

پیش بینی چند ایستگاهه نیترا با بهره‌گیری از ابزار هوش مصنوعی و محاسبات نرم

الناز شرقی^۱، وحید نورانی^{۲*} و غلامرضا عندلیب^۳

^۱ استادیار دانشکده مهندسی عمران، دانشگاه تبریز

^۲ استاد دانشکده مهندسی عمران، دانشگاه تبریز

^۳ دانشجوی دکتری مهندسی عمران - آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه تبریز

(دریافت: ۹۵/۱۲/۱، پذیرش: ۹۶/۶/۴، نشر آنلاین: ۹۶/۶/۵)

چکیده

در این مقاله مدل‌سازی چند ایستگاهه رواناب- نیترا در حوضه آبریز Little River Watershed (LRW)، با استفاده از تبدیل موجک و نقشه‌های خود سازمانده و مدل‌های هوش مصنوعی انجام گردید. به طوری که سری‌های زمانی رواناب- نیترا توسط تبدیل موجک تجزیه گشته و سپس زیرسری‌های تجزیه شده توسط نقشه‌های خود سازمانده خوشه‌بندی گردید. در ادامه، معیار استخراج ویژگی (اطلاعات مشترک) برای انتخاب نماینده از هر خوشه جهت ورود به مدل‌های هوش مصنوعی شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای پیش‌بینی نیترا خروجی حوضه آبریز LRW به کار گرفته شد. مدل‌سازی چند ایستگاهه نیترا بر اساس خاصیت فصلی بودن انجام شده و با مدل‌سازی چند ایستگاهه بر اساس خاصیت مارکف مقایسه گردید. نتایج نشان داد که مدل‌های هوش مصنوعی ترکیب شده با تبدیل موجک، نقشه‌های خود سازمانده و اطلاعات مشترک توانایی پیش‌بینی نیترا چند ایستگاهه را نسبت به مدل‌های هوش مصنوعی که از خاصیت مارکف بهره می‌برند تا حد قابل قبولی بهبود می‌بخشد. به طور کلی، استفاده از خاصیت فصلی بودن پدیده‌ها به همراه کاهش ابعاد ورودی‌ها، می‌تواند به مدل‌های هوش مصنوعی در جهت استفاده از اطلاعات خالص داده‌های مشاهداتی کمک کند.

کلیدواژه‌ها: اطلاعات مشترک، تبدیل موجک، نقشه‌های خودسازمانده، هوش مصنوعی، حوضه آبریز LRW.

۱- مقدمه

Sarkar و همکاران، (۲۰۱۵). در این راستا، شبکه عصبی مصنوعی ANN^۱ و ماشین بردار پشتیبان SVM^۲ به عنوان روش‌های جعبه سیاه توانایی‌های خود را در مدل‌سازی و پیش‌بینی روند غیر خطی کیفیت آب به ویژه نیترا نشان داده‌اند (Dixon، ۲۰۰۹؛ Arabgol و همکاران، ۲۰۱۶).

با توجه به طبیعت غیر خطی و استوکستیک پدیده نیترا، کاربرد مدل‌هایی نظیر ANN و SVM در این زمینه کاملاً قابل توجیه است. علی‌رغم ماهیت انعطاف‌پذیر مدل‌های ANN و SVM، این مدل‌ها نقایصی را در مواجهه با سیگنال‌های هیدرولوژیکی، که عموماً نالیستا بوده و محدوده وسیعی از مقیاس (از چند دقیقه تا چند دهه) را شامل می‌شود، از خود نشان می‌دهند. از این رو، در چنین شرایطی پیش‌پردازش زمانی و یا مکانی داده‌ها قبل از اعمال آن‌ها به مدل‌های ANN و SVM برای غلبه بر این مشکل ضروری به نظر می‌رسد. تبدیل موجک زیرسری‌های مفیدی از سری اصلی به دست می‌دهد که این زیرسری‌ها با استخراج اطلاعات سودمند

انتشار آلودگی نیترا در حوضه‌های آبریز به دلیل چرخه پیچیده مربوط به نیتروژن و آب می‌باشد. نیترا از منابع مختلف از جمله تصفیه خانه‌های فاضلاب، رواناب مزارع کود داده شده، عدم وجود مخازن سپتیک، رواناب مناطق ذخیره‌سازی کود حیوانی و فاضلاب صنعتی حاصل می‌شود. ورود نیترا به آب‌های سطحی و زیرزمینی می‌تواند بهره‌وری مزارع را کاهش دهد، به محیط زیست آسیب رساند و کیفیت آب آشامیدنی را تحت تأثیر قرار دهد. عدم قطعیت بالا و درک فیزیکی محدود از پدیده‌های کیفیت آب مانند نیترا، الزام به استفاده از روش‌های جعبه سیاه در این نوع پدیده‌ها را آشکار می‌سازد. از این رو، تاکنون روش‌های جعبه سیاه متعددی از جمله مدل‌های هوش مصنوعی برای شبیه‌سازی فرآیندهای کیفیت آب مورد استفاده قرار گرفته است (علیائی و همکاران، ۱۳۸۹؛ ریاحی مدوار و همکاران، ۱۳۸۷؛ میرزائی و همکاران، ۱۳۹۵) و (Ravansalar و همکاران، ۲۰۱۵؛

2. Support vector machine

1. Artificial neural network

* نویسنده مسئول؛ شماره تماس: ۰۴۱-۳۳۳۹۲۴۰۹

آدرس ایمیل: elnaz_sharghi@yahoo.com (ا. شرقی)، vnourani@yahoo.com (و. نورانی)، gholamreza.andalib@gmail.com (غ. عندلیب).

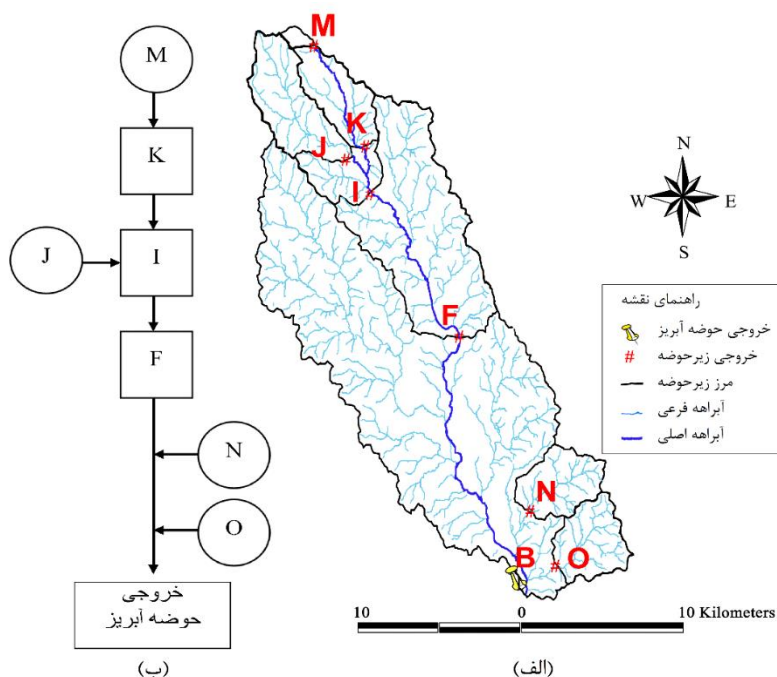
از مقادیر نیترات در قسمت‌های مختلف حوضه را فراهم می‌سازد. برای این منظور در این مقاله برای مدل‌سازی چند ایستگاه نیترات از دو سناریو با دو دیدگاه متفاوت استفاده شده است تا مطلوب‌ترین آن‌ها برای استفاده در کارهای آتی در مسائل هیدرولوژیکی معرفی گردد. در سناریوی اول خاصیت مارکف پدیده دبی- نیترات مورد توجه قرار گرفته است به طوری که از سوابق دبی و نیترات در روزهای گذشته برای پیش‌بینی نیترات خروجی زیرحوضه مورد نظر استفاده شده است. از طرف دیگر، برای تعیین ورودی‌های مدل‌های هوش مصنوعی ANN و SVM از معیار MI به جای معیار خطی ضریب همبستگی استفاده شده است تا از سعی و خطا برای انتخاب ورودی مدل‌ها جلوگیری شود. در سناریوی دوم خاصیت فصلی بودن پدیده نیترات مد نظر قرار گرفته شده است، به طوری که سری‌های زمانی دبی و نیترات در سطح مناسب جهت استخراج زمان و طیف تجزیه شدند. سپس زیرسری‌های زمانی همگن توسط SOM، خوشه‌بندی شده و از هر خوشه یک نماینده جهت ورود به مدل هوش مصنوعی توسط MI انتخاب گردید تا بار نیترات محل‌های مورد نظر در حوضه آبریز LRW پیش‌بینی شود.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

