

کاربرد مدل‌های یادگیری ماشین برای پیش‌بینی قابلیت جذب فیلتر تراشه‌های لاستیکی

ابوالفضل بامری^{۱*}، مهسا خالقی^۲

۱ مربی، عضو هیئت علمی گروه مهندسی علوم خاک، دانشکده آب و خاک، دانشگاه زابل، ایران
۲ دانش آموخته دکتری گروه مهندسی آب، دانشکده آب و خاک، دانشگاه زابل، ایران

(تاریخ دریافت: ۱۳۹۹/۱۱/۲۴؛ تاریخ تصویب: ۱۴۰۰/۰۷/۰۷)

چکیده

در دهه‌های اخیر خطر بالقوه فلزات سنگین در پساب‌ها و ورود آب به منابع آب سطحی و زیرزمینی به طور فزاینده‌ای مورد توجه جامعه جهانی قرار گرفته است. هدف از این مطالعه ارائه یک روش غیرمستقیم به منظور برآورد بازده جذب فیلتر تراشه‌های لاستیکی برای فلزات سنگین سرب، روی و منگنز از پساب صنعتی است. آزمایش‌های جذب ستونی در شرایط مزرعه، بصورت فاکتوریل با سه فاکتور در قالب طرح کاملاً تصادفی با سه تکرار انجام شد. فاکتورهای مورد مطالعه شامل سه فاکتور اندازه ذرات (دو سطح ۰/۵ و ۵ سانتی‌متر)، ضخامت فیلتر (سه سطح ۱۰، ۳۰ و ۵۰ سانتی‌متر) و زمان تماس جاذب با محلول بود. جذب عناصر با استفاده از ۶ مدل رگرسیون خطی، درخت رگرسیونی، شبکه عصبی مصنوعی، جنگل تصادفی، کیوبیست و ماشین بردار پشتیبان بر اساس مجموعه دیتای آزمایشات جذب میدانی مدل‌سازی شد. نتایج نشان داد مدل‌های جنگل تصادفی، شبکه عصبی مصنوعی، درخت رگرسیونی و کیوبیست برای پیش‌بینی راندمان جذب در هر سه عنصر عملکرد قابل قبولی داشتند. با این حال، با توجه به ضریب R^2 و خطای میانگین مربعات ریشه، جنگل تصادفی و شبکه عصبی مصنوعی عملکرد رضایت‌بخش‌تری نسبت به درخت رگرسیونی و کیوبیست مدل نشان دادند. بررسی اهمیت متغیرهای ورودی در دقت پیش‌بینی نیز نشان‌دهنده اهمیت بالای پارامتر زمان تماس جاذب با محلول فلزی در تمامی مدل‌های یادگیری ماشین بود. قابلیت پیش‌بینی دقیق مدل‌های توسعه داده شده می‌تواند به طور معنی‌داری بار کاری آزمایش‌های میدانی مانند راندمان جذب تراشه‌های لاستیکی را کاهش دهد. اهمیت نسبی متغیرها نیز می‌تواند مسیر صحیحی را برای تصفیه بهتر فلزات سنگین ایجاد کند.

کلید واژه‌ها: پساب صنعتی، جنگل تصادفی، شبکه عصبی مصنوعی، فلزات سنگین، مدل‌سازی

سرآغاز

در حالی که تقاضای مواد غذایی با توجه به رشد روزافزون جمعیت از روند رو به رشد قابل توجهی پیروی می‌کند، کمبود آب شیرین به یک محدودیت مهم در تولید مواد غذایی در سراسر جهان تبدیل می‌شود (Khaleghi et al., 2020). در همین راستا، تصفیه فاضلاب‌ها از آلاینده‌ها و سپس بهره‌برداری از این پساب‌های تصفیه شده به‌عنوان منبع بالقوه آب نه تنها می‌تواند کمبود آب را جبران کند، بلکه از ورود آلاینده‌های خطرناک به منابع آب‌های زیرزمینی و سطحی جلوگیری کند. جذب عناصر توسط جاذب‌های مختلف به عنوان یک روش عالی برای مقابله با آب و فاضلاب‌های حاوی فلزات سنگین به دلیل کارایی بالا و کم هزینه بودن شناخته شده است. اما مهم‌ترین قسمت در ساختن فیلتر، انتخاب جاذب است. جاذب‌های متعددی، از جمله کربن فعال تجاری (Kołodźńska et al., 2017)، خاک رس طبیعی یا اصلاح شده (Uddin et al., 2017)، نانولوله‌های کربنی و یا اکسید گرافن (Peng et al., 2017; Abbas et al., 2016)، تراشه‌های لاستیکی (Babiker et al., 2019) و بیومتریال طبیعی (Bădescu et al., 2018)، گزارش شده است که قادر به حذف فلزات از آب و پساب بودند. استفاده از تراشه‌های لاستیکی به عنوان جاذب کم هزینه برای تصفیه آب و فاضلاب، روشی کارا در مورد بازیافت زباله‌های لاستیکی است. تاکنون مطالعات بی‌شماری در مورد جذب فلزات سنگین روی ضایعات تراشه و پودر تایلر لاستیکی انجام شده است (Phasuphan et al., 2019 & Tariqul Islam et al., 2018). Babiker et al (2019) کارایی جاذب تهیه شده از لاستیک فرسوده برای حذف بور از آب را با در نظر گرفتن متغیرهایی همچون اسیدیته و غلظت اولیه فلز مورد بررسی قرار دادند. نتایج این تحقیق نشان داد که این جاذب دارای بالاترین ظرفیت جذب برای عنصر بور، در میان تمامی جاذب‌هایی که تاکنون برای این عنصر مورد مطالعه قرار گرفتند، بوده و همچنین از این جاذب به عنوان یک ماده در دسترس و ارزان با کارایی عالی برای جذب بور از آب‌های آلوده نام برده شد. لازم به ذکر است که جذب فلزات سنگین نه تنها به ویژگی‌های جاذب بستگی دارد، بلکه به شرایط محیطی، خصوصیات فلزات، غلظت اولیه و بسیاری متغیرهای دیگر نیز بستگی دارد. در این راستا، روش یادگیری ماشینی (Machine Learning) ممکن است برای حل مساله از طریق مدل‌سازی و یادگیری رفتار جذب

