

## شبیه‌سازی رسوب معلق رودخانه‌های کشور با استفاده از فناوری تلفیق مدل‌های هوشمند و سامانه مکانی متن‌باز، مطالعه موردی: ایستگاه هیدرومتری رازین، حوزه آبخیز رودخانه مزلقان در استان مرکزی

محمودرضا طباطبائی\*<sup>۱</sup> و امین صالح پورجم<sup>۲</sup>

<sup>۱</sup> استادیار پژوهشی پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

تاریخ پذیرش: ۱۳۹۹/۰۱/۲۵

تاریخ دریافت: ۱۳۹۸/۱۱/۰۵

### چکیده

روابط بین پارامترهای کیفی آب رودخانه و فرایندهای فیزیکی، ژئوشیمیایی و بیولوژیکی انجام‌شده بین منابع حوضه (خاک، پوشش گیاهی، زمین‌شناسی، کاربری اراضی و غیره)، متغیرهای هواشناسی (دما، بارش، ذوب برف و غیره)، متغیر هیدرولوژیکی رودخانه (دبی) و همچنین دخالت‌های انسانی، اغلب بسیار پیچیده، غیرقطعی و غیرخطی بوده به نحوی که درک کامل آن‌ها را غیرممکن می‌سازد. در این شرایط، استفاده از هوش محاسباتی (نظیر شبکه‌های عصبی مصنوعی) ابزار مناسبی در شبیه‌سازی و برآورد متغیرهای کیفی آب رودخانه نظیر بار رسوب معلق محسوب می‌شود. در پژوهش حاضر، با تلفیق کتابخانه‌های متن‌باز GIS و مدل‌های شبکه عصبی مصنوعی (با ناظر و بدون ناظر)، سامانه مکانی هوشمندی، طراحی و کدنویسی شده است که می‌تواند در شرایط تک‌متغیره یا چندمتغیره، رسوب معلق روزانه را برآورد کند. نتایج گرفته‌شده از به‌کارگیری این سامانه در حوزه آبخیز رودخانه مزلقان در محل ایستگاه هیدرومتری رازین نشان داد که این سامانه قادر است با کارایی و صحت‌سنجی مناسب (با ریشه میانگین مربعات خطا برابر ۱۰۳۳ تن در روز، میانگین قدر مطلق خطا ۴۵۵ تن در روز و شاخص نش-ساتکلیف برابر ۰/۸۹ با داده‌های آزمون)، رسوب معلق ایستگاه مورد مطالعه را شبیه‌سازی کند. در مجموع، این سامانه می‌تواند به‌عنوان یک زیرساخت نرم‌افزاری در مقیاس ملی، در شبیه‌سازی و مدیریت رسوب معلق کلیه ایستگاه‌های هیدرومتری کشور مورد استفاده سازمان‌های ذی‌ربط قرار گیرد.

**واژه‌های کلیدی:** برآورد، خوشه‌بندی داده‌ها، شبکه عصبی مصنوعی، صحت‌سنجی، نگاشت خود سازمان‌ده

### مقدمه

شبیه‌سازی و برآورد متغیرهای کیفیت آب رودخانه‌ها نظیر بار رسوب معلق محسوب می‌شوند. در این شیوه شبیه‌سازی، بر خلاف سایر روش‌های مدل‌سازی (معادلات فیزیک پایه یا تجربی)، نیازی به فرموله‌کردن فرایندهای موجود در حوضه و توصیف دقیق جزئیات

روش‌های محاسباتی نرم (شبکه‌های عصبی مصنوعی<sup>۱</sup>، فازی<sup>۲</sup>، نروفازی<sup>۳</sup> و غیره) ابزار مناسبی در

\* مسئول مکاتبات: taba1345@hotmail.com

<sup>۱</sup> Artificial Neural Networks (ANNs)

<sup>۲</sup> Fuzzy

<sup>۳</sup> Neuro-fuzzy

ورودی و از دبی رسوب به‌عنوان خروجی استفاده کردند. بهترین ورودی‌ها برای هر دو مدل با استفاده از الگوریتم ژنتیک و آزمون گاما تعیین شد. Kisi و Ozkan (۲۰۱۷) برای مدل‌سازی رسوب معلق در رودخانه ال در کالیفرنیا، داده‌های دو ایستگاه هیدرومتری در سال‌های ۱۹۶۶ تا ۱۹۷۷ را مورد بررسی قرار دادند. در مطالعه انجام‌شده، چهار روش رگرسیون خطی وزن‌دار، روش ماشین بردار پشتیبان<sup>۲</sup>، مدل شبکه عصبی مصنوعی و روش منحنی سنجه رسوب مورد بررسی و مقایسه قرار گرفتند. نتایج نشان داد که مدل شبکه عصبی مصنوعی در مقایسه با سایر مدل‌ها، برآورد بهتری از رسوب معلق را داشته است. Chen و Chau (۲۰۱۶) در دو ایستگاه در نزدیکی ایالت مونتانا در آمریکا، بار رسوب معلق را با استفاده از سه مدل شبکه عصبی مصنوعی چندلایه پیش‌رو (با سه لایه ورودی، پنهان و خروجی)، شبکه عصبی مصنوعی پیش‌رو با ساختار موازی دوتایی و شبکه عصبی مصنوعی ترکیبی مورد بررسی قرار دادند. نتایج نشان داد که در بین تمامی مدل‌های شبکه عصبی مصنوعی به‌کار رفته، شبکه عصبی مصنوعی چندلایه پیش‌رو، با کمترین مقدار میانگین مربعات خطا<sup>۳</sup> و بیشترین مقدار شاخص NSE<sup>۴</sup>، بهترین مدل برای برآورد بار رسوب معلق بوده است. Demirci و Baltaci (۲۰۱۲) در پژوهشی در ایستگاه ساکرامنتو فری‌پورت در آمریکا، به‌منظور برآورد مقدار غلظت رسوب معلق از روش منطق فازی، رگرسیونی و منحنی سنجه رسوب استفاده کردند. در این پژوهش، از داده‌های دبی جریان، غلظت رسوب معلق و دمای آب که به‌طور پیوسته در مدت زمان پنج سال تهیه شده بود، برای برآورد مقدار غلظت رسوب معلق استفاده شد. نتایج پژوهش حاکی از برتری دقت مدل فازی نسبت به سایر روش‌ها بود. Kisi و Shiri (۲۰۱۲)، به‌منظور برآورد غلظت رسوب معلق روزانه رودخانه Eel در ایالت کالیفرنیا آمریکا، از سه مدل شبکه عصبی، نروفازی و برنامه‌ریزی ژنتیک<sup>۵</sup> (GEP) استفاده کردند. متغیرهای مورد استفاده در مدل‌ها، شامل متغیرهای

آن‌ها نبوده، بلکه با معرفی مجموعه‌ای محدود از متغیرهای مناسب سامانه (حوزه آبخیز) در قالب داده‌های ورودی و خروجی، قوانین و روابط ماوراء موجود در بین داده‌ها کشف شده بدون آن‌که به آگاهی از خصوصیات و قوانین فیزیکی که فرایندهای سامانه را کنترل می‌کنند، نیاز باشد (Tayfur, ۲۰۱۲). در این ارتباط، در دهه اخیر محققین به‌دنبال استفاده از به‌کارگیری این شیوه‌های مدل‌سازی در زمینه برآورد بار رسوب معلق رودخانه‌ها بوده‌اند (Banejad و همکاران، ۲۰۱۵؛ Buyukyildiz و Kumcu, ۲۰۱۷؛ Chen و Chau, ۲۰۱۶؛ Khan و همکاران، ۲۰۱۹؛ Olyaie و همکاران، ۲۰۱۵). در پژوهشی، Ulke و همکاران (۲۰۰۹) با استفاده از مدل‌های نروفازی تطبیقی، منحنی سنجه رسوب<sup>۱</sup>، شبکه عصبی مصنوعی، رگرسیون چندمتغیره، مقدار رسوب معلق روزانه رودخانه گدیز در ترکیه را برآورد کردند. ورودی‌های مدل، شامل داده‌های دبی جریان (روزانه و یک روز قبل)، بارش (روزانه و یک روز قبل) و مقدار رسوب روزانه بود. مقایسه نتایج مدل‌ها نشان داد که در برآورد رسوب معلق، روش‌های مبتنی بر هوش محاسباتی (نروفازی و شبکه عصبی)، برآوردهای دقیق‌تری نسبت به روش‌های رگرسیونی و منحنی سنجه رسوب داشته‌اند. Mustafa و همکاران (۲۰۱۲) به‌منظور برآورد دبی رسوب معلق رودخانه پری در مالزی، از یک شبکه عصبی پرسپترون چندلایه استفاده کردند. آن‌ها به‌منظور آموزش شبکه عصبی مصنوعی، از چهار روش مختلف کاهش شیب، کاهش شیب با مونتوم، گرادیان توام و لونیبرگ مارکواردت (LM) بهره گرفتند. نتایج نشان داد که روش‌های LM و گرادیان توام، بهتر از سایر روش‌ها، در برآورد دبی رسوب عمل می‌کند با این حال، روش LM، به لحاظ سرعت زمانی، بسیار سریع‌تر از روش گرادیان توام باعث هم‌گرایی شبکه می‌شود. Kakaei Lafdani و همکاران (۲۰۱۳) توانائی مدل‌های شبکه عصبی و ماشین بردار پشتیبان در برآورد رسوب معلق روزانه رودخانه دویرج واقع در غرب ایران را مورد بررسی قرار دادند. آن‌ها از داده‌های بارش و دبی جریان به‌عنوان

