مجله علوم پزشکی زانکو/ دانشگاه علوم پزشکی کردستان/ تابستان ۱۳۹۳/ ۶۶-۵۶

کاربرد شبکه های عصبی مصنوعی در مدل سازی و بهینه سازی حذف رنگزای اسید بلاک ۱ با استفاده از نانوکامپوزیت TiO_2-Ni

کمال صالحی[۱]، بهزاد شاهمرادی[۲]، افشین ملکی[۳]، برهان منصوری[٤]، فردین غریبی[٥]

۱-دانشجوی کارشناسی ارشد مهندسی بهداشت محیط، دانشکده بهداشت، دانشگاه علوم پزشکی کردستان، سنندج، ایران

ایمیل: kamalsalehi1366@gmail.com- شماره موبایل: ۰۹۱۹۲۰۰۸۱۳۳

۲-استادیار مهندسی بهداشت محیط، مرکز تحقیقات بهداشت محیط، دانشگاه علوم پزشکی کردستان، سنندج، ایران

۳-دانشیار مهندسی بهداشت محیط، مرکز تحقیقات بهداشت محیط، دانشگاه علوم پزشکی کردستان، سنندج، ایران

٤-دانشجوی دکتری سم شناسی، مرکز تحقیقات آب و مواد غذایی، دانشگاه علوم پزشکی کردستان، سنندج، ایران

٥-کارشناسی ارشد مدیریت خدمات بهداشتی، معاونت تحقیقات، دانشگاه علوم پزشکی کردستان، سنندج، ایران

چکیده

زمینه و هدف: شبکه‌های عصبی مصنوعی، ساختاری غیر خطی بوده که عملکرد آن‌ها بر مبنای مغز انسان می باشد. این شبکه ها ابزاری قوی برای مدل‌سازی ،خصوصاً برای زمانی که ارتباط بین داده‌ها نامعلوم باشد، می‌باشند. بنابراین هدف این مطالعه استفاده از شبکه‌های عصبی مصنوعی برای مدل‌سازی و بهینه‌سازی حذف رنگزای اسید بلاک ۱ از محلول‌های آبی با استفاده از نانوکامپوزیت TiO_2-Ni می‌باشد.

روش بررسی: این تحقیق، یک مطالعه کاربردی- توسعه‌ای است که طی آن نانوکامپوزیت TiO_2-Ni سنتز و خصوصیات شیمیایی آن توسط تصویر میکروسکوپ الکترونی ارزیابی شد. برای طراحی آزمایشات، پیش‌بینی و مدل‌سازی حذف رنگدانه، به ترتیب از روش تاگوچیو شبکه‌های عصبی مصنوعی استفاده شد.

یافته‌ها: نتایج نشان داد که شبکه با تابع انتقال سیگموئیدی، الگوریتم آموزش مارکورات، یک لایه پنهان و ۵ نورون در لایه پنهان، بهتر می‌تواند میزان حذف رنگزای اسید بلاک۱ را پیش‌بینی کند.

بحث و نتیجه‌گیری: با توجه به نتایج بدست آمده، نتیجه می‌گیریم که مدل شبکه‌های عصبی می‌تواند رفتار فرایند فوتوکاتالیستی را در شرایط مختلف آزمایشگاهی پیش‌بینی کند.

واژه‌های کلیدی: اسید بلاک۱، شبکه‌های عصبی مصنوعی، نانوکامپوزیتTiO_2-Ni

[Downloaded from zanko.muk.ac.ir on 2026-11-09]

مقدمه

رنگزاهای آلی مصنوعی، یکی از مهم‌ترین آلاینده‌های فاضلاب‌های صنایعی همچون: نساجی، چرم سازی، رنگرزی، پلاستیک‌سازی وسایل آرایشی،کاغذ سازی ،صنایع رنگ سازی و غذایی است [۱]. سالیانه بیش از ۷×۱۰^{۵} تن در ۱۰۰۰۰ نوع رنگزاهای مصنوعی آلی در سراسر جهان تولید می‌شوند. تحقیقات نشان دادند که حدود ۰/۱۲ از رنگزهای مصرفی در صنایع نساجی وارد پساب می‌شوند و حدود ۲۰٪ این مقدار به همراه پساب تصفیک شده به آب‌های پذیرنده وارد می‌شوند. این رنگزاها نور برخوردی به سطح آب را جذب و منعکس [۲-۴] و از رشد آبزیان در آب جلوگیری می‌کنند و می‌توانند اثرات خطرناکی را بر زنجیره غذایی داشته باشند؛ اما مهمتر از همه، بسیاری از مواد موجود در این پساب‌ها، سمی و حتی سرطان‌زا هستند [۵،۶].