حوضه آبریز LRW واقع در ایالت جورجیا بوده که با وسعتی معادل ۳۳۴ کیلومتر مربع در جنوب ایالات متحده آمریکا قرار دارد. این منطقه از آمریکا به دلیل رشد روز افزون جمعیت نیازمند افزایش زمین‌های زراعی گردیده است که این امر موجب افزایش میزان نیترات آب‌های سطحی به دلیل استفاده از کودهای شیمیایی در مزارع کشاورزی شده است. همچنین مزارع کشاورزی در جنوب حوضه آبریز LRW دارای مساحت بیشتری نسبت به شمال این حوضه می‌باشد. با توجه به جدول (۱)، میزان نیترات نسبت به مساحت زیرحوضه‌ها در زیرحوضه‌های جنوبی بیشتر از زیرحوضه‌های شمالی می‌باشد. مشخصات زیرحوضه‌ها نیز با استفاده از ابزار GIS استخراج شده است. داده‌های مورد استفاده از ژانویه سال ۱۹۹۰ تا دسامبر سال ۲۰۰۳ میلادی می‌باشد که از سایت <ftp://www.tiftonars.org> اقتباس شده‌اند (شکل ۱- الف)، جدول (۱). در این مقاله ۷۵ درصد داده‌ها (از ژانویه ۱۹۹۰ تا ژوئن ۲۰۰۰) برای آموزش و ۲۵ درصد داده‌ها (از ژانویه ۲۰۰۰ تا دسامبر ۲۰۰۳) برای آزمایش مورد استفاده قرار گرفته شد.

در مقیاس‌های مختلف، توانایی مدل را در پیش‌بینی کمیت مورد نظر بالا می‌برند. تبدیل موجک با تجزیه سری‌های زمانی، به کمک ضرایب جزئی، به تفسیر ساختار سری و دریافت اطلاعات مفید در مورد تاریخچه آن کمک می‌کند (Nourani و همکاران، ۲۰۱۴؛ Nourani و Andalib، ۲۰۱۵). در این مقاله، مدل‌های ترکیبی موجک- شبکه عصبی WANN^۱ و موجک- ماشین بردار پشتیبان WSVM^۲ برای مدل‌سازی چند ایستگاه نیترات استفاده شده‌اند. با این حال در هر گونه اطلاعات استخراج شده در مدل‌سازی ممکن است برخی از ورودی‌ها آلوده به نوفه باشند و یا با متغیرهای خروجی رابطه معنی‌داری نداشته باشند. بنابر این، تعیین ورودی‌های غالب و حاوی اطلاعات مفید یکی از چالش‌های ضروری در روند توسعه مدل‌های WANN و WSVM است. بدین منظور، برای تعیین ورودی‌های مدل‌های WANN و WSVM، از نقشه‌های خود سازمانده SOM^۳ و مفاهیم اطلاعات مشترک MI^۴ استفاده شده است. SOM به عنوان یک ابزار خوشه‌بندی قوی یک نوع سیستم شبکه عصبی بدون نظارت است و به تازگی در زمینه‌های مختلف مهندسی آب به طور گسترده استفاده شده است (Nourani و Parhizkar، ۲۰۱۳؛ Chang و همکاران، ۲۰۱۶). از سوی دیگر، معیار MI به عنوان یک معیار غیر خطی برای داده‌ها و اطلاعات می‌تواند یک ابزار ارزشمند در انتخاب ورودی مناسب زیرسری‌های زمانی تجزیه شده توسط موجک باشد (Nourani و همکاران، ۲۰۱۵). در مجموع، بر اساس اهمیت ورودی‌های مدل برای به دست آوردن الگوی کلی از فرآیند دینامیکی نیترات، مشارکت داده‌های مؤثر حوضه آبریز از اهمیت بسیاری برخوردار است. بنابر این، شناسایی و استفاده زمانی- مکانی از اطلاعات زیرحوضه‌ها به عنوان یک تجزیه و تحلیل چند ایستگاه می‌تواند پیش‌بینی انتشار نیترات در حوضه آبریز را بهبود بخشد. لازم به ذکر است که مدل‌های چند ایستگاه در برخی دیگر از زمینه‌های هیدرولوژی مورد استفاده واقع شده‌اند (Turan و Yurdusev، ۲۰۰۹؛ Nourani و Komasi، ۲۰۱۳). بر اساس آخرین تحقیقات و بررسی‌های انجام شده توسط محققین، تاکنون مدل‌سازی چند ایستگاه پدیده نیترات در حوضه آبریز تاکنون انجام نگرفته است. بر همین اساس، تلاش این مقاله نه تنها مدل‌سازی نیترات خروجی حوضه آبریز بلکه اطلاع یافتن از وقایع درون حوضه آبریز نیز می‌باشد. یعنی پیش‌بینی میزان نیترات در درون حوضه نیز صورت خواهد گرفت. جهت توضیح بیشتر، از زیرحوضه‌های ابتدایی و مولد جهت پیش‌بینی نیترات زیرحوضه‌های میانی و از زیرحوضه‌های میانی جهت پیش‌بینی نیترات خروجی حوضه بهره گرفته خواهد شد که این کار سبب آماده شدن بستر مناسب جهت اطلاع یافتن



جدول ۱- مشخصات آماری حوضه آبریز LRW

میانگین	شیب کانال	(میانگین نیترات	مساحت	زیرحوضه
دبی (متر مکعب بر ثانیه)	%	* (۱۰۰ بر مساحت	(کیلومتر مربع)	
نیترات (تن در روز)		نیترات (تن در روز)		
۳/۲۹	۰/۱۰	۲۳/۴۳	۱۲/۹۴	B
۱/۲۵	۰/۱۴	۱۴/۷۲	۱۲/۸۰	F
۰/۶۱	۰/۲۲	۴/۸۹	۹/۷۸	I
۰/۲۶	۰/۲۵	۲/۲۵	۱۰/۲۳	J
۰/۱۹	۰/۲۹	۱/۲۴	۷/۲۹	K
۰/۰۲	۰/۳۳	۰/۱۴	۵/۳۴	M
۰/۱۵	۰/۳۲	۲/۴۸	۱۵/۵۰	N
۰/۱۷	۰/۳۷	۵/۴۳	۳۳/۹۴	O

با دایره مشخص شده‌اند مولد نیترات و زیرحوضه‌هایی که با مربع مشخص شده‌اند مولد و منتقل کننده نیترات هستند. در مدل‌سازی چند ایستگاه مورد نظر نیترات زیرحوضه I با استفاده از زیرحوضه‌های M، K و J پیش‌بینی شده است. در گام دوم، نیترات زیرحوضه F با استفاده از نیترات زیرحوضه I پیش‌بینی شده است و در آخر نیترات خروجی حوضه LRW در ایستگاه B، با استفاده از زیرحوضه‌های F، O و N محاسبه شده است. بدین ترتیب الگوی پیش‌بینی چند ایستگاه با سه گام مدل‌سازی بمانند مخازن آبخاوری مرتبط تکمیل می‌گردد. ذکر این نکته نیز ضروری است که با استفاده از مدل‌سازی چند ایستگاه می‌توان داده‌های خالی سری‌های زمانی در ایستگاه‌های هیدرومتری آسیب دیده را نیز ترمیم کرد. مدل‌سازی چند ایستگاه با استفاده از سناریوی مارکف و فصلی در بخش‌های زیر شرح داده شده است (شکل ۲).

۲-۲- روش تحقیق

از آنجایی که پدیده نیترات یک پدیده پیچیده و دبی و نیترات دارای رابطه غیر خطی هستند، بدین منظور از مدل‌های هوش مصنوعی غیر خطی نظیر ANN و SVM برای مدل‌سازی چند ایستگاه نیترات استفاده شد.