فلزات سنگین بر روی جاذب مانند جاذب لاستیکی متمرکز واقع شود (Emigdio et al., 2017). اگرچه از مدل‌های تجربی مانند مدل‌های لانگمویر و فروندلیچ برای توصیف تعادل جذب برای چند دهه استفاده شده است، اما به سختی می‌توان با این مدل‌ها به طور پیش‌گویانه نتیجه‌گیری کرد و نیز رابطه بین نتایج جذب و شرایط بهره‌برداری در دسترس نمی‌باشد (Febrianto et al., 2009). مدل‌های یادگیری ماشین در حال ظهور در تحقیقات بی‌شماری با موفقیت نشان داده شده‌اند که توانایی مدل‌سازی و پیش‌بینی روابط ریاضی پیچیده و غیرخطی بین متغیرهای مستقل و وابسته را دارند (Zhu et al., 2019; Dehghanian et al., 2016). اخیراً، مدل‌های حاصل از یادگیری ماشین و هوش مصنوعی به طور فزاینده‌ای در مطالعات علوم آب مورد استفاده قرار گرفته‌اند (Granata et al., 2017; Ajamzadeh et al., 2017; Norouzi et al., 2017). Granata et al (2017) از دو مدل رگرسیون بردار پشتیبان (SVR) و درختان رگرسیونی (RT) به منظور پیش‌بینی شاخص‌های کیفیت فاضلاب بهره بردند. نتایج آنان نشان داد که هر دو مدل از استحکام، قابلیت اطمینان و قابلیت تعمیم بالایی برای پیش‌بینی شاخص‌ها برخوردارند با این وجود، رگرسیون بردار پشتیبان عملکرد بهتری از خود نشان داد. Zhu et al (2019) نیز در پژوهشی به بررسی قابلیت روش‌های یادگیری ماشین در پیش‌بینی جذب عناصر توسط جاذب بایوچار پرداختند. در این تحقیق جذب ۶ عنصر سنگین (سرب، کادمیوم، نیکل، آرسنیک، مس و روی) روی ۴۴ بایوچار با استفاده از شبکه عصبی مصنوعی (ANN) و جنگل تصادفی (RF) بر اساس مجموعه داده‌های آزمایشات جذب مدل‌سازی شد. در این شبیه‌سازی مدل RF دقت و کارایی پیش‌بینی بهتری را برای راندمان جذب نسبت به مدل ANN از خود نشان داد.

اگر مدل‌های توسعه یافته برای داده‌های جذب تجربی دقیق باشند، می‌تواند نیروی انسانی و منابع مادی را در آزمایش‌های آینده به طور قابل توجهی کاهش دهد (Zhu et al., 2019). بنابراین، هدف از اجرای این تحقیق الف. استفاده از ۶ روش یادگیری ماشین شامل رگرسیون خطی، شبکه عصبی مصنوعی، درختان رگرسیونی، کیوبیست، جنگل تصادفی، ماشین بردار پشتیبان و مقایسه قابلیت مدل‌های انتخابی برای پیش‌بینی راندمان جذب تراشه لاستیکی و ب. تعیین اهمیت عوامل

تاثیرگذار بر فرآیند جذب می‌باشد.

طرح کاملاً تصادفی بود. تراشه‌های لاستیکی از لاستیک‌های فرسوده خودرو تهیه شد. برای تعیین اندازه ذرات مناسب تراشه‌های لاستیکی از الک‌هایی با اندازه مش مورد نظر استفاده شد تا ذرات در محدوده مورد نیاز آزمایش به دست آیند. مشخصات اولیه پساب مورد استفاده در آزمایش در جدول (۱) ارایه شده است. نمونه‌برداری پساب خروجی از فیلتر در بازه زمانی ۰/۵، ۱، ۲، ۴، ۶ و ۲۴ ساعت پس از شروع آزمایش صورت گرفت. در حین انجام آزمایش در تمام مراحل بار ثابت ۵۰ سانتی‌متر بر روی فیلتر قرار داده شد. نمونه‌های جمع‌آوری شده در ظروف نمونه‌برداری پلاستیکی با حجم ۸۰ سی‌سی نگهداری، و بر روی آن‌ها برچسب‌های مشخصات آزمایش انجام شده چسبانده و برای اندازه‌گیری پارامترها به آزمایشگاه منتقل شد. اندازه‌گیری عناصر سنگین منگنز، روی و سرب با استفاده دستگاه نشر اتمی ICP (پرکین المر مدل DV 7300) انجام شد. برای اندازه‌گیری در ابتدا با استفاده از محلول‌های استاندارد عملیات کالیبراسیون دستگاه انجام شده و سپس غلظت عناصر موردنظر در نمونه‌ها تعیین شد.

مواد و روش‌ها

• جمع‌آوری داده‌های جذب از آزمایش تجربی

به منظور بررسی اثر فیلتر تراشه‌های لاستیکی بر جذب عناصر سنگین سرب، روی و منگنز، سیستمی شامل ۱۸ عدد لایسیمتر با قطر ۵۰ سانتیمتر و ارتفاع ۱۱۰ سانتیمتر، که برای هر کدام یک شیر خروجی تعبیه شده بود، راه‌اندازی شد. آزمایش‌ها در شرایط مزرعه با استفاده از پساب صنعتی کارخانه صنایع فولاد واقع در استان اصفهان در سال ۱۳۸۹ در مزرعه تحقیقاتی دانشگاه صنعتی اصفهان انجام شد. پساب صنعتی از قسمت خروجی کوره بلند و قبل از ورود به حوضچه‌های ته‌شینی تهیه گردید. برای انجام آزمایش‌های جذب ستونی، از سه ضخامت مختلف ۱۰، ۳۰ و ۵۰ سانتی‌متر تراشه‌های لاستیکی استفاده شد. تراشه‌های لاستیکی مورد استفاده در آزمایش در دو سطح اندازه (۵ میلی متری و ۵ سانتی متری) بوده و آزمایش‌ها در ۳ تکرار صورت گرفت. طرح آماری به کار برده شده، فاکتوریل در قالب

جدول (۱): خصوصیات کیفی پساب صنعتی مورد استفاده

پارامتر	هدایت الکتریکی	اسیدیته	غلظت سرب	غلظت روی	غلظت منگنز
واحد	dSm ⁻¹	-		Ppm	
	۱۳/۳	۶/۵	۱/۸۵	۱/۴	۸/۸۶

• مدل‌های ساخته شده با روش‌های یادگیری ماشین

در این تحقیق، روش‌های یادگیری ماشین در محیط نرم‌افزار R اجرا شده است. R یک زبان برنامه‌نویسی و محیط نرم‌افزاری برای محاسبات آماری و تحلیل داده است که حاوی محدوده گسترده‌ای از تکنیک‌های آماری از جمله: مدل‌سازی خطی و غیرخطی، آزمون‌های کلاسیک آماری، تحلیل سری‌های زمانی، رده‌بندی، خوشه‌بندی و قابلیت‌های گرافیکی می‌باشد (Rastegarnia & Sanaati, 2016). در حقیقت، روش‌های یادگیری ماشین برای آموزش و پیش‌بینی روابط پیچیده بین راندمان جذب و فاکتورهای موثر در فرآیند جذب استفاده شد. هدف از ماشین‌های یادگیری پیدا کردن یک عملکرد تقریباً مفید است که زمینه پیش‌بینی ارتباط بین متغیرهای ورودی و نتایج موردنظر را نشان دهد (Mirakzehi et al., 2017). معماری مدل شبکه عصبی مصنوعی (ANN) از یک ساختار نقشه‌برداری

غیرخطی تشکیل شده است که توسط یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده است. هر لایه تعداد سلول‌های عصبی متفاوتی دارد که با وزن مشخصی به هر نورون در لایه بعدی مرتبط است (Zhu et al., 2018). مدل رگرسیون خطی ساده یا چندگانه مدلی است که رابطه بین یک متغیر پاسخ و یک متغیر پیش‌بینی کننده (رگرسیون ساده خطی) یا بیش از یک متغیر پیش‌بینی کننده (رگرسیون خطی چندگانه) را با استفاده از پارامترهای وارد شده بصورت خطی و تخمین زده شده با روش حداقل مربعات نشان می‌دهد (Noi et al., 2017). ماشین بردار پشتیبان، تکنولوژی جدید یادگیری ماشین است که روش آماری غیرپارامتریک و نیمه‌نظارت شده می‌باشد (Rezaei et al., 2018). در حقیقت مدل‌های ماشین‌های بردار پشتیبان به دو گروه عمده الف. مدل طبقه‌بندی ماشین بردار پشتیبان و ب. مدل رگرسیون بردار پشتیبان تقسیم‌بندی می‌شوند. از مدل