روش‌های متعدد فیزیکی، شیمیایی و بیولوژیکی به منظور حذف رنگزاها از پساب‌های نساجی بکار می‌روند. روش‌های تجزیک بیولوژیکی، به‌دلیل سمی بودن زیاد اغلب رنگزاها، برای میکروارگانیسم‌های موجود در فرایند و مقاوم بودن رنگزاها در برابر تجزیک‌ی بیولوژیکی بازده پایینی در تجزیک رنگ دارند[۷].

یکی دیگر از روش‌هایی که در چند سال اخیر توجه بسیاری از محققان را به خود جلب کرده است، اکسیداسیون پیشرفته می‌باشد. فرایندهای اکسداسیون پیشرفته بر پایک تولید رادیکال‌های آزاد هیدروکسیل با قدرت اکسیداسون بالا بوده که سبب تبدیل آلاینده‌های آلی به مواد معدنی(دی اکسیدکربن و آب) می‌شود[۱۰-۸] که بیشترین کارایی را در اکسیداسون ترکیبات مقاوم دارند. اکسیداسیون پیشرفته فرایندی پیچیده بوده و عوامل زیادی روی کارایی آن تأثیر دارند؛ از جمله این عوامل می‌توان به بالانس انرژی تابشی، توزیع انرژی تابشی و مکانیسم‌های انتقال جرم اشاره کرد. از این‌رو مدل‌سازی و پیش‌بینی این فرایند به دلیل تأثیر متغیرهای چندگانه بر فرایند، با استفاده از مدل‌های خطی و خطی چندگانه با مشکلاتی همراه است؛ به‌طوریکه این فرایندها قادر به پیش‌بینی روابط بین پدیده‌ها نمی‌باشد.

امروزه از شبکه‌های عصبی در بسیاری از رشته-های مهندسی از جمله شیمی برای بهینه‌سازی، شبیه سازی، پیش بینی و مدل سازی روابط بین پدیده‌ها استفاده می‌شود. شبکه‌های عصبی اولین بار در سال ۱۹۴۳ توسط Culloch و Pitt استفاده شدند [۱۱]. این شبکه‌ها از عناصر عملیاتی ساده ساخته می شوند که به صورت موازی در کنار هم عمل می‌کنند. شبکه عصبی، شبیه سازی از دستگاه عصبی انسان بوده و در واقع، تقلیدی از مغز و شبکه اعصاب انسان می‌باشد [۱۲،۱۳]. در این شبکه، سعی براین است، ساختاری تهیه شود که همانند مغز، قدرت یادگیری، تعمیم‌دهی و تصمیم‌گیری داشته باشد. در این گونه ساختارها هدف این است که با معرفی عملکرد یک سیستم دینامیکی، مدل را آموزش داده، نحوه عملکرد سیستم را در حافظه مدل ذخیره و از آن برای مواردی که قبلاً با آن مواجه نشده است استفاده شود [۱۴]. از مزیت‌های استفاده از شبکه-های عصبی می‌توان به زمان مورد نیاز کمتر برای مدل-سازی نسبت به روش‌های کلاسیک، عدم نیاز به محاسبات ریاضی برای پیش بینی رفتار پارامترهای دخیل در فرایند و همچنین توانایی پیش بینی تعداد محدودی آزمایش اشاره کرد[۱۵،۱۶]. درنتیجه این مطالعه با هدف استفاده از مدل‌های شبکه‌های عصبی برای

[Downloaded from zanko.muk.ac.ir on 2026-11-09]

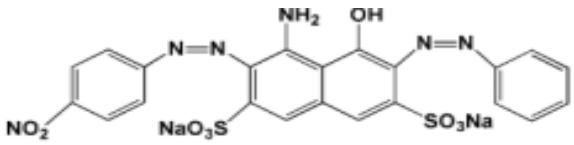
پیش بینی و مدل سازی حذف رنگزای اسید بلاک ۱ با استفاده از فرایند فوتوکاتالیستی نانو کامپوزیت دی-اکسیدتیتانوم - نیکل در حضور نور تابش فرابنفش انجام شد.