هدف مدل‌سازی چند ایستگاه نیترات در این مقاله، پیش-بینی نیترات زیرحوضه‌های میانی و خروجی با استفاده از اطلاعات زیرحوضه‌های مرتبط و همچنین اطلاع یافتن از نحوه جریان نیترات در درون حوضه می‌باشد. بنابر این، مدل‌سازی چند ایستگاه به هیدرولوژیست‌ها این امکان را می‌دهد که با اطلاع از نیترات درون حوضه، تصمیم‌گیری‌های به مراتب قطعی‌تر داشته باشند. شکل (۱-ب) مدل‌سازی چند ایستگاه حوضه آبریز LRW را به طور شماتیک تشریح می‌کند به طوری که زیرحوضه‌هایی که

۲-۲-۲- سناریوی دوم

در سناریوی دوم، رویکرد به خاصیت فصلی پدیده دبی- نیترات در حوضه آبریز LRW معطوف بوده است. در این سناریو هدف استفاده از فرکانس‌های غالب سری‌های زمانی زیرحوضه‌ها با توجه به حذف اطلاعات زائد به صورت ذیل بوده است:

برای پیش‌بینی نیترات زیرحوضه I سه گام پشت سر گذاشته شد. در گام اول، سری‌های زمانی نیترات زیرحوضه‌های M، K و J به همراه سری زمانی رواناب زیرحوضه I توسط تبدیل موجک در سطح q جهت رفع نالیستایی و استخراج خاصیت فصلی سری‌های زمانی تجزیه شدند، به طوری که نیترات زیرحوضه I به زیرسری- های زیرحوضه‌های بالادستی مرتبط گردید:

$$\begin{aligned} N_t^I &= f_n(Q_a^I, Q_{d1}^I, \dots, Q_{dq}^I, N_a^M, N_{d1}^M, \dots, N_{dq}^M, \\ &N_a^K, N_{d1}^K, \dots, N_{dq}^K, N_a^J, N_{d1}^J, \dots, N_{dq}^J) \end{aligned} \quad (۴)$$

که Q_a^I و Q_{dq}^I به ترتیب زیرسری تقریب و زیرسری جزء دبی در سطح q در زیرحوضه I هستند. N_a^M و N_{dq}^M نیز زیرسری تقریب و زیرسری جزء نیترات در سطح q در زیرحوضه M می‌باشند. به طور مشابه دیگر زیرسری‌های زمانی نیز مرتبط به زیرحوضه‌های K و J می‌باشند. در گام دوم، به دلیل حجم انبوهی از داده‌ها، ابزار خوشه‌بندی جهت خوشه‌بندی مکانی- زمانی زیرسری‌های همگن به کار گرفته شد و در گام آخر، به مانند سناریوی اول، ابزار MI جهت انتخاب نماینده مناسب از هر خوشه برای ورود به مدل‌های هوش مصنوعی برای پیش‌بینی نیترات زیرحوضه I استفاده گردید. به طور مشابه، برای پیش‌بینی نیترات زیرحوضه‌های F و B از روابط (۵) و (۶) استفاده گردید. ابزارهای مورد نیاز برای دو سناریوی مورد نظر در بخش‌های ذیل توضیح داده شده‌اند.

$$N_t^F = f_n(Q_a^F, Q_{d1}^F, \dots, Q_{dq}^F, N_a^I, N_{d1}^I, \dots, N_{dq}^I) \quad (۵)$$

$$\begin{aligned} N_t^B &= f_n(Q_a^B, Q_{d1}^B, \dots, Q_{dq}^B, N_a^F, N_{d1}^F, \dots, N_{dq}^F, \\ &N_a^N, N_{d1}^N, \dots, N_{dq}^N, N_a^O, N_{d1}^O, \dots, N_{dq}^O) \end{aligned} \quad (۶)$$

۲-۳- تبدیل موجک و آنتروپی شانون

در اکثر کاربردهای عملی فرآیندهای هیدرولوژی سری زمانی دارای حالت گسسته می‌باشد بنابراین حالت موجک گسسته به صورت رابطه (۷) بیان می‌شود (Mallat, ۱۹۹۸):

$$g_{m,n}(t) = \frac{1}{\sqrt{a_0^m}} g^* \left(\frac{t - nb_0 a_0^m}{a_0^m} \right) \quad (۷)$$

در رابطه فوق m و n اعداد صحیحی هستند که به ترتیب میزان مقیاس و انتقال موجک را کنترل می‌نمایند. همچنین a_0 گام مقیاس کوچک ویژه برای پارامتر انتقال ($1 < a_0$) و b_0 پارامتر انتقال موقعیت ($0 < b_0$) می‌باشند. معمولی‌ترین حالت برای



شکل ۲- فلوچارت سناریوی یک و سناریوی دو

۲-۲-۱- سناریوی اول

در سناریوی اول، خاصیت مارکف پدیده دبی- نیترات اساس مدل‌سازی چند ایستگاه قرار گرفته است، به طوری که پیش‌بینی نیترات زیرحوضه‌های I، F و B به صورت زیر صورت گرفته است. نیترات زیرحوضه I با استفاده از نیترات زیرحوضه‌های M، K و J و همین طور دبی زیرحوضه I پیش‌بینی شده است.

$$\begin{aligned} N_t^I &= f_n(Q_t^I, N_t^M, \dots, N_{t-p_M}^M, N_t^K, \dots, N_{t-p_K}^K, \\ &N_t^J, \dots, N_{t-p_J}^J) \end{aligned} \quad (۱)$$

که نیترات (N) زیرحوضه F در زمان t تابعی (fn) از دبی (Q) زیرحوضه I در زمان t و نیترات زیرحوضه‌های M، K و J در زمان t تا زمان چند روز گذشته P_J, P_K, P_M می‌باشد. البته باید اشاره گردد که دبی زیرحوضه‌های بالادستی تأثیر خود را در میزان نیترات آن‌ها در روزهای بعد گذاشته است.

اما انتخاب داده‌های مناسب از میان انبوه داده‌ها، مهم‌ترین گام در مدل‌سازی چند ایستگاهه تلقی می‌گردد. از این رو، معیار نظارت شده MI جهت انتخاب ورودی مدل‌ها به جای روش سعی و خطا مورد استفاده قرار گرفت به طوری که از میان داده‌های بالقوه، آن دسته از داده‌هایی که دارای بیشترین مقدار MI با خروجی مدل می‌باشند به عنوان ورودی مدل انتخاب گردیدند. کارایی بالای ضریب MI نسبت به معیار خطی ضریب همبستگی در تحقیقات اخیر گزارش شده است (Nourani و همکاران، ۲۰۱۵). به همین ترتیب، نیترات زیرحوضه F با استفاده از رابطه (۲) و نیترات خروجی حوضه (B) با استفاده از نیترات زیرحوضه- های F، O و N توسط رابطه (۳) پیش‌بینی شدند.

$$N_t^F = f_n(Q_t^F, N_t^I, \dots, N_{t-p_I}^I) \quad (۲)$$

$$\begin{aligned} N_t^B &= f_n(Q_t^B, N_t^F, \dots, N_{t-p_F}^F, N_t^N, \dots, N_{t-p_N}^N, \\ &N_t^O, \dots, N_{t-p_O}^O) \end{aligned} \quad (۳)$$

۲-۵- شبکه عصبی مصنوعی

شبکه‌های عصبی توانایی شناخت یک سیستم غیر خطی دینامیکی بدون داشتن هیچ گونه پیش فرض در فرآیند مدل سازی را دارا می‌باشند. معماری شبکه‌های عصبی در اکثر مسائل مهندسی پیش‌بینی کننده از یک سیستم و ساختار سه لایه‌ای تشکیل یافته که شامل لایه ورودی، لایه مخفی و لایه خروجی می‌باشد. در این ساختار لایه ورودی نخست به پردازش داده‌های ورودی برای انتقال به لایه مخفی می‌پردازد، سپس لایه مخفی قبل از ارسال اطلاعات به لایه خروجی با استفاده از توابع انتقال همانند تانژانت هایپربولیک یا تابع منطقی به محاسبه ضرایب وزن مناسب می‌پردازد. ساختار سه لایه FFNNs بر پایه ترکیب خطی از متغیرهای ورودی است که با یک تابع محرک غیر خطی تبدیل می‌یابد. این ساختار از شبکه به این دلیل شبکه پیشرو نامیده می‌شود که چگونگی ارتباط میان نرون‌ها به گونه‌ای است که از لایه ورودی به لایه مخفی و از این لایه به لایه خروجی اتصال می‌یابند و درون یک لایه نیز نرون‌ها به یکدیگر ارتباط پیدا نمی‌کنند (Kim و Valdes, ۲۰۰۳).