• تقسیم بندی داده‌ها برای مدل‌های یادگیری ماشین

برای اجرای ۶ مدل یادگیری ماشین موردنظر از نتایج حاصل از آزمایش‌های میدانی جاذب عناصر سرب، روی و منگنز از پساب صنعتی توسط جاذب تراشه‌های لاستیکی استفاده شد. در طی این فرایند کل داده‌ها به دو دسته تقسیم‌بندی شده‌اند: داده‌های مرحله آموزش (Training data) و داده‌های مرحله آزمایش (Testing data)، به طوری که در این تحقیق ۸۰ درصد از کل داده‌ها به آموزش مدل اختصاص یافت و ۲۰ درصد باقیمانده به عنوان داده‌های آزمون به مدل معرفی شده است. انتخاب داده‌های آموزش و آزمون به صورت سیستماتیک و توسط کاربر انجام شده و بدیهی است که داده‌های یک مرحله در مرحله دیگر مورد استفاده قرار نگرفته است.

• عناصر مورد استفاده در شبیه‌سازی

در شبیه‌سازی با مدل‌های یادگیری ماشین برای پیش‌بینی قابلیت جاذب فیلتر مورد مطالعه از عناصر مختلفی استفاده شده است. این عناصر به عنوان متغیر مستقل به مدل معرفی و شبیه‌سازی‌ها برای پیش‌بینی متغیر هدف (عناصر سرب، روی و منگنز) صورت گرفته است. متغیرهای مستقل مورد استفاده در این تحقیق و علایم اختصاری آنها در جدول (۲) ارائه شده است.

جدول (۲): معرفی عناصر ورودی مدل‌های یادگیری ماشین

عناصر ورودی	حداقل	حداکثر	میانگین
اندازه تراشه لاستیکی (میلی‌متر)	۵	۵۰	۲۷/۵
ضخامت فیلتر لاستیکی (سانتی‌متر)	۱۰	۵۰	۳۰
زمان تماس جاذب با محلول فلزی (ساعت)	۰	۲۴	۱۲

$$\text{Bias} = \bar{P} - \bar{O} \quad (۳)$$

که در فرمول‌های مذکور: n تعداد کل نقاط مورد بررسی، \bar{O} میانگین مقادیر مشاهده شده، \bar{P} میانگین مقادیر پیش‌بینی شده، O_i مقدار مشاهده شده در نقطه i ام و P_i مقدار پیش‌بینی شده با استفاده از مدل در این نقطه است.

نتایج و بحث

• ارزیابی آماری نتایج آزمایش میدانی

شاخص‌های آماری مانند حداقل، حداکثر، میانگین، انحراف معیار و ضریب تغییرات فلزات سنگین پساب ورودی و خروجی در

طبقه‌بندی ماشین بردار پشتیبان جهت حل مسایل طبقه‌بندی داده‌هایی که در کلاس‌های مختلف قرار می‌گیرند، استفاده می‌گردد و مدل رگرسیون بردار پشتیبان در حل مسایل پیش‌بینی کاربرد دارد (Samadianfard & Panahi, 2018). درخت تصمیم یکی از روش‌های داده‌کاوی و ابزارهای قوی و متداول برای دسته‌بندی (classification tree) و پیش‌بینی (regression tree) می‌باشد، که برخلاف شبکه‌های عصبی به تولید قانون می‌پردازد. بدین منظور، فضا یا محدوده مقادیر داده‌های ورودی به چند زیربازه تقسیم و برای هر زیربازه یک الگوی یادگیری، معادله یا مدل ساده استخراج می‌شود (Hasani et al., 2018). جنگل تصادفی نوعی الگوریتم مجموعه طبقه‌بندی شده است که توسط برایمن و کاتلر پیشنهاد شده است. جوهر الگوریتم RF بهبود الگوریتم درخت تصمیم است (Ma et al., 2016). جنگل تصادفی می‌تواند الگوهای پیچیده را یاد بگیرد و ارتباط غیرخطی بین متغیرهای توضیحی و متغیرهای وابسته را در نظر بگیرد (Norouzi et al., 2017). مدل کیوبیست بر اساس درخت مدل M5 کوئینلان پیشنهاد شد (Quinlan, 1993). از مدل مربوطه برای محاسبه مقدار پیش‌بینی شده استفاده می‌شود (Zhou et al., 2019; Noi et al., 2017).

• معیارهای ارزیابی مدل‌ها

به منظور ارزیابی مدل‌های به کار برده شده برای شبیه‌سازی، از چند شاخص آماری از جمله خطای میانگین مربعات ریشه (RMSE)، ضریب تبیین (R^2) و اریب (Bias) استفاده شد که به ترتیب در روابط زیر تعریف شده است (Omidvar et al., 2014):

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (۱)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (O_i - P_i)}{\sum_{i=1}^n (O_i - \bar{O})} \quad (۲)$$

جدول (۳) آمده است. حداکثر مقدار مجاز عناصر سنگین سرب، روی و منگنز در آب آبیاری بر اساس استاندارد پرت و سوارز به ترتیب برابر با ۵، ۲ و ۰/۲ میلی‌گرم بر لیتر است (Tanji, 1990). بر طبق جدول (۳) میزان روی و منگنز در پساب ورودی بیشتر و میزان سرب پساب ورودی کمتر از حداکثر غلظت های مجاز عناصر کمیاب در آب آبیاری می‌باشد.

جدول (۳): آمار توصیفی غلظت عناصر مورد مطالعه در پساب ورودی و خروجی

واحد	داده های پساب ورودی			داده های پساب خروجی		
	Pb	Mn	Zn	Pb	Mn	Zn
	mg.l ⁻¹					
تعداد نمونه	۱۸	۱۸	۱۸	۱۰۸	۱۰۸	۱۰۸
حداقل	۱/۸۵	۸/۸۶	۴/۰۹	۰	۳/۱۶	۱
حداکثر	۱/۸۵	۸/۸۶	۴/۰۹	۱/۳۲	۷/۶۴	۳/۸۵
میانگین	۱/۸۵	۸/۸۶	۴/۰۹	۰/۴۷	۴/۹۰	۲/۴۳
انحراف معیار	۰	۰	۰	۰/۳۵	۱/۱۷	۰/۷۱
ضریب تغییرات (%)	۰	۰	۰	۷۳/۱۳	۲۳/۸۵	۲۹/۱۴

همچنین شعاع یونی آن‌ها ربط داد (Asadi, 2002). Gupta et al (2012) نیز کارایی بالای جاذب حاصل از لاستیک‌های فرسوده را در جذب عنصر سرب و نیکل نشان دادند. این محققین نیز بیشترین میزان جذب را برای عنصر سرب اعلام کرده و علت آن را الکترونگاتیوی بالای عنصر سرب و در نتیجه قدرت جذب شونده‌ی بیشتر بر روی سطح جاذب دانستند. همچنین، همبستگی پارامترهای خروجی (غلظت عناصر سنگین در پساب خروجی از فیلتر) با متغیرهای ورودی آزمایش (خصوصیات جاذب و زمان تماس) از طریق محاسبه ضریب همبستگی (r) مورد بررسی قرار گرفت (جدول ۴). ضریب همبستگی در دو سطح اطمینان ۰/۰۱ و ۰/۰۵ محاسبه شده است.