<sup>2</sup> Support vector machine

<sup>3</sup> Root Mean Square Error (RMSE)

<sup>4</sup> Nash-Sutcliffe (NSE)

<sup>5</sup> Gene Expression Programming (GEP)

<sup>1</sup> Sediment Rating Curve (SRC)

استفاده در مدل‌های داده‌مبنای (نظیر مدل‌های رگرسیون، شبکه‌های عصبی، نروفازی) دارند (Li و همکاران، ۲۰۱۰؛ Nour و همکاران، ۲۰۰۶؛ May و همکاران، ۲۰۱۰؛ Kaufman و Rousseeuw، ۲۰۱۰؛ Bowden و همکاران، ۲۰۰۲). عدم استفاده از داده‌های مشابه و همگن در مجموعه‌های یادشده، تاثیرات بسیار مستقیم در میزان دقت و کارایی نهایی مدل‌های طراحی‌شده داشته، سبب کاهش قدرت تعمیم‌دهی آن‌ها خواهد شد (May و همکاران، ۲۰۱۰). در سامانه طراحی‌شده در این پژوهش، برای ایجاد مجموعه داده‌های همگن و مشابه از شبکه عصبی نگاشت خود سازمان‌ده<sup>۱</sup> استفاده شده است (Kohonen، ۱۹۹۸).

پژوهش حاضر با هدف ایجاد یک زیرساخت نرم‌افزاری در مقیاس ملی و برای کلیه ایستگاه‌های هیدرومتری کشور انجام شده که به کمک آن می‌توان، ضمن وحدت رویه در انجام مراحل مختلف مدل‌سازی رسوب معلق، نسبت به ذخیره‌سازی و مدیریت داده‌های رسوب‌سنجی ایستگاه‌های هیدرومتری کشور نیز اقدام کرد. در این راستا، علاوه بر تشریح اجمالی سامانه، مراحل مختلف شبیه‌سازی رسوب معلق ایستگاه هیدرومتری رازین (واقع در حوضه رودخانه مزلقان در استان مرکزی) تشریح و نتایج آن مورد ارزیابی قرار می‌گیرد.

### مواد و روش‌ها

**منطقه مورد مطالعه:** پژوهش حاضر در حوزه آبخیز رودخانه مزلقان (یکی از زیرحوضه‌های آبخیز حوضه دریاچه نمک) در محل ایستگاه هیدرومتری رازین واقع در استان مرکزی انجام شده است. این ایستگاه با کد ۴۱-۰۵۹، در موقعیت  $50^{\circ} 07'$  طول شرقی و  $1^{\circ} 35'$  عرض شمالی در سال ۱۳۴۹ بر روی رودخانه مزلقان تاسیس شده است. این ایستگاه همچنین به لحاظ کیفیت تجهیزات، جزء ایستگاه‌های درجه یک محسوب می‌شود. داده‌های آب‌سنجی مورد استفاده در این پژوهش، شامل دبی لحظه‌ای و دبی رسوب معلق

بارش روزانه، دبی جریان روزانه و غلظت رسوب معلق روزانه بود. نتایج نشان داد که عملکرد مدل برنامه‌ریزی ژنتیک بهتر از سایر مدل‌ها است. Wang و Tfwala (۲۰۱۲)، برای برآورد دقیق‌تر بار رسوب معلق در رودخانه شیون تایوان به مقایسه دو مدل منحنی سنج رسوب و شبکه عصبی مصنوعی پرداختند. آن‌ها از ۱۷۰ داده رسوب معلق و دبی جریان برای برآورد بار رسوب معلق<sup>۱</sup> استفاده کردند. در این رابطه، از ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد مابقی برای آزمون شبکه عصبی مصنوعی و منحنی سنج رسوب استفاده شد. نتایج نشان داد که مدل شبکه عصبی مصنوعی کارایی بیشتری در تخمین بار رسوب معلق نسبت به منحنی سنج رسوب داشته است. Joshi و همکاران (۲۰۱۶)، بیان کردند که غلظت رسوب معلق با ویژگی‌های هیدرولوژیکی حوزه آبخیز رابطه - غیرخطی داشته، به همین دلیل، استفاده از روش‌های سنتی منحنی سنج رسوب نمی‌تواند تخمین درستی در برآورد غلظت رسوب معلق داشته باشد. در نتیجه، از روش‌های مبتنی بر شبکه عصبی مصنوعی برای مدل‌سازی رسوب معلق استفاده کردند. در این پژوهش، رابطه بین غلظت رسوب معلق با رواناب حاصل از ذوب برف در منطقه یخچال‌های طبیعی کنگتری در هیمالیا طی یک دوره ۱۱ ساله از سال ۱۹۹۹ تا ۲۰۰۹ با استفاده از شبکه عصبی مصنوعی پیش‌رو با الگوریتم پس‌انتشار خطا مورد بررسی قرار گرفت. بررسی آماره‌های ریشه میانگین مربعات خطا<sup>۲</sup>، میانگین قدر مطلق خطا<sup>۳</sup> و ضریب تبیین<sup>۴</sup> نشان داد که مدل شبکه عصبی مصنوعی برآورد دقیق‌تری از غلظت رسوب معلق نسبت به منحنی سنج رسوب داشته است.

خوشه‌بندی داده‌ها و نمونه‌گیری از خوشه‌های حاصله، نقش مهمی در ساخت مجموعه داده‌های همگن و مشابه (نظیر مجموعه داده‌های واسنجی<sup>۵</sup> یا آموزش<sup>۶</sup>، اعتبارسنجی متقابل<sup>۷</sup> و آزمون<sup>۸</sup>) برای

<sup>1</sup> Suspended sediment load

<sup>2</sup> Root Mean Square Error (RMSE)

<sup>3</sup> Mean Absolute Error (MAE)

<sup>4</sup> Coefficient of determination ( $R^2$ )

<sup>5</sup> Calibration data set

<sup>6</sup> Training data set

<sup>7</sup> Cross-validation data set

<sup>8</sup> Test data set

<sup>9</sup> Data driven models

<sup>10</sup> Self-organizing map

رکوردهای اطلاعاتی مورد استفاده پس از حذف آمار خالی و تکراری مجموعاً ۴۱۷ نمونه بوده که خصوصیات آماری آن‌ها در جدول ۱ ارائه شده است.