۲-۶- ماشین بردار پشتیبان

ماشین‌های بردار پشتیبان SVM در سال ۱۹۹۵ توسط واپنیک و کرتز معرفی شدند. شبکه‌های عصبی SVM برخلاف سایر انواع شبکه‌های عصبی (MLP, RBF, ANFIS) به جای این که خطای مدل سازی یا طبقه بندی را کمینه کنند، ریسک عملیاتی را به عنوان تابع هدف در نظر می‌گیرند و مقدار بهینه آن را محاسبه می‌کنند. اگر فرض بر طبقه بندی یک مجموعه داده به دو گروه باشد، در واقع کاری که شبکه عصبی SVM انجام می‌دهد، ریسک عدم طبقه بندی صحیح را به صورت سری کمیت‌های عددی بیان کرده، سپس مقدار کمینه آن را محاسبه می‌کند؛ اما یک شبکه عصبی MLP هر موقع تفکیک درست باشد یا مقدار خطای تفکیک کمینه باشد آن را به عنوان راه حل ارائه می‌کند. ماشین بردار پشتیبان الگوریتمی است که نوع خاصی از مدل‌های خطی را می‌یابد که حداکثر حاشیه ابر صفحه را حاصل می‌کنند. حداکثر کردن حاشیه ابر صفحه منجر به حداکثر شدن تفکیک بین دسته ها می‌شود. به نزدیک ترین نقاط آموزشی به حداکثر حاشیه ابر صفحه، بردارهای پشتیبان اطلاق می‌گردد و تنها از این بردارها برای مشخص کردن مرز بین دسته‌ها استفاده می‌شود. قواعد تصمیم‌گیری که تعریف می‌شود و توسط یک صفحه بهینه که طبقات تصمیم‌گیری باینری را تفکیک می‌کند، به صورت رابطه (۱۱) است (Suykens و Vandewalle, ۱۹۹۹).

پارامترهای رابطه (۷) مقادیر $a_0 = 2$ و $b_0 = 1$ هستند که این مقیاس لگاریتمی با توان دو برای انتقال و مقیاس تحت عنوان آرایش شبکه دوتایی نامیده می‌شود.

Shannon (۱۹۴۸)، آنتروپی (محتوای اطلاعاتی) را به صورت ریاضی و با استفاده از توزیع احتمالاتی داده‌ها فرمول بندی کرده و آن را به عنوان معیار سنجش بی‌نظمی، آشفتگی، عدم قطعیت و اطلاعات معرفی کرد. اگر X متغیر تصادفی گسسته با مقادیر x_1, x_2, \dots, x_N و احتمالات متناظر p_1, p_2, \dots, p_N باشد، آنتروپی شانون از رابطه (۸) محاسبه می‌شود:

$$H(X) = H(P) = -\sum_{i=1}^N p(x_i) \log[p(x_i)] \quad (۸)$$

که در این رابطه $H(X)$ آنتروپی X است که تابع آنتروپی شانون نیز نامیده می‌شود. MI نیز به صورت زیر تعریف می‌شود (Yang و همکاران, ۲۰۰۰):

$$MI(X, Y) = H(X) + H(Y) - H(X, Y) \quad (۹)$$

$H(X, Y)$ نیز آنتروپی مشترک می‌باشد:

$$H(A, B) = -\sum_{a \in A} \sum_{b \in B} p_{AB}(a, b) \log p_{AB}(a, b) \quad (۱۰)$$

۲-۴- نقشه خودسازمانده

SOM یک ابزار جدید، مؤثر و نرم‌افزاری برای تجسم و خوشه بندی اطلاعات با ابعاد بزرگ است. این ابزار مجموعه‌ای از داده‌های با بعد بالا را با بر روی یک شبکه منظم کم بعد نگاشت می‌دهد، این ابزار توانایی تبدیل روابط آماری پیچیده و غیر خطی داده‌های با بعد بالا را به روابط ساده هندسی در صفحه نمایش کم بعد داده‌ها دارا است (Kohonen, ۱۹۹۷). برای خوشه بندی SOM در دو مرحله برای کاهش ابعاد فضای ورودی مدل به کار گرفته شده است. در مرحله اول SOM دو بعدی برای به دست آوردن دید کلی نسبت به ساختار سری‌ها و تعیین تعداد تقریبی خوشه‌ها استفاده شده است. سپس در مرحله دوم برای اطمینان از خوشه بندی تعیین شده از یک SOM یک بعدی با اندازه تعیین شده در مرحله اول استفاده شد تا سری‌ها خوشه بندی شوند. در SOM دو مرحله ای، در ابتدا لایه خروجی یا Kohonen ۶ در ۶ در نظر گرفته شد و سپس در مرحله دوم SOM یک بعدی با اندازه ۶ در ۱ برای به دست آوردن بهترین ساختار خوشه بندی به کار گرفته شد.

۳-۱- نتایج سناریوی یک

در مدل‌های داده محور FFNN و LSSVM، انتخاب داده‌های مناسب نقش بسزایی در افزایش کارایی مدل در هر دو بخش آموزش و آزمایش دارد، ضمن این که از بیش برآزش مدل نیز جلوگیری به عمل می‌آید. بدین منظور، معیار MI جهت انتخاب ورودی‌های مناسب و همین‌طور زمان تأخیر بهینه برای پیش‌بینی نیترات زیرحوضه‌ها به کار گرفته شد. جدول (۲) نتایج آنالیز حساسیت با استفاده از معیار MI را برای مدل‌سازی چند ایستگاه نشان می‌دهد. نتایج مدل‌سازی چند ایستگاه برای زیرحوضه‌های داخلی I و F و خروجی حوضه LRW (ایستگاه B) در جدول (۲) ارائه شده است. همان‌طور که قبلاً اشاره شد، برای هر مدل، ورودی‌های غالب (جدول (۲)، ستون چهارم) به وسیله ضریب MI انتخاب گردید. به علاوه به وسیله برآزش FFNN و LSSVM های مختلف برای تمامی زیرحوضه‌های LRW (یک مدل هوش مصنوعی برای هر زیرحوضه به طور مجزا)، بروز رسانی سری‌های زمانی نیترات در آینده امکان‌پذیر خواهد بود. از طرف دیگر، برای درک بیشتر پدیده دینامیکی نیترات و ارزیابی ورودی‌های مدل-های جعبه سیاه چند ایستگاه، منشأ نیترات در حوضه آبریز LRW بررسی شده است. پدیده نیتراته شدن توسط باکتری‌ها از آمونیم شدن گیاهان، کود، زباله و مدفوع حیوانات حاصل می‌گردد. نیترات محلول در آب بوده و می‌تواند توسط جریان آب در حوضه پخش شود. بنابراین، کاربری اراضی رابطه مستقیم با میزان تولید نیترات در زیرحوضه‌ها دارد. با بررسی تصاویر ماهواره‌ای، پوشش حوضه آبریز LRW به پنج قسمت مزارع، چراگاه، آب، جنگل و شهری تقسیم گردید (Bosch و همکاران، ۲۰۰۶).

با توجه به شکل‌های (۱-الف) و (۳)، در ابتدای حوضه آبریز LRW که ارتفاع بالاتری نسبت به خروجی حوضه دارد، میزان پوشش جنگل بیشتر از چراگاه و مزارع بوده که با کاهش ارتفاع میزان پوشش جنگل نیز کاهش یافته و بر میزان چراگاه و مزارع افزوده می‌شود از طرفی، طبق آمار جدول (۱)، میزان نیترات بر مساحت زیرحوضه‌ها، در مناطق مرتفع کمتر و در مناطق پست بیشتر نمود پیدا می‌کند. با نگاه دقیق‌تر، زیرحوضه O با درصد مزارع و چراگاه بالا میزان نیترات نسبت به مساحت بالاتری نسبت به زیرحوضه F به خود اختصاص داده است. در نتیجه، می‌توان استنباط کرد که مناطق پست با درصد پوشش چراگاه و مزارع بالا، منشأ اصلی تولید نیترات در حوضه آبریز LRW هستند و هر چقدر مساحت چراگاه و مزارع بیشتر باشد منجر به تولید نیترات بیشتر خواهد شد. علاوه بر این، انتخاب ورودی مدل‌های چند ایستگاه با استفاده از معیار MI با ژئومورفولوژی حوضه آبریز LRW مطابقت

$$y = \sum_{i=1}^N \gamma e_i K(X, X_i) + b \quad (11)$$

که در آن γ خروجی معادله، e_i ارزش طبقه نمونه آموزشی X_i و نشان دهنده ضرب داخلی و γ ضریب کرنل است. بردارهای $X = (X_1, X_2, \dots, X_n)$ نشان دهنده یک داده ورودی و بردارهای X_i بردارهای پشتیبان هستند. در این تحقیق، از SVM نوع حاشیه نرم با الگوریتم حداقل مربعات LSSVM استفاده شده است. در هسته مدل LSSVM نیز از کرنل RBF با پارامتر σ استفاده گردیده است زیرا این نوع کرنل بالاترین میزان کارایی را در مدل‌های هیدرولوژیکی داشته است (Nourani و Andalib، ۲۰۱۵):

$$K(X, X_i) = \exp\left(-\frac{\|X - X_i\|^2}{2\sigma^2}\right) \quad (12)$$

۳-۲- معیار کارایی مدل

یک مدل مناسب نتایج قابل قبولی از نظر ضریب تبیین DC^2 و جذر میانگین مربعات خطا RMSE² در مراحل آموزش و آزمایش نشان می‌دهد؛ بنابراین برای ارزیابی کارایی مدل، روابط (۱۳) و (۱۴) جهت مقایسه عملکرد مدل‌های مختلف ارائه شده است (Nourani و Andalib، ۲۰۱۵):

$$DC = 1 - \frac{\sum_{i=1}^T (O_{obs_i} - O_{com_i})^2}{\sum_{i=1}^T (O_{obs_i} - \bar{O}_{obs_i})^2} \quad (13)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^T (O_{obs_i} - O_{com_i})^2}{T}} \quad (14)$$