همچنین بر طبق این جدول، مقادیر حداقل، حداکثر و میانگین غلظت هر سه عنصر در پساب خروجی نشان‌دهنده عملکرد مناسب فیلترهای استفاده شده در جذب عناصر می‌باشد. به طوری که بر اساس مقادیر میانگین، مقدار جذب ۷۵/۶ درصد برای عنصر سرب، ۴۴/۷ درصد برای عنصر منگنز و ۴۰/۶ درصد برای عنصر روی به دست آمد. بر اساس نتایج به دست آمده استفاده از جاذب تراشه‌های لاستیکی سبب کاهش بیش از ۷۵ درصدی مقدار عنصر سرب در پساب خروجی شده است که نشان‌دهنده کارایی بالای این جاذب در جذب سرب می‌باشد. با این وجود این جاذب برای دو عنصر دیگر نیز با جذب بیش از ۴۰ درصد، نتایج قابل قبولی از خود نشان داده است. این تفاوت در میزان جذب کاتیون‌های فلزی را می‌توان به تفاوت در میل ترکیبی آن‌ها برای اتصال به گروه‌های عاملی سطح مواد جاذب و

جدول (۴): همبستگی پارامترهای خروجی با متغیرهای ورودی


پارامتر خروجی	زمان تماس جاذب با محلول فلزی	ضخامت فیلتر لاستیکی	اندازه تراشه لاستیکی
سرب	-۰/۶۱۵ **	-۰/۰۵۵	۰/۰۰۳
منگنز	-۰/۴۷۶ **	-۰/۳۴۲ **	-۰/۰۷
روی	-۰/۶۵۸ **	-۰/۱۰۱	۰/۲۲۸ *

جاذب و محلول حاوی فلزات سنگین میزان جذب افزایش یافته و در نتیجه غلظت عناصر در پساب خروجی کاهش می‌یابد. مقادیر منفی ضریب همبستگی بین پارامترهای خروجی و

با توجه به ضریب همبستگی (جدول ۴)، غلظت هر سه عنصر سرب، روی و منگنز رابطه منفی معنی‌داری را با زمان در سطح ۱ درصد نشان داد. این بدان معنی است که با افزایش زمان تماس

با توجه به این که بر اساس نتایج همبستگی پارامترهای خروجی با متغیرهای ورودی، مولفه‌ی زمان تماس جاذب با محلول فلزی بیشترین تاثیر را در غلظت عناصر در پساب خروجی داشته، برای نشان دادن اثر متقابل متغیرهای ورودی شبیه‌سازی دو بعدی برای هر عنصر به صورت جداگانه صورت گرفت (شکل ۱). همان‌طور که در شکل (۱) قابل مشاهده می‌باشد با گذشت زمان تماس از ۰ تا ۲۴ ساعت، نمودار غلظت سرب در پساب خروجی از رنگ سفید که دارای بالاترین محدوده غلظت می باشد ($>1/22$) به رنگ آبی که دارای کمترین میزان غلظت می‌باشد ($>0/13$) تغییر یافت که به وضوح نشان‌دهنده تاثیر بالای پارامتر زمان در فرآیند جذب می‌باشد.

ضخامت فیلتر نیز نشان‌دهنده رابطه معکوس بین غلظت عناصر در پساب خروجی و ضخامت فیلتر به کار برده شده می‌باشد. در حقیقت با افزایش ضخامت فیلتر کارایی فیلتر در جذب عناصر بالاتر رفته و در نتیجه غلظت عنصر در پساب خروجی کاهش می‌یابد. هر چند به جز برای عنصر منگنز (دارای معنی‌داری در سطح یک درصد) در بقیه عناصر این همبستگی از نظر آماری معنی‌دار نبوده است. بین اندازه ذرات فیلتر و غلظت عناصر سرب و منگنز در پساب خروجی از فیلتر همبستگی معنی‌داری مشاهده نشده و تنها برای عنصر روی در سطح ۵ درصد همبستگی معنی‌دار بود. همبستگی بین میزان جذب عناصر با زمان تماس محلول فلزی و ضخامت فیلتر در دیگر تحقیقات نیز گزارش شده است (Abedi & Mousavi, 2004; Kazemipour et al., 2008; Ansari, 2005; Ram-Bishnoi et al., 2004).



شکل (۱): نقشه دو بعدی تغییرات زمانی عنصر سرب در پساب خروجی در بعدهای ضخامت و اندازه.

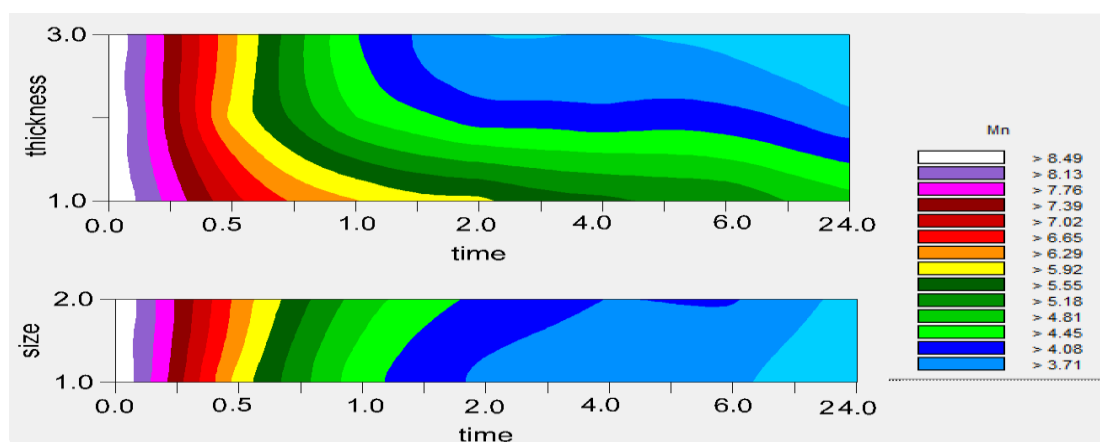
(۱) نشانگر عدم تاثیر اندازه ذرات جاذب در فرآیند جذب سرب از پساب می‌باشد که با نتایج جدول همبستگی هم‌خوانی دارد. لازم به ذکر است در این نمودار اندازه ذرات ۱ نشان‌دهنده ذرات ۵۰ میلیمتری و اندازه ذرات ۲ نشان‌دهنده ذرات ۵ میلیمتری می‌باشد.