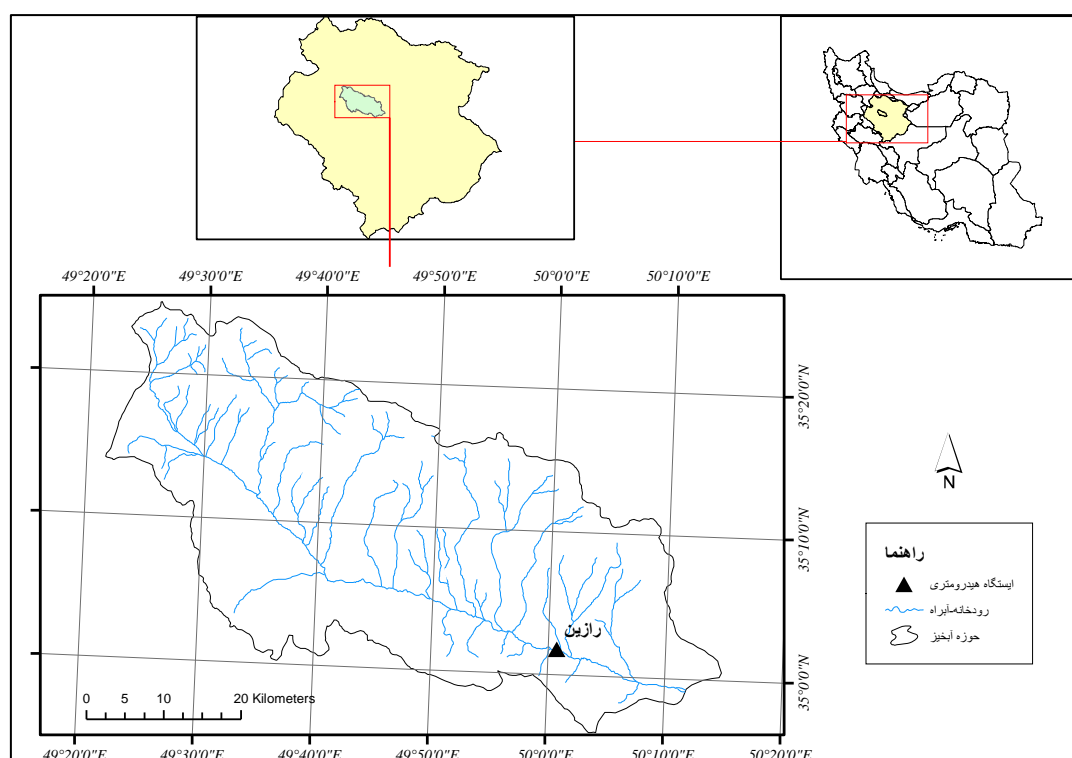
روزانه ایستگاه مربوطه بوده که از مرکز آمار تحقیقات منابع آب وزارت نیرو (تماب) اخذ شده است. دوره آماری طرح بین سال‌های ۱۳۴۹ تا ۱۳۹۲ است. تعداد

جدول ۱- ویژگی‌های آماری داده‌های آب‌سنجی ایستگاه هیدرومتری رازین (۱۳۴۹ تا ۱۳۹۲)

دبی لحظه‌ای ( $m^3 s^{-1}$ )	دبی رسوب معلق ( $tonday^{-1}$ )	خصوصیات آماری
۳۸/۸۸	۶۱۴۰۲/۶۹	بیشینه
۰/۰۱	۰	کمینه
۴/۹۶	۲۴۷۲/۷۵	میانگین
۵/۵۹	۶۵۳۱/۱۶	انحراف معیار
۲/۲	۴/۶۳	چولگی
۱۱۲/۷۰	۲۶۴/۱۳	ضریب تغییرات (درصد)

سایر آماره‌های محاسبه‌شده، بیانگر پیچیدگی مدل‌سازی و برآورد رسوب معلق رودخانه است. شکل ۱، موقعیت حوزه آبخیز رودخانه مزلقان در حوضه دریاچه نمک (به رنگ زرد) و ایستگاه هیدرومتری رازین را نشان می‌دهد.

همان‌طور که از اطلاعات آماری جدول ۱ استنباط می‌شود، دبی رسوب دارای چولگی و ضریب تغییرات زیاد بوده، تغییرات بین کمینه و بیشینه آن بسیار زیاد است. همچنین، وجود انحراف معیار زیاد داده‌های رسوب معلق در مقایسه با میانگین آن، حکایت از غیرنرمال بودن این داده‌ها دارد. این موضوع، به همراه



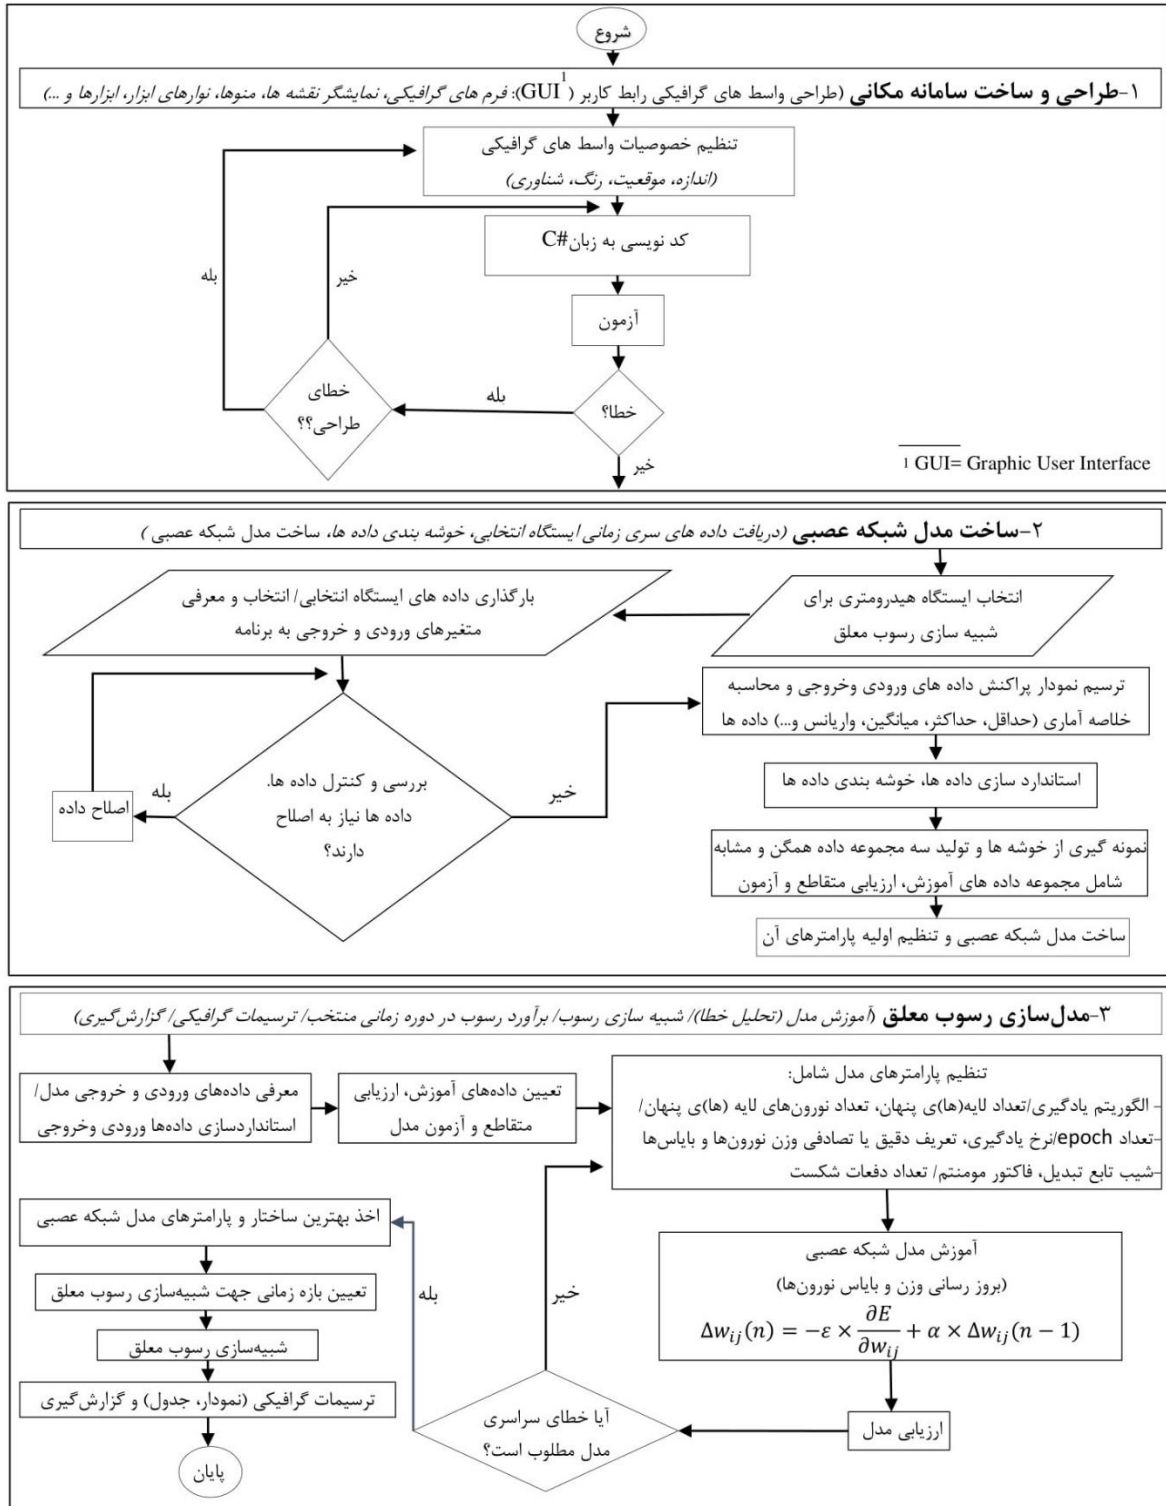
شکل ۱- موقعیت حوزه آبخیز رودخانه مزلقان و ایستگاه هیدرومتری رازین

کتابخانه‌های متن باز GIS و به‌کارگیری زبان برنامه‌نویسی #Visual C# NET Framework، به‌طور

ساختار نرم‌افزاری سامانه مکانی هوشمند شبیه‌ساز رسوب معلق: این سامانه با استفاده از

می‌شود. به‌منظور درک بهتر از چگونگی طراحی و کارکرد سامانه مکانی هوشمند شبیه‌ساز رسوب معلق، روند نمای سامانه مکانی به‌صورت اجمالی تهیه شده است تا کاربر بتواند با یک نگاه به‌صورت کلی، کارکرد سامانه را درک کند (شکل ۲).