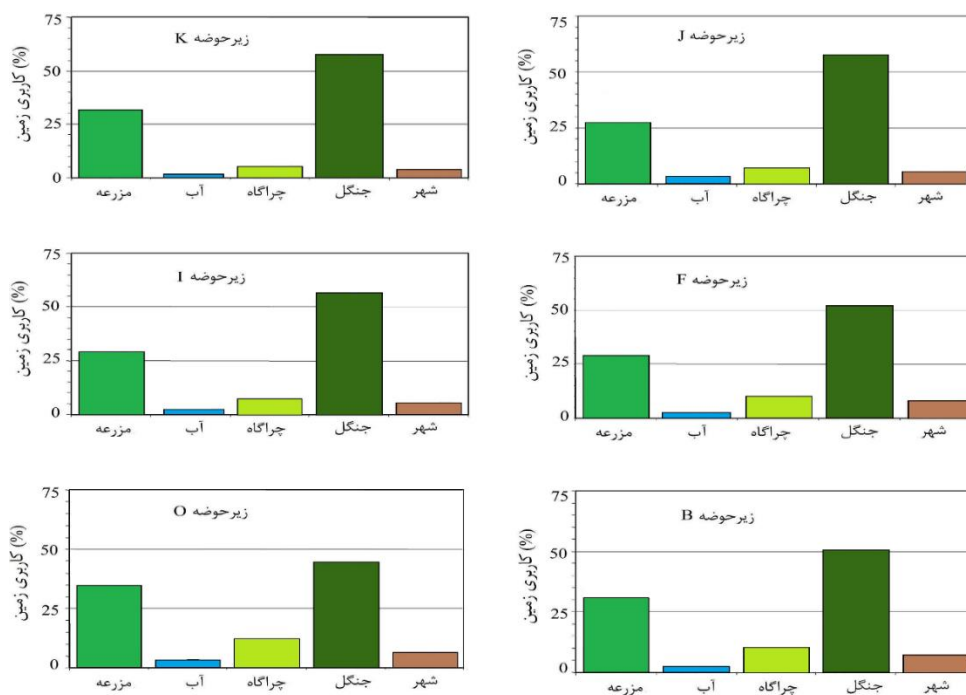
در این روابط T ، O_{obs_i} و O_{com_i} به ترتیب تعداد مشاهدات، داده‌های مشاهداتی، داده‌های محاسباتی و میانگین داده‌های مشاهداتی است. DC معیاری است که برای تعیین دقت تخمین مدل، با مقایسه داده‌های مشاهداتی و محاسباتی کاربرد دارد.

۳- نتایج و بحث

نتایج مدل‌سازی چند ایستگاه با استفاده از داده‌های زیرحوضه‌های LRW با استفاده از دو سناریوی مجزا در بخش‌های زیر شرح داده شده‌اند. نتایج حاصل از مدل‌های FFNN و LSSVM نیز در هر دو سناریو مقایسه شدند.

نزدیک خروجی (N و O)، بدون تأخیر برای پیش‌بینی نیترات خروجی حوضه آبریز LRW وارد مدل‌های هوش مصنوعی گردیدند. مقایسه نتایج پیش‌بینی چند ایستگاه نیترات (جدول ۲) نشان می‌دهد اگرچه مدل‌های FFNN و LSSVM نتایج قابل قبولی را نشان دادند، اما مدل LSSVM توانست توانایی بالاتری بر اساس معیار ارزیابی DC نسبت به مدل FFNN به نمایش گذارد. یک روش پیش‌پردازش مناسب همانند سناریوی دو می‌تواند توانایی مدل چند ایستگاه را بهبود بخشد. در بخش بعدی نتایج مدل‌سازی چند ایستگاه توسط سناریوی دو ارائه می‌شود.

دارد. در مدل اول، برای پیش‌بینی نیترات زیرحوضه I، نیترات زیرحوضه‌های K و J در زمان t بدون زمان تأخیر انتخاب شدند که این امر به دلیل نزدیکی ایستگاه‌های K و J با ایستگاه F و همین‌طور شیب بالا میان این ایستگاه‌ها بود؛ اما، نیترات زیرحوضه M با یک روز تأخیر توسط MI انتخاب گردید. در مدل دوم، نیترات زیرحوضه I با یک روز تأخیر برای پیش‌بینی نیترات زیرحوضه F وارد مدل‌های هوش مصنوعی گردید. در مدل سوم، به دلیل شیب کم کانال و فاصله زیاد بین ایستگاه‌های F و B، نیترات زیرحوضه F با دو روز تأخیر وارد مدل شد. همین‌طور، زیرحوضه‌های



شکل ۳- کاربری حوضه آبریز LRW در سال ۲۰۰۳ (Bosch و همکاران، ۲۰۰۶)

جدول ۲- نتایج پیش‌بینی چند ایستگاه نیترات در سناریوی یک توسط FFNN و LSSVM

مدل	زیرحوضه	خروجی	ورودی منتخب توسط MI	ساختار شبکه	ضریب تبیین		RMSE (نرمال)	
					آموزش	آزمایش	آموزش	آزمایش
	I	N_t^I	$Q_t^I, N_{t-1}^M, N_t^K, N_t^J$	$(4, 8, 1)$ ^۱	۰/۸۰	۰/۱۷	۰/۱۰	۰/۱۰
FFNN	F	N_t^F	Q_t^F, N_{t-1}^I	$(2, 1, 0, 1)$	۰/۷۰	۰/۲۸	۰/۰۹	۰/۰۹
	B	N_t^B	$Q_t^B, N_{t-2}^F, N_t^N, N_t^O$	$(4, 9, 1)$	۰/۷۲	۰/۲۶	۰/۱۰	۰/۱۰
	I	N_t^I	$Q_t^I, N_{t-1}^M, N_t^K, N_t^J$	$(7, 1)$ ^۲	۰/۷۴	۰/۲۳	۰/۰۹	۰/۰۹
LSSVM	F	N_t^F	Q_t^F, N_{t-1}^I	$(4, 2)$	۰/۷۰	۰/۲۸	۰/۰۹	۰/۰۹
	B	N_t^B	$Q_t^B, N_{t-2}^F, N_t^N, N_t^O$	$(3, 5)$	۰/۶۸	۰/۳۰	۰/۰۹	۰/۰۹

^۱ ساختار شبکه عصبی مصنوعی (از چپ به راست: تعداد نرون ورودی، تعداد نرون میانی و تعداد نرون خروجی)

^۲ پارامترهای کرنل RBF ماشین بردار پشتیبان (γ, σ)