روش بررسی

مواد

دی‌اکسید تیتانیوم خالص، اکسید نیکل، N- بوتیل آمین از شرکت مرک آلمان تهیه شدند. رنگدانه اسید بلاک ۱ از شرکت الوند ثابت همدان تهیه شد و بدون خالص‌سازی مورد بررسی قرارگرفت. ساختار شیمیایی و همچنین بعضی خصوصیات دیگر آن در جدول ۱ نشان داده شده است. همچنین برای تشخیص کیفیت نانوذره سنتز شده از دستگاه میکروسکوپ الکترونی روبشی JEM 2000FX II استفاده شد.

جدول ۱: خصوصیات رنگزای اسید بلاک

فرمول مولکولی	$C_{22}H_{14}N_6Na_2O_9S_2$
وزن مولکولی	۶۱۶/۴۹
λ_{max}	۶۱۸
ساختار مولکولی	

سنتز نانوکامپوزیت دی‌اکسید تیتانیوم با اکسید نیکل

برای سنتز نانومواد کاتالیستی، مقدار مشخصی از دی‌اکسید تیتانیوم و اکسید فلزی نیکل با نسبت‌های مختلف (۱/۱، ۱/۲، ۱/۳ دی‌اکسیدتیتانیوم به اکسید نیکل) با هم ترکیب،، سپس حلال مناسب (HCl)، به میزان ۱۰ میلی‌لیتر به آن اضافه شد. در مرحله بعد مقدار ۱ میلی‌لیتر از سورفاکتانت N- بوتیل آمین به محلول اضافه و به مدت سه دقیقه بهم زده شد. پس از اطمینان از اندود بودن کامل، طبق روش هیدروترمال در کوره در دمای ۱۲۰ درجه سانتی‌گراد به مدت ۱۲ ساعت قرار داده شد تا واکنش‌های شیمیایی مورد نظر رخ دهد. پس از طی شدن زمان واکنش مناسب، ترکیب حاصل را با آب ۲ بار تقطیر، چند بار شست‌وشو می‌دهیم تا آلودگی‌های احتمالی و سورفاکتانت برطرف شود؛ سپس در دمای محیط قرار داده شد تا خشک شود. بعد از خشک شدن در دسیکاتور قرار گرفت تا خصوصیات آن تعیین شود .

طراحی آزمایش

در این مطالعه، برای طراحی آزمایشات از روش تاگوچی استفاده شد. گام اول در طراحی آزمایشات به روش تاگوچی، تعیین عوامل مؤثر و سطوح آن‌ها می-باشد؛ در میان عوامل مؤثر بر فرایند حذف رنگدانه، ۳ عامل و برای هر عامل هم، ۵ سطح نوع نانوذره در نظر گرفته شد (جدول۲). برای جلوگیری از بروز خطا و براساس اصول آماری بعد از طراحی آزمایشات ،عمل تصادفی داده‌ها انجام شد.

[Downloaded from zanko.muk.ac.ir on 2026-11-09]

جدول ۲: سطوح متغیرهای انتخاب شده برای طراحی آزمایش توسط روش تاگوچی

متغیر	سطوح متغیر				
	-۲	-۱	۰	۱	۲
غلظت نانوذره (گرم در لیتر)	۰/۵	۱	۱/۵	۲	۲/۵
غلظت رنگزا(میلی گرم در لیتر)	۲۵	۴۰	۶۰	۸۰	۱۰۰
PH	۳	۵	۷	۹	۱۱