کاملاً هدفمند طراحی و کدنویسی شده، برای ساخت آن تا کنون بالغ بر ۹۰۰۰ خط برنامه نوشته شده است. این سامانه همچنین، یک سامانه مکانی برای دسترسی سریع به داده‌های مکانی و سری‌های زمانی ایستگاه‌های هیدرومتری رودخانه‌های کشور محسوب



شکل ۲- روند نمای سامانه مکانی هوشمند شبیه‌ساز رسوب معلق در یک نگاه

لایه پنهان، قادر به تقریب زدن هر نوع تابع غیرخطی هستند (Hornik و همکاران ۱۹۸۹).

**تهیه داده‌های همگن برای آموزش و آزمون مدل‌ها:** به منظور افزایش قدرت تعمیم‌دهی و ساخت هرچه دقیق‌تر مدل شبکه عصبی، لازم است داده‌های مورد استفاده در آموزش مدل، معرف و نماینده داده‌های کل دوره آماری باشند. همچنین، به منظور آزمون و ارزیابی صحیح نتایج مدل، لازم است داده‌های آزمون، مشابه داده‌های آموزش و ارزیابی متقاطع به کار رفته در مدل بوده، در توزیع فراوانی یکسانی با آن‌ها باشند. بدین منظور در پژوهش حاضر از شبکه عصبی نگاشت خود سازمان‌ده<sup>۳</sup>، برای خوشه‌بندی داده‌ها و از روش تخصیص برابر<sup>۴</sup>، به منظور نمونه‌گیری از خوشه‌ها استفاده شده است. تعیین تعداد بهینه خوشه‌ها، به وسیله شاخص ارزیابی کیفیت خوشه‌بندی دیویس-بولدین<sup>۵</sup> انجام گرفته است. به منظور تحلیل نتایج آماری حاصل از خوشه‌بندی داده‌ها در سه مجموعه داده آموزش، ارزیابی متقاطع و آزمون، علاوه بر مقایسه پارامترهای آماری (میانگین، انحراف معیار، چولگی و غیره) آن‌ها با یکدیگر، از آزمون ناپارامتری دو نمونه‌ای کلموگروف-اسمیرنوف<sup>۶</sup> (Mansourfar, ۲۰۰۹) برای بررسی و مقایسه یکسان بودن توزیع داده‌های موجود در مجموعه‌های یادشده استفاده شده است که در ادامه به اختصار به آن‌ها اشاره می‌شود.

**شبکه عصبی نگاشت خود سازمان‌ده:** شبکه عصبی SOM، یک شبکه عصبی مصنوعی غیرنظارتی بوده، الگوریتم آموزش آن، به صورت رقابتی و بدون ناظر انجام می‌شود. ساختار SOM، از یک لایه ورودی و یک لایه خروجی (لایه کوهنن) تشکیل می‌شود (Kohonen, ۱۹۹۸). در این ساختار، نورون‌های لایه ورودی، محل ارتباط داده‌های ورودی با شبکه بوده، به ازاء هر متغیر ورودی، یک نورون در این لایه وجود دارد (به عنوان مثال دبی، بارش و غیره). لایه خروجی، ماتریس یا شبکه‌ای (عموماً یک شبکه دو بعدی) از نورون‌ها را تشکیل داده به نحوی که هر نورون این شبکه،

**شبکه عصبی مصنوعی پرسپترون چندلایه رو به جلو:** در پژوهش حاضر و در سامانه مکانی هوشمند شبیه‌ساز رسوب معلق، از شبکه عصبی مصنوعی با ناظر (پرسپترون چندلایه رو به جلو) برای شبیه‌سازی رسوب معلق استفاده شده است که در ادامه، به اختصار به آن اشاره می‌شود. این شبکه، از عناصر عملیاتی ساده‌ای به نام نرون ساخته شده است که به صورت موازی و در کنار هم، عمل می‌کنند. شبکه‌های عصبی چندلایه، از یک لایه ورودی (در ارتباط با داده‌های ورودی)، یک یا چندلایه پنهان (برای سازماندهی نرون‌ها) و یک لایه خروجی (در رابطه با داده خروجی) تشکیل می‌شوند. عملکرد شبکه عصبی، از طریق نحوه اتصال بین اجزاء، با تنظیم مقادیر هر اتصال که به نام وزن اتصال بیان می‌شود، تعیین می‌شود. یکی از انواع شبکه‌های عصبی پرکاربرد در هیدرولوژی و منابع آب، شبکه‌های عصبی پرسپترون چندلایه رو به جلو با الگوی آموزش پس‌انتشار<sup>۲</sup> خطا است (Uike و همکاران، ۲۰۰۹). در این نوع از شبکه‌های عصبی، برای جریان داده، از لایه ورودی به سمت لایه پنهان و از لایه پنهان به سمت لایه خروجی بوده، از این نظر به آن‌ها شبکه‌های عصبی رو به جلو یا پیشخور گفته می‌شود. به منظور آموزش شبکه عصبی، مقدار خطا در جهت بیشترین شیب تابع خطای محاسبه شده و این مقدار، به لایه‌های قبل (لایه یا لایه‌های پنهان) فرستاده شده تا با تنظیم مجدد مقادیر وزن نرون‌ها، مقدار خطا را کاهش دهند (فانون دلتا) (Tayfur, ۲۰۱۲) (رابطه ۱).

$$w_{ij}^{new} = w_{ij}^{old} - \eta \frac{\partial E}{\partial w_{ij}} \quad (1)$$

که در آن،  $\eta$  معین، تکرار یک بعد و قبل،  $i$  و  $j$  نرون‌های بین وزن به ترتیب  $w_{ij}^{old}$  و  $w_{ij}^{new}$  از نرخ یادگیری و  $E$  تابع خطا می‌باشد.

آموزش شبکه عصبی و کاهش خطا تا ایجاد همگرایی در شبکه ادامه می‌یابد. شبکه‌های عصبی می‌توانند دارای چندین لایه پنهان عصبی باشند، با این وجود، تحقیقات انجام شده نشان می‌دهد که شبکه‌های عصبی مصنوعی پیشخور، با دارا بودن یک

<sup>3</sup> Self-Organizing Map (SOM)

<sup>4</sup> Proportional allocation

<sup>5</sup> Davies-Bouldin index

<sup>6</sup> Two-sample Kolmogorov-Smirnov test (KS)

<sup>1</sup> Feed-Forward Multi-Layer Perceptron (FFMLP)

<sup>2</sup> Back propagation

همگن (مجموعه‌های آموزش، ارزیابی متقاطع و آزمون)، بایستی از خوشه‌های تولیدی به شکل مناسبی نمونه‌گیری به‌عمل آورده که در پژوهش حاضر، از روش تخصیص متناسب رابطه (۵)، به نسبت ۷۰، ۱۵ و ۱۵ درصد به‌ترتیب برای سه مجموعه داده یاد شده استفاده شده است. در روش تخصیص متناسب، تعداد نمونه‌ها متناسب با اندازه خوشه تغییر کرده بدین‌نحو که با افزایش اندازه هر خوشه، تعداد نمونه‌گیری از آن‌ها افزایش یافته، بالعکس، رابطه (۵):

$$nh = n \frac{Nh}{\sum_{j=1}^H N_j} \quad (5)$$

که در آن،  $nh$  تعداد نمونه گرفته شده از خوشه  $h$ ،  $n$  تعداد داده مورد نیاز،  $Nh$  تعداد داده‌ها در خوشه  $h$  و  $N_j$  تعداد داده در سایر خوشه‌ها است.