۳-۲- نتایج سناریوی دو

در حوضه آبریز LRW بیشترین میزان نیترات در ماه‌های ژانویه تا مارس و کمترین میزان نیترات در ماه‌های ژوئیه تا سپتامبر مشاهده شده است، این امر به دلیل فصلی بودن الگوی نیترات رودخانه‌ها می‌باشد که میزان زهاب زمین در فصل زمستان افزایش می‌یابد. بنابر این، برای مد نظر قرار دادن الگوی فصلی در مدل‌سازی چند ایستگاه، از تبدیل موجک استفاده شد. در این میان، انتخاب مادر موجک مناسب، یک چالش در مدل‌سازی ترکیبی موجک-هوش مصنوعی به شمار می‌رود. وظیفه مادر موجک کشف شباهت مابین تابع موجک مورد استفاده و سری زمانی مورد تحلیل می‌باشد که به دلیل شباهت مادر موجک *coif2* به سری‌های زمانی نیترات حوضه آبریز LRW نسبت به مادر موجک‌های دیگر نظیر *db2* و *db5*، این مادر موجک در این تحقیق مورد استفاده قرار گرفت. علاوه بر این، انتخاب سطح تفکیک مناسب نیز در کاربرد تبدیل موجک دارای اهمیت خاصی است که در این مطالعه به دلیل وجود نمود فصلی سالانه، سطح تفکیک ۸ برای تجزیه سری‌های زمانی رواناب و نیترات زیرحوضه‌های LRW انتخاب گردید. گام بعدی در سناریوی دوم، انتخاب ورودی مناسب برای مدل‌های هوش مصنوعی از میان انبوه داده‌های زیرسری‌های جزء و تخمین زیرحوضه‌ها می‌باشد (۹ زیرسری رواناب و ۹ زیرسری نیترات برای هر زیرحوضه)، زیرا که افزایش بیش اندازه اطلاعات ورودی مدل‌ها می‌تواند باعث بیش برآزش و کاهش دقت پیش‌بینی گردد. بر این اساس در این مرحله تلاش گردید تا زیرسری‌های غالب از میان داده‌ها جهت ورود به مدل‌های هوش مصنوعی انتخاب گردد که این امر توسط ابزارهای SOM و MI انجام شد. بعد از تجزیه سری‌های زمانی دبی و نیترات زیرحوضه‌ها این زیرسری‌ها توسط ابزار SOM خوشه‌بندی شد تا زیرسری‌های همگن در یک خوشه قرار گیرند. این نوع خوشه‌بندی قبلاً در دیگر تحقیقات انجام پذیرفته است (Nourani و Parhizkar, ۲۰۱۳). بعد از خوشه‌بندی، معیار MI برای انتخاب زیرسری غالب از هر خوشه به کار گرفته شد. به مانند سناریوی اول، زیرسری که بیشترین مقدار MI را با خروجی مدل داشته باشد به عنوان ورودی به مدل هوش مصنوعی انتخاب گردید. ورودی‌های منتخب جهت مدل‌سازی چند ایستگاه در جدول (۳) آورده شده است. در مدل اول، برای پیش‌بینی نیترات زیرحوضه I، زیرحوضه J با چهار زیرسری زمانی نیترات و زیرحوضه K با دو زیرسری نیترات شرکت کردند و از زیرحوضه M، هیچ زیرسری انتخاب نگردید که این امر به دلیل کمبود میزان نیترات زیرحوضه M به جهت پوشش زیاد جنگلی می‌تواند باشد. در مدل دوم، برای پیش‌بینی نیترات زیرحوضه F، زیرحوضه I با سه زیرسری زمانی نیترات و زیرحوضه F با دو زیرسری رواناب انتخاب شدند. در مدل سوم نیز برای پیش‌بینی نیترات زیرحوضه B، زیرحوضه F با بیشترین مقدار نیترات با چهار زیرسری زمانی

نیترات و زیرحوضه‌های O و N نیز هرکدام با یک زیرسری زمانی نیترات و زیرحوضه B نیز با یک زیرسری زمانی رواناب برگزیده شدند. همان طور که ملاحظه می‌شود بر اساس مشخصات زیرحوضه‌ها، زیرحوضه‌های نزدیک خروجی مدل زیرسری‌های با فرکانس بالا و زیرحوضه‌های دور از خروجی حوضه با زیرسری‌های با فرکانس پایین در مدل‌سازی چند ایستگاه شرکت نمودند. نتایج مدل‌سازی‌های چند ایستگاه به وسیله FFNN و LSSVM در جدول (۳) برای سناریوی دو ارائه شده است. همین طور، برای سناریوی دوم، نیترات مشاهداتی و محاسباتی خروجی حوضه آبریز LRW به وسیله مدل FFNN در شکل (۴) نمایش داده شده است. همچنین مقایسه نتایج حاصل از مدل‌سازی چند ایستگاه حوضه آبریز LRW، تفاوت‌های دو سناریوی مارکف و فصلی را نشان می‌دهد (شکل (۵)).

۴- نتیجه‌گیری

پیش‌بینی نیترات چند ایستگاه حوضه آبریز LRW واقع در آمریکا بر اساس داده‌های روزانه دبی- نیترات زیرحوضه‌ها با استفاده از مدل‌های هوش مصنوعی FFNN و LSSVM انجام شد. این مدل‌سازی چند ایستگاه برای پیش‌بینی نیترات زیرحوضه‌های درون حوضه و خروجی حوضه آبریز با استفاده از دو سناریوی فصلی و مارکف صورت گرفت.


سری‌های زمانی روزانه رواناب و نیترات به عنوان ورودی‌های بالقوه جهت پیش‌بینی نیترات داخل و خروجی حوضه آبریز LRW با استفاده از هوش مصنوعی استفاده گردیدند؛ به این ترتیب که از داده‌های زیر حوضه‌های بالادست برای پیش‌بینی نیترات زیرحوضه‌های بالادست و سپس برای پیش‌بینی نیترات زیرحوضه‌های پایین دست استفاده گردید. اما قبل از مدل‌سازی، منشأ اصلی نیترات در حوضه آبریز LRW بررسی گردید و بر اساس داده‌های آماری و نوع کاربری زمین استنباط گردید که منشأ نیترات زیرحوضه‌ها، چراگاه‌ها و مزارع هستند.

در سناریوی اول با در نظر گرفتن خاصیت زنجیر مارکف سری‌های زمانی رواناب- نیترات به پیش‌بینی چند ایستگاه نیترات پرداخته شد. ورودی‌های منتخب توسط MI با ژنومورفولوژی حوضه آبریز LRW نیز مطابقت نشان داد، به طوری که زیر حوضه‌های دور و با شیب کم دارای تأخیر زمانی بیشتری نسبت به زیرحوضه‌های نزدیک و با شیب زیاد داشتند.

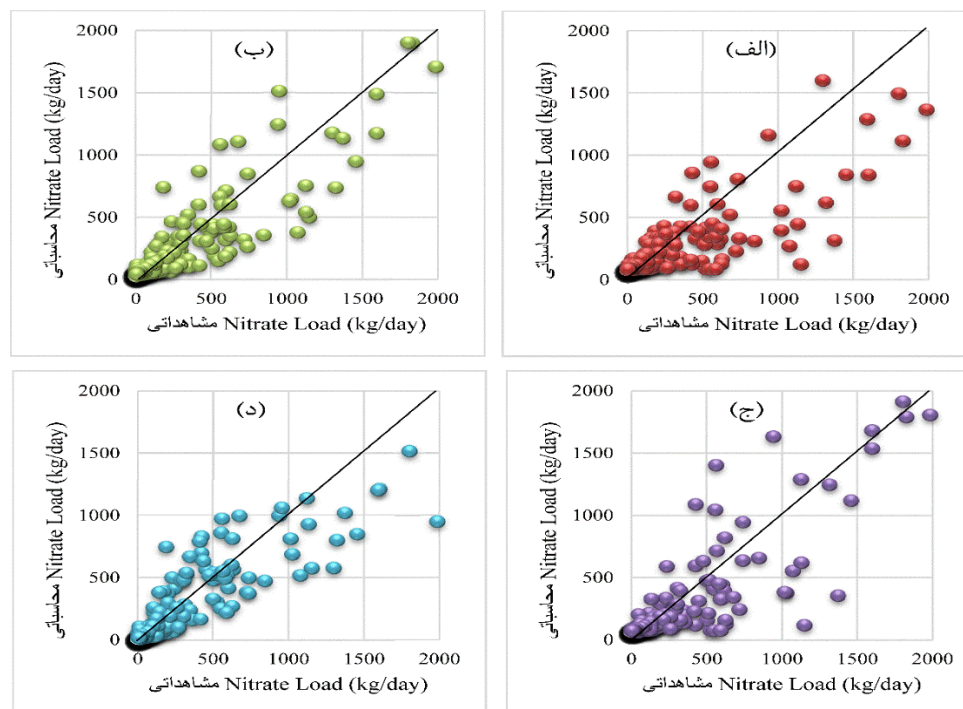
نتایج مدل‌های هوش مصنوعی نشان داد که سناریوی دو (فصلی) دقت بیشتری در پیش‌بینی نیترات نسبت به سناریوی یک (مارکف) دارا می‌باشد (حداکثر ۳۹ درصد) که این امر به دلیل در نظر گرفتن الگوی فصلی پدیده نیترات در سناریوی دو و همین‌طور انتخاب ورودی‌های بهینه می‌باشد.

