صورت درصدی از میانگین مقادیر مشاهداتی  
Figure 7. Optimal error diagram of both models, as percentage of the average observation values

آزمایشگاهی آن‌ها پرهزینه و زمان‌بر هستند، می‌باشد. همچنین دقت بالای شبکه عصبی موجک ناشی از تجزیه سیگنال با کمک تابع گسسته موجک، منجر به ساده‌تر شدن این سیگنال‌ها شده و باعث ایجاد برتری محسوسی نسبت به مدل شبکه عصبی مصنوعی می‌باشد. در مجموع این تحقیق نشان می‌دهد استفاده از مدل شبکه عصبی موجک می‌تواند در زمینه تخمین هدایت الکتریکی آب رودخانه‌ها مؤثر باشد و گامی در اتخاذ تصمیمات مدیریتی در جهت بهبود آب کشاورزی و شرب این رودخانه‌ها می‌باشد.

در پژوهش حاضر عملکرد مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی را جهت شبیه‌سازی هدایت الکتریکی آب رودخانه کاکارضا مورد ارزیابی قرار گرفت. نتایج تحقیق نشان داد که مدل شبکه عصبی موجک دقت بالا و خطای ناچیز در تخمین هدایت الکتریکی و قابلیت بسیار بالایی در تخمین برخی مقادیر کمینه، بیشینه و میانی نسبت به شبکه عصبی مصنوعی دارد. که با نتایج تحقیق بانژاد و همکاران (۱) مطابقت دارد در تبیین این نتایج می‌توان بیان نمود شبکه عصبی موجک قادر به پیش‌بینی پارامترهای کیفی آب در حجم بالا، احتیاج به اندازه‌گیری و کارهای