در شکل (۲) نیز کاملاً قابل مشاهده می‌باشد که با گذشت زمان تماس از ۰ تا ۲۴ ساعت، غلظت عنصر منگنز در پساب خروجی کاهش یافته است. شیب شدید در نمودار اثر متقابل زمان و ضخامت فیلتر (نمودار بالایی در شکل ۲) تاثیر بهتر ضخامت بالاتر را نسبت به ضخامت کمتر در فرآیند جذب به خوبی نشان می‌دهد. در این نمودار ضخامت ۵۰ سانتی‌متری فیلتر در زمان تماس بسیار کمتری در مقایسه با ضخامت فیلتر ۱۰ سانتی‌متر به

اثر متقابل متغیر زمان با متغیر ضخامت فیلتر (نمودار بالایی در شکل ۱) نشان می‌دهد که در زمان‌های اولیه تماس جاذب با محلول فلزی بین ضخامت‌های مختلف به کار برده شده تفاوت قابل مشاهده‌ای در عملکرد جذب وجود ندارد، اما با گذشت زمان شیب ملایم نمودارهای رنگی بیانگر تاثیر بهتر ضخامت بیشتر (۵۰ سانتی‌متر) می‌باشد. بدین معنی که در زمان تماس برابر، هر چه ضخامت فیلتر بیشتر می‌شود مقدار جذب بالاتر و در نتیجه غلظت سرب در پساب خروجی کمتر می‌شود. تاثیر حجم و یا ضخامت فیلتر در بالا رفتن کارایی فیلتر در تحقیقات پیشین ذکر شده است (Kazemipour et al., 2008; Ram-Bishnoi et al., 2004). همچنین عمودی بودن خطوط رنگی در نمودار اثر متقابل متغیر زمان با اندازه ذرات جاذب (نمودار پایینی در شکل

پایینی در شکل ۲)، تاثیر غير معنی‌دار اندازه ذرات جاذب در فرایند جذب قابل مشاهده می‌باشد. نمودارهای اثر متقابل عنصر منگنز نیز کاملاً موید نتایج جدول همبستگی می‌باشد.


مقدار مشخصی از راندمان جذب رسیده است و در پایان زمان تماس محلول فلزی با جاذب غلظت منگنز کمتری را در پساب خروجی از خود نشان داده است. همچنین برای عنصر منگنز نیز در نمودار اثر متقابل متغیر زمان با اندازه ذرات جاذب (نمودار



شکل (۲): نقشه دو بعدی تغییرات زمانی غلظت عنصر منگنز در پساب خروجی در بعدهای ضخامت و اندازه

در طول زمان مشابه هم نبوده و در برخی زمان‌ها ضخامت فیلتر ۳۰ سانتی‌متر برابر و یا حتی کمی کمتر از ضخامت فیلتر ۱۰ سانتی‌متر اثر کرده است. هر چند این اتفاق در زمان‌های اولیه تماس جاذب و محلول فلزی (۴ ساعت اول) رخ داده است و با گذشت زمان باز هم روند اثر متقابل مشابه دو عنصر قبل می‌باشد.

برای عنصر روی (شکل ۳) نیز مانند دو عنصر دیگر، تاثیر پارامتر زمان در فرایند جذب کاملاً مشهود بوده و از نظر آماری طبق جدول همبستگی تاثیر از نظر آماری معنی‌دار بوده است. اما برای این عنصر اثر متقابل پارامترهای اندازه ذرات و ضخامت کمی متفاوت می‌باشد. همان‌طور که در نمودار بالایی در شکل (۳) قابل بیان می‌باشد باز هم ضخامت بیشتر دارای تاثیر بهتر و سریعتر در فرایند جذب عنصر روی بوده است اما شیب نمودارها



شکل (۳): نقشه دو بعدی تغییرات زمانی غلظت عنصر روی در پساب خروجی در بعدهای ضخامت و اندازه.

است، اندازه ذرات شماره ۲ یا همان ذرات فیلتر ۵ میلی‌متری (کوچکتر) دارای تاثیر بیشتر در فرایند جذب روی از محلول فلزی می‌باشند و این تاثیر با گذشت زمان مشهودتر می‌باشد. این روند

در نمودار پایینی در شکل (۳)، اثر متقابل زمان تماس و اندازه ذرات نشان‌دهنده تاثیر مثبت هر دو پارامتر در فرایند جذب عنصر روی بوده و همان‌طور که در نمودار به وضوح قابل مشاهده

پیش‌بینی بالاتری از خود نشان دادند. مقادیر ضریب رگرسیون بالاتر از ۰/۹۷ هم در مرحله تست و هم در کل، برای روش‌های شبکه عصبی مصنوعی، جنگل تصادفی، کیوبیست و درخت رگرسیونی نشان‌دهنده کارایی بالای این روش‌ها در پیش‌بینی غلظت سرب خروجی و انطباق بسیار مطلوب مقادیر مشاهداتی و مقادیر پیش‌بینی شده توسط این مدل‌ها می‌باشد. بر اساس مقادیر R^2 ، روش رگرسیون خطی ($R^2 > 0/41$) و پس از آن روش ماشین بردار پشتیبان ($R^2 > 0/68$) عملکرد ضعیف‌تری را در پیش‌بینی غلظت سرب از خود نشان دادند.

برای دو عنصر منگنز و روی نیز مدل رگرسیون خطی بدترین عملکرد را در پیش‌بینی از خود نشان داد و پس از آن روش ماشین بردار پشتیبان کارایی متوسط در پیش‌بینی غلظت خروجی را موجب شد. همچنین برای این دو عنصر نیز مشابه با سرب، مدل‌های جنگل تصادفی، شبکه عصبی مصنوعی، کیوبیست و درخت رگرسیونی به طور مطلوبی ($R^2 < 0/85$) در پیش‌بینی غلظت خروجی موفق عمل نمودند. عملکرد بهتر مدل جنگل تصادفی ($R^2 < 0/97$) در پیش‌بینی غلظت سرب و آرسنیک در مقایسه با مدل ماشین بردار پشتیبان توسط (Ma et al (2016) گزارش شده است. همچنین در گزارش Granata et al (2017)، هر دو مدل درخت رگرسیونی و رگرسیون بردار پشتیبان قابلیت مطلوبی از خود در پیش‌بینی شاخص‌های کیفی فاضلاب مانند BOD، COD، TDS و TSS از خود بروز دادند.

برای عنصر روی با نتایج جدول همبستگی برای عنصر روی (همبستگی معنی دار در سطح ۵ درصد) مطابقت دارد. علت تفاوت مشاهده شده بین عنصر روی با دو عنصر دیگر را می‌توان به تفاوت در میل ترکیبی آن‌ها، الکترونگاتیوی و همچنین شعاع یونی آن‌ها ربط داد (Asadi, 2002).