جدول ۳- نتایج پیش‌بینی چند ایستگاه نیترات در سناریوی دو توسط FFNN و LSSVM

مدل	زیرحوضه	خروجی	ورودی منتخب توسط MI	ساختار شبکه	ضریب تبیین		RMSE (نرمال)		
					آموزش	آزمایش	آموزش	آزمایش	
	I	N_t^I		(۶,۵,۱)	$N_a^J, N_{d4}^J, N_{d6}^J, N_{d8}^J, N_a^K, N_{d5}^K$	۰/۸۲	۰/۸۴	۰/۰۱۲	۰/۰۰۶
FFNN	F	N_t^F		(۵,۷,۱)	$N_a^I, N_{d2}^I, N_{d6}^I, N_{d7}^I, Q_{d8}^I$	۰/۷۸	۰/۸۲	۰/۰۱۴	۰/۰۰۷
	B	N_t^B		(۷,۹,۱)	$N_a^F, N_{d6}^F, N_{d7}^F, N_{d8}^F, N_{d4}^N, N_{d3}^O, Q_a^{KB}$	۰/۸۱	۰/۸۶	۰/۰۱۰	۰/۰۰۶
	I	N_t^I		(۱۲,۴)	$N_a^J, N_{d4}^J, N_{d6}^J, N_{d8}^J, N_a^K, N_{d5}^K$	۰/۸۰	۰/۸۴	۰/۰۱۲	۰/۰۰۶
LSSVM	F	N_t^F		(۶,۲)	$N_a^I, N_{d2}^I, N_{d6}^I, N_{d7}^I, Q_{d8}^I$	۰/۸۰	۰/۸۲	۰/۰۱۴	۰/۰۰۶
	B	N_t^B		(۲,۹)	$N_a^F, N_{d6}^F, N_{d7}^F, N_{d8}^F, N_{d4}^N, N_{d3}^O, Q_a^{KB}$	۰/۸۲	۰/۸۲	۰/۰۱۴	۰/۰۰۶



شکل ۴- مرحله آزمایش سری‌های زمانی محاسباتی و مشاهداتی مدل FFNN نیترات خروجی حوضه آبریز LRW در سناریوی دو



شکل ۵- دیاگرام متقابل مرحله آزمایش سری‌های زمانی محاسباتی و مشاهداتی نیترات خروجی حوضه آبریز LRW. (الف) سناریوی یک مدل FFNN، (ب) سناریوی دو مدل FFNN، (ج) سناریوی یک مدل LSSVM، (د) سناریوی دو مدل LSSVM

Nourani V, Andalib G, "Daily and monthly suspended sediment load predictions using wavelet based artificial intelligence approaches", *Journal of Mountain Science*, 2015, 12(1), 85-100.

Nourani V, Baghanam AH, Adamowski J, Kisi O, "Applications of hybrid Wavelet-Artificial Intelligence models in hydrology: A review", *Journal of Hydrology*, 2014, 514, 358-377.

Nourani V, Khanghah TR, Baghanam AH, 2015. "Application of entropy concept for input selection of Wavelet-ANN based rainfall-runoff modeling", *Journal of Environmental Informatics*, 2015, 26, 52-70.

Nourani V, Komasi M, "A geomorphology-based ANFIS model for multi-station modeling of rainfall-runoff process", *Journal of Hydrology*, 2013, 490, 41-55.

Nourani V, Parhizkar M, "Conjunction of SOM-based feature extraction method and hybrid wavelet-ANN approach for rainfall-runoff modeling", *Journal of Hydroinformatics*, 2013, 15, 829-848.

Ravansalar M, Rajaee T, Zounemat-Kermani M, "A wavelet-linear genetic programming model for sodium (Na⁺) concentration forecasting in rivers", *Journal of Hydrology*, 2015, 537, 398-407.

Sarkar A, Pandey P, "River water quality modelling using artificial neural network technique", *Aquatic Procedia*, 2015, 4, 1070-1077.

Shannon CE, "A mathematical theory of communications I and II. Bell", *System Technical Journal*, 1948, 27, 379-443.

Suykens JAK, Vandewalle J, "Least square support vector machine classifiers", *Neural Processing Letters*, 1999, 9, 293-300.

Turan ME, Yurdusev MA, "River flow estimation from upstream flow records by artificial intelligence methods", *Journal of Hydrology*, 2009, 369, 71-77.

Yang HH, Vuuren SV, Sharma S, Hermansky H, "Relevance of time-frequency features for phonetic and speaker-channel classification", *Speech Communication*, 2000, 31, 35-50.

بنابراین، مدل موجک-هوش مصنوعی که با SOM-MI ترکیب شده است یک روش مناسب و کارآمد در مدل سازی چند ایستگاهه نیترات می باشد. بدین ترتیب که سری های زمانی زیرحوضه ها توسط تبدیل موجک تجزیه گشته، سپس زیرسری های همگن توسط ابزار SOM خوشه بندی گردیده و در گام بعدی از هر خوشه زیرسری غالب توسط MI برای ورود به مدل های هوش مصنوعی انتخاب شدند. پیشنهاد می گردد در مدل ارائه شده پارامترهایی نظیر شدت بارش و دما نیز دخیل گردند و نتیجه مدل سازی چند ایستگاهه با مدل های فیزیکی و دیگر مدل های هوش مصنوعی مقایسه گردد. همچنین مدل سازی چند ایستگاهه برای مدل سازی دیگر پارامترهای کیفیت آب نیز به کار برده شود.

۵- مراجع

ریاحی مدوار ح، ایوب زاده س، "نخمین ضریب پراکندگی طولی آلودگی با استفاده از سیستم استنتاج فازی-عصبی انطباقی"، *نشریه آب و فاضلاب*، ۱۳۸۷، ۶۷، ۳۴-۴۶.

علیانی ا، بانژاد ح، صمدی م، رحمانی ع، ساقی م، "ارزیابی کارایی شبکه عصبی مصنوعی در پیش بینی شاخص های کیفی (BOD و DO) آب رودخانه دره مرادیبک همدان"، *مجله دانش آب و خاک*، ۱۳۸۹، ۲۰، ۱۹۹-۲۱۰.

میرزائی م، ریاحی بختیاری ع، سلمان ماهینی ع، غلامعلی فرد م، "مدل سازی ارتباط کیفیت آب های سطحی و سنجه های سیمای سرزمین با استفاده از سیستم استنتاج عصبی- فازی (مطالعه موردی: استان مازندران)"، *مجله آب و فاضلاب*، ۱۳۹۵، ۲۷، ۸۱-۹۲.

Arabgol R, Sartaj M, Asghari K, "Predicting nitrate concentration and its spatial distribution in groundwater resources using support vector machines (SVMs) model", *Environmental Modeling and Assessment*, 2016, 21, 71-82.

Bosch DD, Sullivan DG, Sheridan JM, "Hydrologic Impacts of land-use Changes in Coastal Plain Watersheds", *Transactions of the ASABE*, 2006, 49 (2), 423-432.

Chang, FJ, Chang LC, Huang CW, Kao IF, "Prediction of monthly regional groundwater levels through hybrid soft-computing techniques", *Journal of Hydrology*, 2016, 541, 965-976.

Dixon B, "A case study using support vector machines, neural networks and logistic regression in a GIS to identify wells contaminated with nitrate-N", *Hydrogeology Journal*, 2009, 17, 1507-1520.

Kim T, Valdes JB, "Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks", *Journal of Hydrologic Engineering*, 2003, 6, 319-328.

Kohonen T, "Self-Organizing Maps", Springer-Verlag, Berlin, 1997.

Mallat SG, "A Wavelet Tour of Signal Processing", second ed. Academic Press, San Diego, 1998.

EXTENDED ABSTRACT

Multi-Station Nitrate Prediction via Artificial Intelligence and Soft Computing Tools

Elnaz Sharghi, Vahid Nourani*, Gholamreza Andalib

Faculty of Civil Engineering, University of Tabriz, Tabriz 5166616471, Iran

Received: 19 February 2017; Accepted: 26 August 2017

Keywords:

Mutual information, Wavelet transform, Self-organizing map, Artificial intelligence, Little river watershed.