### تحلیل آماری داده‌های حاصل از خوشه‌بندی

**داده‌ها:** به‌منظور بررسی و مقایسه همگنی و مشابهت داده‌های مجموعه‌های آموزش، ارزیابی متقاطع و آزمون، علاوه بر مقایسه پارامترهای آماری (میانگین، انحراف معیار، چولگی و غیره) از آزمون ناپارامتری کولموگروف-اسمیرنوف دو نمونه‌ای، به‌منظور بررسی یکسانی و تشابه توزیع فراوانی داده‌ها در مجموعه داده‌های یاد شده استفاده شد. در این آزمون، فرض  $H_0$  و  $H_1$ ، به‌ترتیب یکسان بودن و یکسان نبودن توزیع داده‌ها در دو جمعیت را بیان می‌کند. در آزمون مربوطه، با محاسبه آماره آزمون  $D_c$ ، از رابطه (۶) و مقایسه آن با مقدار آماره بحرانی که با توجه به تعداد داده و سطح خطا (مثلاً درصد  $\alpha=5$ ) از جدول تعیین می‌شود، یکسان بودن توزیع جمعیت داده‌ها در مجموعه‌های مورد بررسی را می‌توان به‌صورت دو به دو با یکدیگر مقایسه کرد.

$$D_c = \text{Max} \left| \frac{F(n_{i1})}{n_1} - \frac{F(n_{i2})}{n_2} \right| \quad (6)$$

که در آن،  $F(n_{i1})$  و  $F(n_{i2})$  فراوانی تجمعی متغیر  $x$  در دو مجموعه مورد مقایسه و  $D_c$  آماره آزمون، بیشینه قدر مطلق اختلاف فراوانی تجمعی نسبی دو مجموعه است (Mansourfar, 2012). چنانچه آماره محاسبه شده آزمون ( $D_c$ ) از آماره جدول ( $D_i$ ) کوچک‌تر باشد، فرض  $H_0$  آزمون تأیید می‌شود. برای انجام این آزمون در این پژوهش، از توابع آماری موجود در محیط برنامه‌نویسی C# استفاده شده است. به‌منظور اطلاع بیشتر در زمینه تهیه داده‌های همگن و مشابه، خوشه

به کلیه نورون‌های لایه ورودی متصل بوده، ولی به نورون‌های دیگر این لایه متصل نیست. فرایند آموزش در شبکه SOM از سه مرحله رقابت<sup>۱</sup>، همکاری<sup>۲</sup> و تطبیق<sup>۳</sup> تشکیل می‌شود. در ابتدا وزن نورون‌های لایه خروجی به‌صورت تصادفی تعریف شده و در طی فرایند آموزش و در طول زمان، به مقادیر متغیرهای بردارهای ورودی بیشتر شبیه می‌شود. پس از آن که شبیه‌ترین نورون به بردار ورودی<sup>۴</sup> (BMU) مشخص شد، وزن‌های آن و وزن‌های دیگر نورون‌های همسایه آن، برحسب مقدار فاصله‌ای که از BMU دارند (فاز همکاری) بر طبق رابطه (۲) به‌هنگام می‌شوند (فاز تطبیق):

$$w_{ji}(t+1) = w_{ji}(t) + \theta(t) \times \eta(t) \times [x_i(t) - w_{ji}(t)] \quad (2)$$

که در آن،  $t$  نماینده زمان،  $\theta(t)$  تابعی است که فاصله نورون‌های همسایه BMU را به نسبتی از همسایگی تبدیل می‌کند و  $\eta(t)$  نرخ یادگیری است.

**استانداردسازی داده‌ها:** استاندارد کردن داده‌ها، به‌منظور بی‌بعد کردن آن‌ها در محاسبات فاصله (در عملیات خوشه‌بندی) و یا به‌منظور جلوگیری از کوچک‌شدن بیش از حد وزن‌های تخصیص یافته به نرون‌ها (در مدل‌های شبکه عصبی) است. در این پژوهش، با توجه به استفاده از توابع محرک سیگموئید و تانژانت هایپربولیک، به‌ترتیب از رابطه‌های (۳) و (۴) برای استاندارد کردن داده‌ها در بازه‌های  $[0/1-0/9]$  و  $[0/9-0/9]$  استفاده شده است.

$$z = 0.1 + (0.8 \times \frac{X_i - X_{imin}}{X_{imax} - X_{imin}}) \quad (3)$$

$$z = \left( \frac{1.8(X_i - X_{imin})}{X_{imax} - X_{imin}} \right) - 0.9 \quad (4)$$

که در آن،  $Z$  متغیر استاندارد شده،  $X_i$  متغیر اولیه،  $X_{imax}$  و  $X_{imin}$  به‌ترتیب مقادیر کمینه و بیشینه متغیر  $X_i$  است. در آموزش مدل‌های شبکه عصبی، از داده‌های دبی لحظه‌ای ( $Q_w$ ) به‌عنوان متغیر ورودی (تخمین‌گر مدل<sup>۵</sup>) و از بار رسوب معلق ( $Q_s$ ) به‌عنوان متغیر خروجی استفاده شده است.

**روش نمونه‌گیری از خوشه‌ها (تخصیص متناسب):** به‌منظور تهیه سه مجموعه حتی‌الامکان مشابه و

<sup>1</sup> Competitive phase

<sup>2</sup> Co-operative Phase

<sup>3</sup> Adaptive phase

<sup>4</sup> Best Matching Unit (BMU)

<sup>5</sup> Model predictor

### نتایج و بحث

الف- رابط‌های گرافیکی کاربر: سامانه مکانی شبیه‌ساز رسوب معلق از مجموعه‌ای از رابط‌های گرافیکی کاربر (نظیر پنجره‌های گفتگو، فرم‌های گرافیکی، منوها، ابزارها و غیره) تشکیل یافته است. علاوه بر ابزارهای تخصصی GIS، امکانات لازم به منظور تعامل کاربر با سامانه برای انجام محاسبات و پردازش‌های لازم در راستای مدل‌سازی و برآورد رسوب معلق ایستگاه‌های هیدرومتری کشور فراهم شده است. تعداد این رابط‌های گرافیکی با توجه به وظایف تعریف‌شده برای آن‌ها زیاد و متنوع بوده که به دلیل محدودیت، تنها به ذکر برخی از آن‌ها اکتفا می‌شود. شکل‌های ۳ و ۴، رابط‌های گرافیکی این سامانه را پس از اجرای سامانه نشان می‌دهد.

#### نوار ابزار تخصصی انتخاب ایستگاه هیدرومتری:

به منظور دسترسی سریع به اطلاعات توصیفی و یا سری زمانی ایستگاه هیدرومتری مورد مطالعه، لازم است، در ابتدا آن ایستگاه انتخاب شود. بدین خاطر از نوار ابزار انتخاب ایستگاه هیدرومتری شکل ۵ با تعیین ایستگاه مورد نظر که می‌تواند از طریق نام ایستگاه و یا کد ایستگاه انجام شود، ایستگاه هیدرومتری مورد نظر انتخاب می‌شود. با تعیین ایستگاه هیدرومتری، اطلاعات توصیفی ایستگاه، بلافاصله در جدولی در پائین پنجره اصلی نرم‌افزار، به صورت یک رکورد رنگی نمایش داده می‌شود (شکل ۶).

بندی داده‌ها و سایر تجزیه و تحلیل‌های مرتبط، به Tabatabaei و همکاران (۲۰۱۵)، Tabatabaei و همکاران (۲۰۱۹a,b) و Tabatabaei و همکاران (۲۰۲۰) مراجعه شود.

**ارزیابی و صحت‌سنجی کارائی مدل:** به منظور ارزیابی و مقایسه نتایج گرفته‌شده از مدل شبکه عصبی و مقایسه آن‌ها با داده‌های رسوب مشاهداتی (داده‌های مجموعه آزمون)، اندازه‌گیری مقدار خطا و ترسیمات گرافیکی انجام شد. به منظور صحت‌سنجی و بررسی میزان خطای محاسباتی مدل، از شاخص‌های ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، معیار نش-ساتکلیف (NS) و ضریب تبیین ( $R^2$ ) بین داده‌های مشاهده‌ای با داده‌های محاسباتی (به ترتیب رابطه‌های ۷ تا ۱۰) استفاده شد.