• ارزیابی مدل‌های مختلف ماشین‌های یادگیری

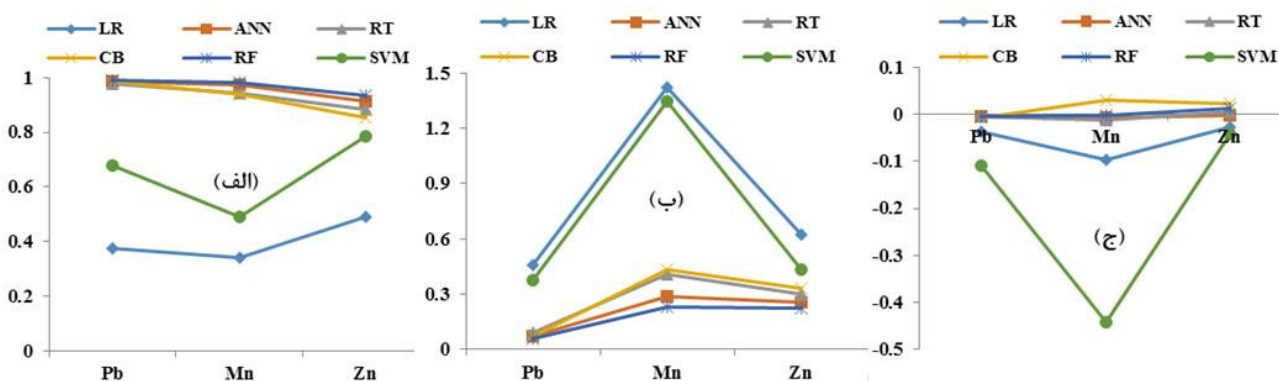
در مطالعه حاضر، هدف اصلی پیش‌بینی غلظت عناصر در پساب خروجی از فیلتر لاستیکی با استفاده از تعداد محدود پارامترهای ورودی سهل‌الوصول مانند زمان تماس جاذب با محلول فلزی و خصوصیات فیلتر است، به طوری که تا حد امکان از صرف زمان و هزینه‌های زیاد آزمایشات جذب جلوگیری شود. برای این منظور در این تحقیق، از ۶ روش یادگیری ماشین برای پیش‌بینی غلظت سه عنصر سنگین سرب، روی و منگنز در پساب خروجی از فیلتر استفاده گردید. مدل‌های به کار برده شده شامل: رگرسیون خطی، ماشین بردار پشتیبان، مدل کیوبیست، شبکه عصبی مصنوعی، درخت تصمیم‌گیری و جنگل تصادفی می‌باشد. ارزیابی آماری مدل‌های مورد مطالعه در جدول و شکل (۵) نشان داده شده است. مقایسه الگوریتم‌های مختلف ماشین‌های یادگیری برای هر سه عنصر مورد مطالعه بیانگر قابلیت بالای روش‌های یادگیری ماشین در پیش‌بینی غلظت عناصر در پساب خروجی از فیلتر لاستیکی می‌باشد. هر چند بر اساس شاخص‌های آماری محاسبه شده برخی از روش‌ها قابلیت

جدول (۵): ارزیابی مدل‌های مختلف ماشین‌های یادگیری در پیش‌بینی غلظت فلزات سنگین مورد مطالعه

روش	نوع داده	سرب			منگنز			روی		
		bias	RMSE	R^2	bias	RMSE	R^2	bias	RMSE	R^2
رگرسیون خطی	تست	-۰/۱۴۶	۰/۵۲۷	۰/۴۱۱	-۰/۳۸۰	۱/۶۲۲	۰/۳۸۳	-۰/۱۰۳	۰/۶۳۸	۰/۵۹۳
	کل	-۰/۰۳۷	۰/۴۵۷	۰/۳۷۵	-۰/۰۹۶	۱/۴۲۲	۰/۳۴۲	-۰/۰۲۶	۰/۶۲۲	۰/۴۹۰
شبکه عصبی مصنوعی	تست	-۰/۰۱۷	۰/۰۶۸	۰/۹۹۰	-۰/۰۲۲	۰/۲۵۸	۰/۹۸۰	-۰/۰۱۱	۰/۲۳۵	۰/۹۵۱
	کل	-۰/۰۰۴	۰/۰۷۱	۰/۹۸۵	-۰/۰۰۶	۰/۲۸۴	۰/۹۷۳	-۰/۰۰۳	۰/۲۵۷	۰/۹۱۴
درخت رگرسیونی	تست	-۰/۰۱۷	۰/۰۸۹	۰/۹۸۲	-۰/۰۴۵	۰/۳۹۹	۰/۹۶۱	۰/۰۲۲	۰/۲۸۸	۰/۹۱۸
	کل	-۰/۰۰۴	۰/۰۸۹	۰/۹۷۴	-۰/۰۱۱	۰/۴۰۸	۰/۹۴۶	۰/۰۰۶	۰/۲۹۹	۰/۸۸۲
مدل کیوبیست	تست	-۰/۰۲۷	۰/۰۷۱	۰/۹۹۰	-۰/۰۲۹	۰/۳۶۰	۰/۹۶۸	-۰/۰۱۲	۰/۲۸۰	۰/۹۱۹
	کل	-۰/۰۰۷	۰/۰۷۲	۰/۹۸۵	-۰/۰۳۱	۰/۴۳۱	۰/۹۴۰	۰/۰۲۲	۰/۳۳۵	۰/۸۵۲
جنگل تصادفی	تست	-۰/۰۲۳	۰/۰۷۲	۰/۹۸۹	-۰/۰۲۴	۰/۲۵۲	۰/۹۸۴	۰/۰۴۲	۰/۲۳۴	۰/۹۴۷
	کل	-۰/۰۰۶	۰/۰۵۹	۰/۹۸۹	-۰/۰۰۲	۰/۲۳۳	۰/۹۸۲	۰/۰۱۲	۰/۲۲۲	۰/۹۳۵
ماشین بردار پشتیبان	تست	-۰/۱۹۹	۰/۴۹۷	۰/۶۳۲	-۰/۰۷۰۸	۱/۶۴۹	۰/۴۸۰	-۰/۱۲۶	۰/۵۲۵	۰/۷۸۷
	کل	-۰/۱۰۹	۰/۳۷۸	۰/۶۸۰	-۰/۴۴۳	۱/۳۴۵	۰/۴۸۹	-۰/۰۴۲	۰/۴۳۱	۰/۷۸۷

شده، در شکل (۴) به وضوح قابل مقایسه می‌باشد. همان‌طور که از شکل‌ها برمی‌آید برای هر سه عنصر، مدل‌های رگرسیون خطی و ماشین بردار پشتیبان ضعیف‌ترین عملکرد را داشتند. همچنین، مدل‌های جنگل تصادفی، شبکه عصبی مصنوعی، درخت رگرسیونی و کیوبیست به ترتیب بهترین عملکرد را از خود نشان دادند. (Zhu et al (2019) نیز دقت و کارایی بالای دو مدل جنگل تصادفی و شبکه عصبی مصنوعی را در پیش‌بینی جذب عناصر سرب، روی، کادمیوم، آرسنیک، نیکل و مس توسط جاذب بایوچار اعلام کردند. هر چند در تحقیق آنان مدل جنگل تصادفی بهتر از مدل شبکه عصبی مصنوعی گزارش شده است.


علاوه بر شاخص آماری ضریب رگرسیون، نزدیک بودن مقادیر دو شاخص RMSE و Bias به صفر نیز بیان‌کننده عملکرد بهتر چهار مدل شبکه عصبی مصنوعی، جنگل تصادفی، کیوبیست و درخت رگرسیونی در مقایسه با روش‌های رگرسیون خطی و ماشین بردار پشتیبان می‌باشد. همچنین مقادیر منفی Bias نشان‌دهنده این می‌باشد که تقریباً تمامی مدل‌ها تمایل به کم‌برآورد کردن غلظت عناصر خروجی دارند. هر چند مقادیر این کم‌برآورد در اکثر مدل‌ها ناچیز و نزدیک به صفر بوده و موجب کاهش دقت پیش‌بینی نشده است. همچنین، دقت مدل‌های مختلف یادگیری ماشین برای پیش‌بینی غلظت خروجی سه عنصر سرب، روی و منگنز بر اساس شاخص‌های آماری محاسبه



شکل (۴): مقایسه دقت مدل‌های مختلف یادگیری ماشین بر اساس شاخص آماری (الف) R^2 (ب) RMSE (ج) Bias

برای عنصر منگنز، روند کلی مشابه با عنصر سرب بوده و متغیر زمان تماس تأثیرگذارترین پارامتر بوده و پس از آن متغیر ضخامت فیلتر و سپس اندازه ذرات در جایگاه بعدی اهمیت قرار داشتند. برای این عنصر نیز تنها در مدل شبکه عصبی مصنوعی پارامتر اندازه ذرات دارای تأثیر قابل توجهی در پیش‌بینی غلظت خروجی بوده است. در مورد عنصر روی، نتایج اهمیت متغیرها کمی متفاوت با دو عنصر دیگر بود. هر چند برای این عنصر نیز موثرترین پارامتر زمان تماس بوده اما پس از آن اندازه ذرات نقش پررنگ‌تری را نسبت به ضخامت فیلتر از خود بروز داد. علت این تفاوت مشاهده شده در بین عناصر مورد مطالعه را می‌توان به ماهیت عناصر و میل ترکیبی متفاوت آن‌ها با سطح جاذب ربط داد (Asadi, 2002).