1. Introduction

The diffusion of nitrate pollution in watersheds is due to complex biochemical and hydrological procedures linked to the cycle of nitrogen and water. Nitrate load comes from different sources such as wastewater treatment plants, runoff of fertilized lawns and cropland, failing on-site septic systems, runoff of animal manure storage areas, and industrial discharges that contain corrosion inhibitors. Loss of nitrate to surface and groundwater can reduce farm productivity, harm the environment, and affect drinking water quality. Large uncertainties and limited physical understanding of the water quality such as nitrate barricade the process-based modeling and seek a black box relationship between driving and resultant variables. Therefore, in this paper Multi-Station (MS) modeling of nitrate of the Little River Watershed (LRW) has been done. Hence, MS nitrate modeling is considered whereby nitrate loads of the inside and outlet of the LRW could be predicted. As a more explanation, the nitrate of upper sub-basins are employed for predictions of the interior sub-basins nitrate loads, and then, central sub-basins are participated in outlet nitrate prediction of the LRW. So, MS model can prepare a reliable platform to get information about the amount of nitrate in crucial places of the LRW. For this purpose, two scenarios with distinct views are used for MS nitrate modeling to identify the suitable strategy for future hydro-environmental researches. In the first scenario, Markovian characteristics of the streamflow-nitrate process are proposed as the base of the MS model, where antecedent of streamflow and nitrate time series of sub-basins are shared in nitrate modeling. On the other hand, non-linear feature extraction criterion of MI that is more suitable measure regarding the linear measure of Correlation Coefficient (CC) is employed for the selection of appropriate inputs of the Least Square SVM (LSSVM) and Feed Forward Neural Network (FFNN) models to avoid from the time consuming trial-error process of input selection. In the second scenario, seasonality-based characteristics of the streamflow-nitrate process are focused. Where, streamflow and nitrate time series of the sub-basins are decomposed by the wavelet transforms at a suitable level for clarifying spectral and temporal information of the time series. Then, as a new feature extraction method, both SOM and MI are respectively employed for clustering homogeneous sub-series and selecting clusters' proper agents, to be fed into LSSVM and FFNN models for MS nitrate load modeling of the LRW.

2. Methodology

2.1. Proposed Method

The nonlinear Artificial Intelligence (AI)-based models of FFNN and LSSVM via two different scenarios (Markovian and seasonality-based) were proposed in this study to predict nitrate loads in the interior parts and outlet of the LRW. The aim of the proposed MS model was to predict the nitrate loads of the watershed using related sub-basins information as inputs of AI models to understand the circulation of nitrate load in

* Corresponding Author

E-mail addresses: elnaz_sharghi@yahoo.com (Elnaz Sharghi), vnourani@yahoo.com (Vahid Nourani), gholamreza.andalib@gmail.com (Gholamreza Andalib).

several places of the watershed. So, MS modeling lets engineers get out of classic black box views and identify the process in the mid points of the watershed by AI models and have more certainty in their decisions.

2.2. Case study

The LRW in Tifton, southeast Georgia, southeast US as a mould of a stereotyped coastal plain watershed was surveyed for the present study goal. Indwelling a wide zone in the southeast US, coastal plain watersheds have typified via platy, flat sedimentary flood plains with sandy soils, and slow moving flows. Observed streamflow and nitrate load time series from the LRW's sub-basins used in this study range from January-1990 to December-2003, have been recorded and compiled by <ftp://www.tiftonars.org/databases/LREW>.

2.3. Wavelet transform and Shannon entropy

For capturing the seasonality pattern of the nitrate process in the second scenario, WT was employed to decompose the time series into sub-series at different time scales. The wavelet gives a time-scale localization of time series that obtains from the compact support of its main function and attempts of relevance betwixt the time series and WT function. In the hydro-environmental fields, the signals often have discrete forms, which discrete WT was presented by (Mallat, 1998) as Eq. 1:

$$g_{m,n}(t) = \frac{1}{\sqrt{a_0^m}} g^* \left(\frac{t - nb_0 a_0^m}{a_0^m} \right) \quad (1)$$

where m and n are integers that control the wavelet dilation and translation respectively; a_0 is a specified fined dilation step greater than 1; and b_0 is the location parameter and must be greater than zero.

To select the suitable inputs of AI models with regard to the target in a non-linear process, it is necessary to use a robust supervised tool. To this end, entropy-based feature extraction tool of MI was employed in this paper which is briefly described here: Shannon entropy (H) or information content, for a discrete random variable of X by sample size of N (bin number), that gets values $x_1; x_2; \dots; x_N$ with probabilities of p_1, p_2, \dots, p_N , respectively, by (Shannon, 1948) as Eq. 2:

$$H(X) = H(P) = - \sum_{i=1}^N p(x_i) \log[p(x_i)] \quad (2)$$

MI betwixt 2 random variables X and Y is determined by (Yang et al, 2000) as Eq. 3:

$$MI(X, Y) = H(X) + H(Y) - H(X, Y) \quad (3)$$

Where $H(A)$ and $H(B)$ are the entropy of A and B , respectively, and $H(A, B)$ their joint entropy as Eq. 4:

$$H(A, B) = - \sum_{a \in A} \sum_{b \in B} p_{AB}(a, b) \log p_{AB}(a, b) \quad (4)$$

2.4. Feed Forward Neural Network (FFNN) and Least Square Support Vector Machine (LSSVM) models

In the simulation step, two distinct non-linear ANN and SVM data-driven models were utilized among various kinds of AI models, where former is a very commonly used method in hydro-environmental modeling and the latter one recently has gained more attention of hydrologists.

FFNN is known as the prominent kind of ANN, which utilized in most researches for examining the different hydro-environmental processes. 3-layer FFNN that have mostly employed to prediction of hydro-environmental signals gives an inclusive structure to portray nonlinear mapping betwixt inputs and target. The specific equation for one target variable of a 3-layer FFNN was presented by (Kim and Valdes, 2003).

LSSVM was emanated from SVM as a robust scheme for dealing problems in nonlinear classification, function and density prediction (Suykens and Vandewalle, 1999), where (Suykens and Vandewalle, 1999) presented the LSSVM non-linear regression. Between the various kernels of LSSVM, the Radial Basis Function (RBF) is usually employed in regression problems.

3. Results and discussion

Comparison of the obtained results of MS nitrate predictions of the LRW revealed differences between two proposed, Markovian and seasonality-based modeling scenarios (Table 1). The results of AI models showed that the scenario 2 could provide more precision results as far as seasonal pattern of the nitrate process was concerned, the justification being that in scenario 2, the models were only fed by utile pre-processed information, whereas in scenario 1, avail of sub-basins wasn't considered to be compared with each other. In the interim, scenario 1 lost its accuracy due to the paucity of temporal pre-processing and robust purge of information. The results of the second scenario, which employs both spatial and temporal pre-processing methods via feature extraction criterion, were more accurate than the results of the first scenario. Therefore, the Wavelet-AI models, which utilize SOM and MI to capture the space and/or time variations involved in the process, is an appropriate and promising MS nitrate load prediction method. Once decomposed by wavelets, the multi-level sub-signals of sub-basins entered the SOM and the sub-series with the same features were placed in one cluster. Next, via an appropriate feature extraction criterion (e.g., MI), useful sub-series were picked from each cluster, and those reflecting the dominant seasonality of the streamflow-nitrate process were imposed into AI model, in which way, only utile data were fed to the model.

Table 1. Comparison of nitrate predictions at outlet of the LRW by two scenarios

Model	Method	Network structure	DC		RMSE (normalized)	
			Calibration	Verification	Calibration	Verification
FFNN	Scenario 1	(4.9.1)	0.72	0.58	0.026	0.010
	Scenario 2	(7.9.1)	0.86	0.81	0.010	0.006
LSSVM	Scenario 1	(3.5)	0.68	0.65	0.030	0.009
	Scenario 2	(2.9)	0.82	0.82	0.014	0.006

4. Conclusions

Prior to modeling, the LRW nitrate load source was surveyed via data statistics and land cover classification and it was deduced that tilled and pasture lands are the main sources of the nitrate load in the sub-basins.

In the first scenario, the antecedent of streamflow-nitrate time series were utilized as inputs, but for suitable input selection, supervised feature extraction criterion of MI was employed to avoid a trial-error process. The results of MI input selection showed conformity with the geomorphology of the LRW i.e. the input sub-basins far from the output sub-basin and low slope had more lagged time compared to the near or high slope sub-basins.

Via the second scenario and to enhance the results of the first scenario, data pre-processing via WT and SOM-MI feature extraction methods led to the detection of important hydrological parameters which were proven useful in improving AI-based MS nitrate predictions. The success of the second scenario was due to the fact that nitrate process of the LRW obeys from a seasonal pattern that could be handled by WT.

Finally, the comparison of the results obtained by FFNN and LSSVM models revealed that LSSVM has a bit better performance than FFNN because of the former's strength in classifying nonlinear streamflow-nitrate data in both scenarios.

5. References

- Kim T, Valdes JB, "Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks", *Journal of Hydrologic Engineering*, 2003, 6, 319-328.
- Mallat SG, "A Wavelet Tour of Signal Processing", second ed. Academic Press, San Diego, 1998.
- Shannon CE, "A mathematical theory of communications I and II. Bell", *System Technical Journal*, 1948, 27, 379-443.
- Suykens JAK, Vandewalle J, "Least square support vector machine classifiers", *Neural Processing Letters*, 1999, 9, 293-300.
- Yang HH, Vuuren SV, Sharma S, Hermansky H, "Relevance of time-frequency features for phonetic and speaker-channel classification", *Speech Communication*, 2000, 31, 35-50.