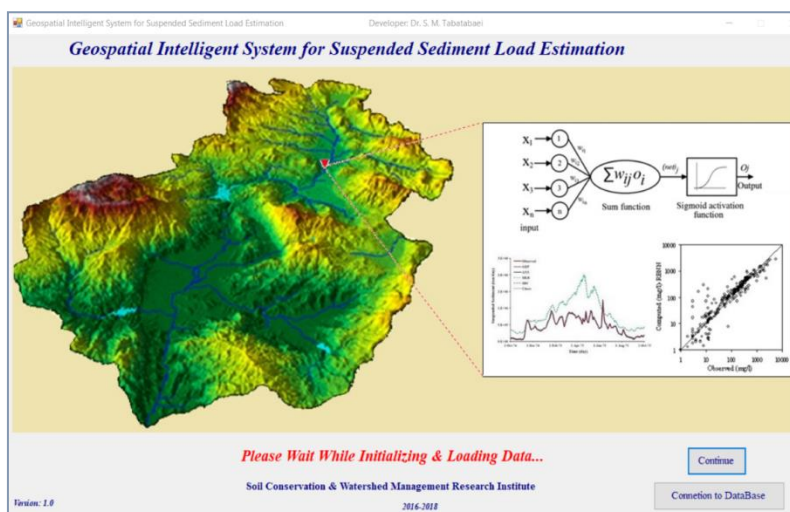
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_M - S_O)^2} \quad (7)$$

$$MAE = \frac{\sum_{i=1}^n |S_O - S_M|}{n} \quad (8)$$

$$NS = 1 - \frac{\sum_{i=1}^n (S_M - S_O)^2}{\sum_{i=1}^n (S_O - \bar{S}_O)^2} \quad (9)$$

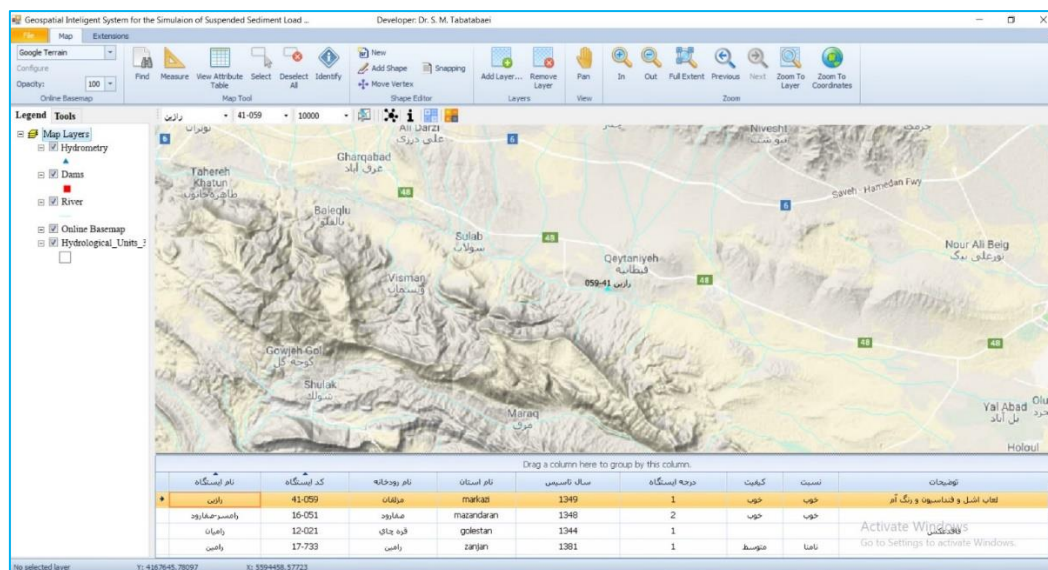
$$R^2 = \left[ \frac{\sum_{i=1}^n (S_O - \bar{S}_O)(S_M - \bar{S}_M)}{\sqrt{\sum_{i=1}^n (S_O - \bar{S}_O)^2 \sum_{i=1}^n (S_M - \bar{S}_M)^2}} \right]^2 \quad (10)$$

که در آن‌ها،  $S_M$  و  $S_O$  به ترتیب دبی رسوب معلق مشاهده‌ای و برآوردشده،  $\bar{S}_M$  میانگین دبی رسوب،  $\bar{S}_O$  میانگین دبی رسوب برآوردشده و  $n$  تعداد داده‌ها است.



شکل ۳- پنجره اولیه نشان داده شده پس از اجرای سامانه نرم‌افزاری





شکل ۴- پنجره اصلی سامانه با نقشه بر خط زمینه‌ای Terrain Google

دیویس بولدین، تعداد خوشه‌های بهینه  $K$  برای داده‌های مورد مطالعه، ۴۲ خوشه تعیین شد (شکل ۸).

نتایج پارامترهای آماری (معیارهای مرکزیت و پراکندگی داده‌ها) و نتایج مربوط به مقایسه توزیع داده‌ها (نتایج آزمون  $KS$ ) در سه مجموعه داده‌های آموزش، اعتبارسنجی متقاطع و آزمون برای ایستگاه هیدرومتری رازین به ترتیب در جداول ۲ و ۳ آمده است. همان‌طور که در جدول ۲ مشاهده می‌شود، نتایج خلاصه آماری متغیرهای دبی لحظه‌ای و دبی رسوب در سه مجموعه داده آموزش، اعتبارسنجی متقاطع و آزمون، تا اندازه زیادی مشابه به یکدیگر است. همچنین، نتایج گرفته‌شده از آزمون  $KS$  (جدول ۳)، بیانگر یکسان‌بودن توزیع داده‌ها در مجموعه داده‌های مورد بررسی است، لذا می‌توان نتیجه گرفت که از داده‌های مشابهی برای آموزش و صحت‌سنجی مدل‌ها استفاده شده است.

#### نوار ابزار تخصصی شبیه‌سازی رسوب معلق:

به‌منظور تولید مدل شبکه عصبی و شبیه‌سازی رسوب معلق برای هر یک از ایستگاه هیدرومتری انتخاب شده، از این نوار ابزار استفاده می‌شود (شکل ۷). با استفاده از ابزار موجود در این نوار، امکان ایجاد مدل شبکه عصبی و آموزش آن، گرفتن اطلاعات در خصوص وجود و یا عدم وجود مدل شبکه عصبی برای ایستگاه مورد نظر و شبیه‌سازی رسوب معلق برای ایستگاه هیدرومتری انتخاب‌شده در شرایط یک یا چندمتغیره وجود دارد.


مقیاس نمایش	کد ایستگاه	نام ایستگاه
1000	41-059	رازین

شکل ۵- نوار ابزار انتخاب ایستگاه هیدرومتری


ب- نتایج خوشه‌بندی و تحلیل آماری داده‌ها: با استفاده از الگوریتم خوشه‌بندی SOM و شاخص

نام ایستگاه	کد ایستگاه	نام رودخانه	نام استان	سال تاسیس	درجه ایستگاه	کیفیت
رازین	41-059	مزلقان	markazi	1349	1	خوب
رامسر-مفارود	16-051	مفارود	mazandaran	1348	2	خوب
رامیان	12-021	قره چای	golestan	1344	1	
رامین	17-733	رامین	zanjan	1381	1	متوسط
راه رودبار	17-043	سفیدرود	gilan	1328	1	خوب

شکل ۶- جدول اطلاعات توصیفی ایستگاه‌های هیدرومتری



شکل ۷- نوار ابزار تخصصی شبیه‌سازی رسوب معلق



شکل ۸- تعیین تعداد بهینه خوشه‌ها با استفاده از خوشه‌بندی SOM و شاخص دیویس-بولدین در ایستگاه رازین

جدول ۲- پارامترهای آماری مجموعه داده‌های آموزش، اعتبارسنجی متقاطع و آزمون ایستگاه هیدرومتری رازین

پارامترهای آماری						متغیرهای مدل و مجموعه داده‌ها
درصد ضریب تغییرات	چولگی	کمینه	بیشینه	انحراف معیار	میانگین	
دبی لحظه‌ای ( $Q_w$ ) ( $sm^{-3}$ )						
۱۱۲/۴۴	۲/۱۱	۰/۰۱	۳۳/۴	۵/۶	۴/۹۸	مجموعه آموزش
۱۲۱/۷۶	۳/۰۷	۰/۰۲	۳۸/۸۸	۶/۱۳	۵/۰۳	مجموعه اعتبارسنجی متقاطع
۱۰۵/۷۲	۱/۳۸	۰/۰۱	۲۱/۳۶	۵/۰۸	۴/۸	مجموعه آزمون
دبی رسوب معلق ( $Q_s$ ) ( $tonday^{-1}$ )						
۲۷۲/۴۴	۵/۰۱	۰/۰۲	۶۱۴۰۲/۶۹	۶۷۰۱/۶۶	۲۴۵۹/۸۸	مجموعه آموزش
۲۲۸/۹	۳/۱۹	۰/۰	۲۸۲۰۴/۱۱	۵۵۷۸/۸۵	۲۴۳۷/۳۳	مجموعه اعتبارسنجی متقاطع
۲۶۲/۱۶	۳/۸۵	۰/۰۱	۳۶۹۷۱/۵۴	۶۷۱۰/۳۳	۲۵۵۹/۶	مجموعه آزمون