اهمیت متغیرهای ورودی (زمان تماس، اندازه ذرات فیلتر، و ضخامت فیلتر) در پیش‌بینی غلظت خروجی سه عنصر مورد تحقیق در مدل‌های مختلف یادگیری ماشین مورد بررسی قرار گرفت (شکل ۵). نتایج اهمیت متغیرها برای عنصر سرب نشان می‌دهد که متغیر زمان تماس بیشترین تأثیر را در بیان تغییرات غلظت سرب در پساب خروجی در هر ۶ مدل به کار برده شده نشان داد. همچنین در همه مدل‌ها به جز مدل شبکه عصبی مصنوعی، متغیر اندازه ذرات کمترین نقش را در تغییر غلظت سرب داشت. متغیر ضخامت فیلتر در برخی مدل‌ها دارای تأثیر قابل توجه و در برخی مدل‌ها تأثیر ناچیزی از خود نشان داد. علت برخی تفاوت‌ها در اهمیت پارامترها در مدل‌های مختلف احتمالاً به فرآیند پیچیده شبیه‌سازی و روابط ریاضی پیچیده و غیرخطی بین متغیرهای مستقل و وابسته در مدل‌های مختلف پیش‌بینی مربوط می‌شود (Ajamzadeh et al., 2017).



شکل (۵): درجه اهمیت متغیرهای ورودی در مدل‌های مختلف یادگیری ماشین‌های

میدانی جذب سه عنصر مورد مطالعه توسط جاذب لاستیکی استفاده گردید. نتایج مدل‌سازی داده‌های آزمایش جذب نشان می‌دهد که از بین سه متغیر ورودی مورد بررسی، پارامتر زمان تماس جاذب با محلول فلزی به عنوان مهم‌ترین فاکتور در فرآیند جذب در تمامی مدل‌های یادگیری ماشین تعیین و دو فاکتور ضخامت فیلتر و اندازه ذرات جاذب دارای اهمیت نسبی کمتری بودند. همچنین بررسی‌ها بیانگر دقت بالاتر دو مدل جنگل تصادفی و شبکه عصبی مصنوعی ($R^2 < 0.94$) در پیش‌بینی غلظت عناصر خروجی از جاذب می‌باشد. هر چند مدل‌های درخت رگرسیونی و کیوبیست نیز نتایج مطلوبی برای هر سه عنصر ($R^2 < 0.85$) از خود نشان دادند. در این بین دو روش ماشین بردار پشتیبان و مدل رگرسیون خطی ($R^2 > 0.78$) برای پیش‌بینی غلظت عناصر خروجی از فیلتر دقت چندانی از خود نشان ندادند. با توجه به نتایج به‌دست آمده، مدل‌های جنگل تصادفی و شبکه عصبی مصنوعی دارای توانایی‌های قابل‌قبولی برای پیش‌بینی دقیق راندمان جذب فلزات سنگین برای جاذب تراشه‌های لاستیکی بوده و برای کاهش آزمایش‌های تکراری، زمان‌بر و پرهزینه‌ی جذب راهکار با ارزشی می‌باشد.

به طور کلی نتایج تعیین اهمیت متغیرهای ورودی در همه مدل‌ها نشان داد که پارامتر زمان دارای اهمیت بسیار زیادی در تعیین غلظت عناصر در پساب خروجی از فیلتر می‌باشند. متغیرهای ضخامت فیلتر و اندازه ذرات از درجه اهمیت کمتری برخوردار بوده و مدل‌ها به خوبی توانسته‌اند این موضوع را بیان کنند. این نتایج با مشاهدات میدانی (جدول ۴) کاملاً مطابقت داشته و این انطباق عملکرد خوب مدل‌ها را در تعیین پارامتر تاثیرگذار نشان می‌دهد. میرک‌زهی و همکاران نیز در تحقیق خود انطباق نتایج مشاهداتی و نتایج پیش‌بینی شده توسط مدل درخت تصمیم‌گیری را در تعیین اهمیت متغیرهای ورودی گزارش کردند (Mirakzehi et al., 2017).

نتیجه‌گیری

در این پژوهش از روش‌های یادگیری ماشین شامل روش‌های رگرسیون خطی، درخت رگرسیونی، شبکه عصبی مصنوعی، جنگل تصادفی، کیوبیست مدل و ماشین بردار پشتیبان برای پیش‌بینی بازده جذب فیلتر تراشه‌های لاستیکی برای فلزات سنگین سرب، روی و منگنز در محلول‌های آبی (پساب صنعتی) استفاده شد. برای ایجاد مدل‌های مذکور از داده‌های آزمایش

فهرست منابع

- Abbas, A.; Al-Amer, A.M.; Laoui, T.; Al-Marri, M.J.; Nasser, M.S.; Khraisheh, M. & Atieh, M.A. 2016. Heavy metal removal from aqueous solution by advanced carbon nanotubes: critical review of adsorption applications. *Separation and Purification Technology*. 157:141–161.
- Abedi Koupaei, J. & Mousavi, F. 2004. Adsorption of lead from industrial effluent by paddy husk ash, *Journal of Water and Wastewater*, 40: 37-33. (In Persian)

Ajamzadeh, A.; Mollaeinia, M.R. & Ghandahari, Gh. 2017. Comparison of Artificial Intelligence Methods in Predicting Daily Time Series of Minimum and Maximum Temperature and Precipitation in Tangab Dam Station (Fars Province). *Geographical Space*, 59: 205-228. (In Persian)

Ansari Mahabadi, A. 2005. Removal of Nitrate and Ammonium from Groundwater by Fine Mineral Filters, Applied Research Project, Deputy of Research and Basic Studies, Iran Water Resources Management Company. (In Persian)

Asadi, F. 2002. Removal of heavy metals from industrial wastewater by rice husk, sawdust and soil, Master Thesis in Soil Science, Faculty of Agriculture, Isfahan University of Technology. (In Persian)

Babiker, E.; Al-Ghouti, M.A.; Zouari, N. & McKay, G. 2019. Removal of boron from water using adsorbents derived from waste tire rubber. *Journal of environmental chemical engineering*. 7(2): 102948.

Bădescu, I.S.; Bulgariu, D.; Ahmad, I. & Bulgariu, L. 2018. Valorisation possibilities of exhausted biosorbents loaded with metal ions—a review. *Journal of Environmental Management*. 224: 288–297.