## منابع

1. Banejad, H., M. Kamali, K. Amirmoradi and E. Olyaie. 2014. Forecasting Some of the Qualitative Parameters of Rivers Using Wavelet Artificial Neural Network Hybrid (W-ANN) Model (Case of study: Jajroud River of Tehran and Gharaso River of Kermanshah). *Iranian Journal of Health and Environment*, 6(3): 277-294 (In Persian).
2. Dastorani, M.T., K.H. AzimiFashi and A. Talebi. 2011. Estimation of Suspended Sediment Using Journal of Artificial Neural Network. *Watershed Management Research*, 3(6): 61-74 (In Persian).
3. Dayhoff, J.E. 1990. *Neural Network Principles*: New York: Prentice-Hall International, 650pp.
4. Eshghi, P., J. Farzad Mehr, M.T. Dastorani and Z. Arab Asadi. 2017. The Effectiveness of Intelligent Models in Estimating the River Suspended Sediments (Case Study: Babaaman Basin, Northern Khorasan). *Watershed Management Research*, 7(14): 88-95 (In Persian).
5. Faryadi, S., K. Shahedi and M. Nabatpoor. 2013. Investigation of Water Quality Parameters in Tadjan River using Multivariate Statistical Techniques. *Journal of Watershed Management*, 6: 75-92 (In Persian).
6. Gazzaz, N.M., M.K. Yusoff, A. Zaharin Aris, H. Juahir and M.F. Ramli. 2012. Artificial neural network modeling of the water quality index for Kinta River (Malaysia) using water quality variables as predictors. *Journal of Marine Pollution Bulletin*, 64(1): 2409-2420.
7. Ghorbani, M.A. and R. Dehghani. 2017. Comparison of Bayesianneural Network, Artificial Neural Network Gene Expression Programming in River Water Quality (Case Study: Belkhiachay river). *Watershed Management Research*, 8(15): 13-24 (In Persian).
8. Khanna, T. 1990. *Foundation of neural networks: Addison-Wesley Series in New Horizons in Technology*: New York: Addison-Wesley, 540 pp.
9. Kaveh, A. and A. Iran Manesh. 2005. *Artificial neural network in the optimization of structures: Building and Housing Research Center*, pp: 112-120 (In Persian)
10. Maier, H.R. and G.C. Dandy. 1996. The use of artificial neural networks for the prediction of water quality parameters. *Water Resources Research*, 32(4): 1013-1022.
11. Najah, A., A. Elshafie, O. Karim and O. Jaffar. 2009. Prediction of Johor river water quality parameters using artificial neural networks. *European Journal of scientific research*, 28(4): 422-435.
12. Safavi, A.A. and J.A. Romania. 1997. Application of wavelet-based neural networks to modelling and optimisation of an experimental distillation column. (*IFAC Journal of Engineering Applications of Artificial Intelligence*, 10(3): 301-313).
13. Saf Sheken, F., N. Pir Moradian and R. Sharifian. 2012. Simulation of rainfall-runoff hydrograph and the use of artificial neural network model of rainfall in the catchment kasilian. *Iran-Watershed Management Science & Engineering*, 5(15): 1-10 (In Persian)
14. Sayadi, H., A. Olad Ghafari, A. Faalian and A. A. Sadr aldin. 2009. Comparison of RBF and MLP Neural Networks Performance for Estimation of Reference Crop Evapotranspiration. *Soil and Water*, 19(2): 1-12 (In Persian).
15. Singh, K.P., A. Basant, A. Malik and G. Jain .2009. Artificial neural network modeling of the river water quality-A Case Study. *Journal of Ecological Modeling*, 220(2): 888-895.
16. Taklifi, A. and G. Asadolah Fardi .2009. Comparison two models RNN and mlp for predict the amount of salt in AjiChay .Tenth Seminar irrigation and reduce evaporation, pp: 90-102 (In Persian).
17. Tokar, A.S. and P.A. Johnson . 1999 . Rainfall- Runoff modeling using artificial neural networks. *Journal of Hydrology Engineering*, 3(1): 232-239.
18. Wang, D., A.A. Safavi and J.A. Romagnoli .2000 . Wavelet-based adaptive robust M-estimator for non-linear system identification. *AIChE Journal*, 46(8): 1607-1615.
19. Yar Mohammadi, A., M. Chit Sazan, K. Rangzan and J. Mozafari Zadeh. 2006. Using artificial neural networks for simulate the water quality of river floodplains. *First Conference on Environmental Engineering*, pp: 68-75 (In Persian).
20. Zhu, Y.M., X.X. Lu and Y. Zhou . 2007. Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjian River in the Upper Yangtze Catchment. *Geomorphology*, 84(1): 111-125.

## Estimation of Rivers' Electrical Conductivity using Wavelet Neural Network (Case study: Kakareza River)

Mohammad Ali Ghorbani<sup>1</sup> and Reza Dehghani<sup>2</sup>

---

1- Associate Professor, University of Tabriz Science in Water Engineering

(Corresponding author: ghorbani@tabrizu.ac.ir)

2- M.Sc., Science in Water Engineering, University of Tabriz

Received: December 26, 2014 Accepted: May 17, 2015

---

### Abstract

Electrical conductivity (EC) is an important factor in river engineering, especially studying of river water quality. In this study we studied and evaluated wavelet neural network to predict the electrical conductivity of the Kakareza river (in lorestan), and the results were compared with results of artificial neural network model. For this purpose, hydrogen carbonate, chloride, sulfate, calcium, magnesium, sodium and flow rate at monthly scale during the period (1969-2015) as input and output parameters were selected as electrical conductivity. The criteria of correlation coefficient, root mean square error and of Nash Sutcliff coefficient were used to evaluate and performance compare of models. The results showed that wavelet neural network model has the highest correlation coefficient (0.977), the lowest root mean square error (0.032 ds/m) and the highest standards Nash Sutcliffe (0.847) became a priority in the validation phase. The results indicate acceptable capability of wavelet neural network models to estimate the electrical conductivity of river water.

**Keywords:** Artificial neural network, Electrical conductivity, Kakareza, Model, Wavelet neural network