جدول ۳- نتایج آزمون ناپارامتری دو نمونه‌ای KS بر روی داده‌های سه مجموعه آموزش، اعتبارسنجی متقاطع و آزمون در ایستگاه

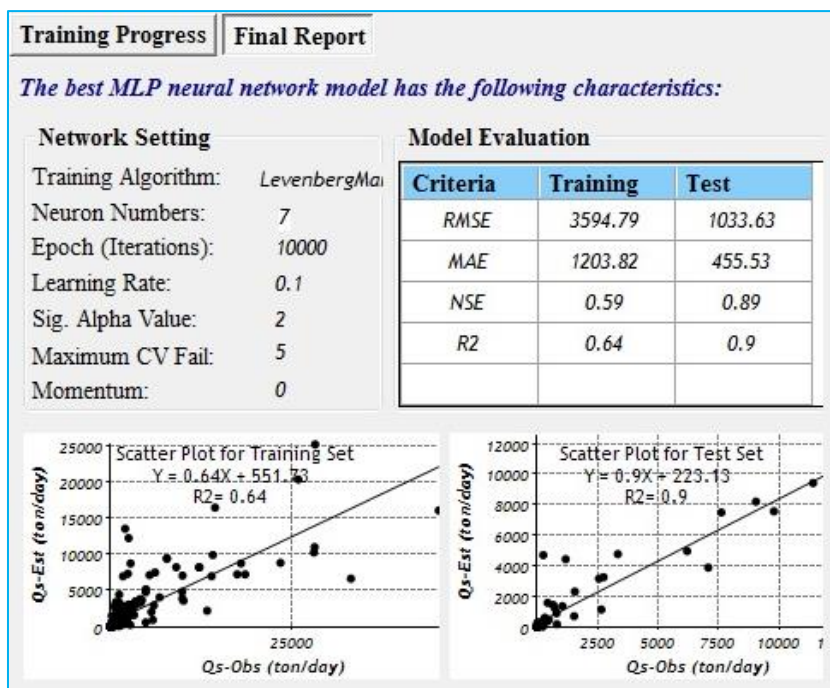
هیدرومتری رازین			
متغیر	مجموعه‌های مورد مقایسه	P-value	آماره $D_c$ یا $k$ (محاسباتی)
دبی لحظه‌ای ( $Q_w$ ) ( $sm^{-3}$ )	آموزش-اعتبارسنجی متقاطع	۰/۸۴	۰/۰۸۳**
دبی لحظه‌ای ( $Q_w$ ) ( $sm^{-3}$ )	آموزش-آزمون	۰/۹۲	۰/۰۷۴**
دبی لحظه‌ای ( $Q_w$ ) ( $sm^{-3}$ )	اعتبارسنجی متقاطع-آزمون	۰/۹۵	۰/۰۸۹**
دبی رسوب معلق ( $Q_s$ ) ( $tonday^{-1}$ )	آموزش-اعتبارسنجی متقاطع	۰/۸۶	۰/۰۸**
دبی رسوب معلق ( $Q_s$ ) ( $tonday^{-1}$ )	آموزش-آزمون	۰/۸۵	۰/۰۸۲**
دبی رسوب معلق ( $Q_s$ ) ( $tonday^{-1}$ )	اعتبارسنجی متقاطع-آزمون	۰/۹۹	۰/۰۷**

\*\* معنی‌داری در سطح خطای یک درصد ( $\alpha = 0.1$ ) با اطمینان ۹۹ درصد

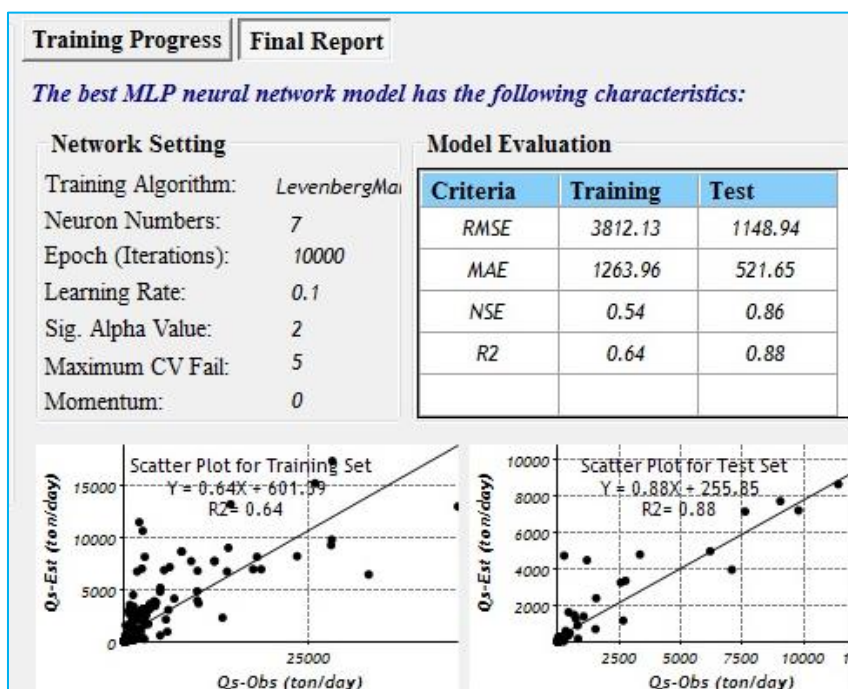
بهترین مدل شبکه عصبی پس از بارها آموزش و زمانی که از توابع فعال‌سازی<sup>۱</sup> لوگ سیگموئید (ANN-Sig) و تانژانت هایپربولیک (ANN-Tan) در ساخت مدل‌های شبکه عصبی استفاده شده است را نشان می‌دهند.

ج- نتایج شبیه‌سازی رسوب معلق: در شکل‌های ۹ و ۱۰ و همچنین جدول ۴، نتایج شبیه‌سازی رسوب معلق ایستگاه رازین که به‌وسیله سامانه مورد ارزیابی و مقایسه قرار گرفته‌اند، نمایش داده شده است. شکل‌های ۹ و ۱۰، گزارش عملکرد سامانه در تولید

<sup>1</sup> Activation Function



شکل ۹- گزارش سامانه از پارامترهای بهترین مدل شبکه عصبی برآوردگر رسوب معلق ایستگاه رازین (با تابع فعال‌سازی لوگ سیگموئید) به همراه نتایج معیارهای ارزیابی و صحت‌سنجی مجموعه داده‌های آموزش و ارزیابی



شکل ۱۰- گزارش سامانه از پارامترهای بهترین مدل شبکه عصبی برآوردگر رسوب معلق ایستگاه رازین (با تابع فعال‌سازی تانژانت هایپربولیک) به همراه نتایج معیارهای ارزیابی و صحت‌سنجی مجموعه داده‌های آموزش و ارزیابی

جدول ۴- ساختار شبکه و نتایج ارزیابی مدل‌های شبکه عصبی در برآورد بار رسوب معلق ایستگاه هیدرومتری رازین با داده‌های آزمون

شاخص‌های ارزیابی کارایی مدل					نام مدل
R <sup>2</sup>	NSE	RMSE (t/day <sup>-1</sup> )	MAE (t/day <sup>-1</sup> )	ساختار شبکه	
۰/۹	۰/۸۹	۱۰۳۳/۶۳	۴۵۵/۵۳	۱:۷:۱	ANN-Sig
۰/۸۸	۰/۸۶	۱۱۴۸/۹۴	۵۲۱/۶۵	۱:۷:۱	ANN-Tan

با توجه به آن که در تولید این سامانه از منابع آزاد و رایگان جهانی (Open Source) استفاده شده است، لذا، برای استفاده و توسعه نیازمند مجوز خارجی نیست. این قابلیت، یکی از ویژگی‌های مهم این سامانه بوده، که امکان تجاری‌سازی آن در سطح کشور و یا در سطح بین‌المللی را فراهم می‌کند. نتایج گرفته شده از این پژوهش نشان داد که عملکرد مدل‌های هوشمند به کار رفته در سامانه پیشنهادی در برآورد و شبیه‌سازی رسوب معلق ایستگاه هیدرومتری رازین با نتایج کارهای انجام‌شده در سطح بین‌المللی نظیر Melesse و همکاران (۲۰۱۱)، Khan و همکاران (۲۰۱۸) و Malik و همکاران (۲۰۱۷) مطابقت می‌کند. در خاتمه، این سامانه مکانی هوشمند که در مدت چهار سال و با هدف تسهیل در فرایندهای پیچیده مدل‌سازی رسوب معلق رودخانه‌ها طراحی و ساخته شده است می‌تواند، به‌عنوان یک زیرساخت ملی، در شبیه‌سازی و مدیریت رسوب معلق کلیه ایستگاه‌های هیدرومتری کشور مورد استفاده سازمان‌های ذی‌ربط قرار گیرد.