Dehghanian, N.; Ghaedi, M.; Ansari, A.; Ghaedi, A.; Vafaei, A.; Asif, M.; Agarwal, S.; Tyagi, I. & Gupta, V.K., 2016. A random forest approach for predicting the removal of Congo red from aqueous solutions by adsorption onto tin sulfide nanoparticles loaded on activated carbon. *Desalination and Water Treatment*. 57: 9272–9285.

Emigdio, Z.; Abatal, M.; Bassam, A.; Trujillo, L.; Juárez-Smith, P. & El Hamzaoui, Y. 2017. Modeling the adsorption of phenols and nitrophenols by activated carbon using genetic programming. *Journal of Cleaner Production*. 161:860–870.

Febrianto, J.; Kosasih, A.N.; Sunarso, J.; Ju, Y.; Indraswati, N. & Ismadji, S. 2009. Equilibrium and kinetic studies in adsorption of heavy metals using biosorbent: a summary of recent studies. *Journal of Hazardous Materials*. 162:616–645.

Granata, F.; Papirio, S.; Esposito, G.; Gargano, R. & Marinis, G. 2017. Machine Learning Algorithms for the Forecasting of Wastewater Quality Indicators. *Water*. 9(105), doi:10.3390/w9020105.

Gupta, V.; Ganjali, M.R.; Nayak, A.; Bhushan, B. & Agarwal, Sh. 2012. Enhanced heavy metals removal and recovery by mesoporous adsorbent prepared from waste rubber tire. *Chemical Engineering Journal*. 197: 330–342.

Hasani, Z.; Mirabbasi-Najafabadi, R. and Ghasemi, A.R. 2018. Prediction of Groundwater Quality of Khanmirza plain Using Decision tree Method. *Hydrogeology*, 3(1): 99-110. (In Persian)

Kazemipour, M.; Ansari, M.; Tajrobehkar, S.; Majdzadeh, M. & Reihani Kermani, H. 2008. Removal of lead, cadmium, zinc and cooper from industrial wastewater by carbon developed from walnut, hazelnut, almond, pistachio shell and apricot stone, *Journal of Hazardous Materials*. 150: 322-327.

Khaleghi, M.; Hassanpour, F.; Karandish, F. & Shahnazari, A. 2020. Integrating partial root-zone drying and saline water irrigation to sustain sunflower production in freshwater-scarce regions. *Agricultural Water Management*. 234, <https://doi.org/10.1016/j.agwat.2020.106094>.

Kołodzyńska, D.; Krukowska, J. & Thomas, P. 2017. Comparison of sorption and desorption studies of heavy metal ions from biochar and commercial active carbon. *Chemical Engineering Journal*. 307: 353–363.

Ma, W.; Tan, K. & Du, P. 2016. Predicting soil heavy metal based on random forest model. *IGARSS: 4331-4334*. 978-1-5090-3332-4/16/\$31.00 ©2016 IEEE.

Mirakzahi, Kh.; Shahriari, A.; Pahlavan-Rad, M.R. & Bameri, A. 2017. Application of random forest method for predicting soil classes in low relief lands (Case study: Hirmand county). *Journal of Water and Soil Conservation*, 24(1): 67-84. (In Persian)

Noi, P.T.; Degener, J. & Kappas, M. 2017. Comparison of Multiple Linear Regression, Cubist Regression, and Random Forest Algorithms to Estimate Daily Air Surface Temperature from Dynamic Combinations of MODIS LST Data. *Remote sensing*. 9(398). doi:10.3390/rs9050398.

- Norouzi, H.; Nadiri, A.A.; Asghari Mogaddam, A. & Gharekhani, M. 2017. Prediction of Transmissivity of Malikan Plain Aquifer Using Random Forest Method. *Water and Soil Science*, 27(2):61-75. (In Persian)
- Omidvar, K.; Shafie, Sh.; Taghizadeh, Z. & Alipour, M. 2014. Evaluating the efficiency of the decision tree model in predicting rainfall in Kermanshah synoptic station. *Journal of Applied researches in Geographical Sciences*, 34: 89-110. (In Persian)
- Peng, W.; Li, H.; Liu, Y. & Song, S. 2017. A review on heavy metal ions adsorption from water by graphene oxide and its composites. *Journal of Molecular Liquids*. 230: 496–504.
- Phasuphan, W.; Praphairaksit, N. & Imyim, A. 2019. Removal of ibuprofen, diclofenac, and naproxen from water using chitosan-modified waste tire crumb rubber. *Journal of Molecular Liquids*. (294): 111554.
- Quinlan, R. 1993. Combining instance based and model based learning. In *Proceedings of the Tenth International Conference on Machine Learning*. Amherst, MA, USA. 27–29. pp. 236–243.
- Ram Bishnoi, N.; Bijaj, M.; Sharma, N. & Gupta, A. 2004. Adsorption of Cr (VI) on activated rice husk carbon and activated alumina. *Bioresource Technology*. 91: 305-307.
- Rastegarnia, M. & Sanaati, p. 2016. Determination of hydraulic flow units using random forest method for one of Iran's oil reservoirs, *Scientific-Extension Monthly of Oil and Gas Exploration and Production*, 135: 55-59. (In Persian)
- Rezaei, M.; Sameni, A. & Fallah-Shamsi, S.R. 2018. Advanced machine learning methods for wind erosion monitoring in southern Iran. *Journal of Environmental Erosion Research*, Vol: 29(8:1): 39-58. (In Persian)
- Samadianfard, S. & Panahi, S. 2018. Estimating Daily Reference Evapotranspiration using Data Mining Methods of Support Vector Regression and M5 Model Tree. *Journal of Watershed Management Research*, 10(18):157-167. (In Persian)
- Tanji, K.K. 1990. *Agricultural Salinity Assessment and Management*. ASCE Manuals and Reports on engineering practice. No. 71. New York. 481P.
- Tariqul Islam M.d.; Saenz-Arana, R.; Hernandez, C.; Guinto, T.; Ariful Ahsan, M.d.; Bragg, D.T.; Wang, H.; Alvarado-Tenorio, B. & Noveron, J. 2018. Conversion of waste tire rubber into a high-capacity adsorbent for the removal of methylene blue, methyl orange, and tetracycline from water. *Journal of Environmental Chemical Engineering*. <https://doi.org/10.1016/j.jece.2018.04.058>.
- Uddin, M.K. 2017. A review on the adsorption of heavy metals by clay minerals, with special focus on the past decade. *Chemical Engineering Journal*, 308: 438–462.
- Zhou, J.; Li, E.; Wei, H.; Li, Ch.; Qiao, Q. & Jahed Armaghani, D. 2019. Random Forests and Cubist Algorithms for Predicting Shear Strengths of Rockfill Materials. *Applied Sciences*. 9(1621), doi:10.3390/app9081621.
- Zhu, X.; Wang, X. & Sik Ok, Y. 2019. The application of machine learning methods for prediction of metal sorption onto biochars. *Journal of Hazardous Materials*. 378: 120727.
- Zhu, X.; Wu, G.; Coulon, F.; Wu, L. & Chen, D. 2018. Correlating asphaltene dimerization with its molecular structure by potential of mean force calculation and data mining. *Energy Fuel*. 32:5779–5788.