### سپاس‌گزاری

این پژوهش در قالب پروژه تحقیقاتی با کد ۹۷۰۲۵۷-۱۲-۲۹-۲۹-۰۲ و با استفاده از اعتبارات مالی پژوهشکده حفاظت خاک و آبخیزداری به انجام رسیده است و نویسندگان بدین‌وسیله از حمایت‌های مادی و معنوی این پژوهشکده صمیمانه تشکر و قدردانی می‌کنند.

همان‌طور که از نتایج ارزیابی مدل‌ها در جدول ۴ استنباط می‌شود، مدل شبکه عصبی با تابع فعال‌سازی لوگ سیگموئید عملکرد نسبتاً بهتری در مقایسه با مدل شبکه عصبی با تابع فعال‌سازی تانژانت هایپربولیک داشته است. در مجموع، پژوهش حاضر با استفاده از فناوری‌های نوین و به‌کارگیری روش‌های داده‌کاوی و با هدف ارائه یک زیرساخت نرم‌افزاری در مقیاس ملی به منظور ذخیره‌سازی و ایجاد وحدت رویه در انجام مراحل مختلف شبیه‌سازی رسوب معلق ایستگاه‌های هیدرومتری کشور انجام شده است. بدین‌منظور با استفاده از کتابخانه‌های متن‌باز سامانه‌های اطلاعات مکانی (GIS) و زبان برنامه‌نویسی NET Framework Visual C#، یک سامانه مکانی ویژه و تخصصی، طراحی و کدنویسی شده است که در آن، داده‌های مکانی و سری‌های زمانی ایستگاه‌های هیدرومتری رودخانه‌های کشور به سهولت قابل دسترسی بوده، که می‌تواند در شبیه‌سازی رسوب معلق رودخانه‌ها، مورد استفاده قرار گیرد. در این سامانه، به‌منظور تعامل کاربر با داده‌ها (مشتمل بر لایه‌های مکانی و اطلاعات سری‌های زمانی)، امکانات گرافیکی لازم طراحی و کدنویسی شده است. همچنین، به‌منظور شبیه‌سازی هوشمند رسوب معلق، از شبکه‌های عصبی مصنوعی SOM و MLP به‌ترتیب به‌منظور خوشه‌بندی داده‌ها و شبیه‌سازی رسوب معلق رودخانه‌ها استفاده شده است. تجزیه و تحلیل آماری داده‌ها، ترسیم نمودارها و تحلیل خطا از دیگر امکانات تعبیه‌شده در سامانه است.

### منابع مورد استفاده

1. Banejad, H., K.W. Chau and A.M. Melesse. A comparison of various artificial intelligence approaches performance for estimating suspended sediment load of river systems, a case study in United States. *Environmental Monitoring and Assessment*, 187(4): 189-204.
2. Bowden, G.J., H.R. Maier and G.C. Dandy. 2002. Optimal division of data for neural network models in water resources applications. *Water Resources Research*, 38(2): 2-11.
3. Buyukyildiz, M. and S.Y. Kumcu. 2017. An estimation of the suspended sediment load using adaptive network based fuzzy inference system, support vector machine and artificial neural network models. *Water Resources Management*, 31(4): 1343-1359.
4. Chen, X.Y. and K.W. Chau. 2016. A hybrid double feedforward neural network for suspended sediment load estimation. *Water Resources Management*, 30: 2179-2194.
5. Demirci, M. and A. Baltaci. 2012. Prediction of suspended sediment in river using fuzzy logic and multilinear regression approaches. *Neural Computing and Applications*, 23(1): 145-151.
6. Hornik, K., M. Stinchcombe and H. White. 1989. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5): 359-366.
7. Joshi, R., K. Kumar and V.P.S. Adhikari. 2016. Modelling suspended sediment concentration using artificial neural networks for Gangotri glacier. *Hydrology Process*, 30(9): 1354-1366.

8. Kakaei Lafdani, E., A. Moghaddamnia and A. Ahmadi. 2013. Daily suspended sediment load prediction using artificial neural networks and support vector machines. *Journal of Hydrology*, 478: 50-62.
9. Khan, M.Y.A., F. Tian, F. Hasan and G.J. Chakrapani. 2019. Artificial neural network simulation for prediction of suspended sediment concentration in the River Ramganga, Ganges Basin, India. *International Journal of Sediment Research*, 34(2): 95-107.
10. Kisi, O. and C. Ozkan. 2017. A new approach for modeling sediment-discharge relationship: local weighted linear regression. *Water Resources Management*, 30(2): 1-23.
11. Kisi, O. and O. Shiri. 2012. River suspended sediment estimation by climatic variables implication: comparative study among soft computing technique. *Computers and Geosciences*, 43: 73-82.
12. Kohonen, T. 1998. The self-organizing map. *Neurocomputing*, 21(1): 1-6.
13. Li, X., M.H. Nour, D.W. Smith and A.A. Prepas. 2010. Neural networks modeling of nitrogen export: model development and application to unmonitored boreal forest watersheds. *Environmental Technology*, 31(5): 495-510.
14. Malik, A., A. Kumar and J. Piri. 2017. Daily suspended sediment concentration simulation using hydrological data of Pranhita River Basin, India. *Computers and Electronics in Agriculture*, 138: 20-28.
15. Mansourfar, K. 2009. Advanced statistical methods using applied software. University of Tehran Press, 459 pages (in Persian).
16. May, R.J., H.R. Maier and G.C. Dandy. 2010. Data splitting for artificial neural networks using SOM-based stratified sampling. *Neural Networks*, 23: 283-294.
17. Melesse, A.M., S. Ahmad, M.E. McClain, X. Wang and Y.H. Lim. 2011. Suspended sediment load prediction of river systems: an artificial neural network approach. *Agricultural Water Management*, 98(5): 855-866.
18. Mustafa, M.R., R.B. Rezaur, S. Saiedi and M.H. Isa. 2012. River suspended sediment prediction using various multilayer perceptron neural network training algorithms, a case study in Malaysia. *Water Resources Management*, 26(7): 1879-1897.
19. Nour, M.H., D.W. Smith, M. Gamal El-Din and E.E. Prepas. 2006. Neural networks modelling of streamflow, phosphorus, and suspended solids: application to the Canadian Boreal Forest. *Water Science and Technology*, 53(10): 91-99.
20. Olyaie, E., H. Banejad, K.W. Chau and A.M. Melesse. 2015. A comparison of various artificial intelligence approaches performance for estimating suspended sediment load of river systems, a case study in United States. *Environmental Monitoring and Assessment*, 187(4): 189-202.
21. Tabatabaei, M., K. Solaimani, M.H. Roshan and A. Kavian. 2015. Estimation of daily suspended sediment concentration using artificial neural networks and data clustering by self-organizing. *Journal of Watershed Management Research*, 5(10): 98-116 (in Persian).
22. Tabatabaei, M., A. Salehpour Jam and S.A. Hosseini. 2019a. Presenting a new approach to increase the efficiency of the sediment rating curve model in estimating suspended sediment load in watersheds, case study: Mahabad-Chai River, Lake Urmia Basin, West Azarbayejan Province, Iran. *Journal of Watershed Management Research*, 10(19): 181-193 (in Persian).
23. Tabatabaei, M., A. Salehpour Jam and S.A. Hosseini. 2019b. Suspended sediment load prediction using non-dominated sorting genetic algorithm II. *International Soil and Water Conservation Research*, 7(20): 119-129.
24. Tabatabaei, M., A. Salehpour Jam and J. Mossafaei. 2020. Improvement of the efficiency of artificial neural network model in suspended sediment simulation using particle swarm optimization algorithm. DOI: 10.22092/ijwmse.2019.125871.1638 (in Persian).
25. Tayfur, G. 2012. Soft computing in water resources engineering: artificial neural networks, fuzzy logic and genetic algorithms. WIT Press, Dorset, 267 pages.
26. Tfwala, S.S. and Y.M. Wang. 2016. Estimating sediment discharge using sediment rating curves and artificial neural networks in the Shiwen River, Taiwan. *Water*, 8(53): 1-15.
27. Ulke, A., G. Tayfur and S. Ozkul. 2009. Predicting suspended sediment loads and missing data for Gediz River, Turkey. *Journal of Hydrologic Engineering*, 14(9): 954-965.