روش انجام آزمایش

برای انجام آزمایشات فوتوکاتالیستی، ابتدا محلول مادر اسید بلاک۱ (۱۰۰۰ میلی‌گرم در لیتر) با حل کردن ۱ گرم از رنگدانه در ۱ لیتر آب مقطر تهیه شد. سپس فاکتورهای مؤثر بر انجام فرایندهای مورد مطالعه شامل pH، غلظت رنگزا و دوز نانو کامپوزیت در مراحل جداگانه در طول تحقیق، مطالعه شد. همه آزمایشات در حالت ناپیوسته در بشر به حجم ۲۰۰ میلی لیتر با استفاده از شیکر انجام شد. در هر مرحله بعد از ساخت محلول رنگزا با غلظت‌های ۲۰ تا ۸۰ میلی‌گرم در لیتر از محلول مادر و تنظیم pH بین ۱۱-۳، مقدار مشخصی ازنانوکامپوزیت (۲/۵-۰/۵ گرم در لیتر) به آن اضافه شد و محلول به مدت ۲ساعت در معرض اشعه فرابنفش (Uv)قرار داده شد. طی آزمایشات فوتوکاتالیست در فواصل زمانی مشخص(بازه زمانی۲۰دقیقه)، از محلول ساخته شده نمونه برداری انجام شد. نمونه‌های گرفته شده از محلول در سانتیریفوژ (با دور۲۰۰۰) قرار داده شدند و در نهایت با استفاده از دستگاه اسپکتروفوتومتر(*UV-VIS*) مقدار تخریب رنگدانه در طول موج ۶۱۸ *nm*، خوانده شد. میزان تخریب رنگدانه قبل و پس از افزودن نانو ذره و گذشت زمان مورد نیاز برای رسیدن به تعادل با در نظر گرفتن کلیه شرایط، اندازه‌گیری و بازده حذف مواد رنگدانه (R) با استفاده از معادله (۱) محاسبه شد.

$$R\ (\%) = \frac{A_0 - A}{A_0} \times 100 \qquad (1)$$

که$A0$، تخریب رنگدانه در زمان صفر و At، تخریب رنگدانه پس از گذشت زمان t دقیقه می باشد. در این تحقیق از مقدار حذف مطلق استفاده شد [۱۷].

تدوین مدل

در این تحقیق برای بهینه‌سازی مقدار تخریب رنگدانه توسط نانوکامپوزیت دی‌اکسیدتیتانیوم با اکسید نیکل از مدل شبکه عصبی مصنوعی با ساختار پیش، استفاده شد. در طراحی ساختار مدل با توجه به تعداد متغیرهای ورودی و خروجی، تعداد نورون های لایه ورودی وخروجی به‌ترتیب تعیین شد. سپس برای پارامترهای قابل تنظیم و درنتیجه تعیین بهترین ساختار شبکه عصبی، تعداد زیادی شبکه عصبی با ساختار مختلف طراحی و ارزیابی شد. این شبکه‌های عصبی با تغییر پارامترهای قابل تنظیم (شامل: تابع انتقال ، قانون

[Downloaded from zanko.muk.ac.ir on 2026-11-09]

یادگیری ، مقدار مومنتوم، تعداد لایه میانی، تعداد نورون لایه میانی) ساخته و اجرا شدند. دقت این شبکه‌ها به‌وسیله معیار های آماری محاسبه و در مرحله آزمون بررسی شد و در نهایت شبکه‌ای که نزدیکترین نتیجه را با واقعیت داشت، به‌عنوان شبکه اصلی انتخاب شد.

معیارهای آماری

برای مقایسه مدل‌های مختلف تدوین شده توسط شبکه عصبی مصنوعی از معیارهای آماری ضریب همبستگی و مجذور میانگین مربعات خطا استفاده شد.

$$R=\frac{\Sigma_{i=1}^{n}((y_{obs})_i-(y_{obs}^{-}))\times(y_{est})_i-(y_{est}^{-}))}{\sqrt{\Sigma_{i=1}^{n}((y_{obs})-y_{obs}^{-})^2\Sigma_{i=1}^{N}((y_{est})_i-(y_{est}^{-}))^2}}$$

$$RMSE=\sqrt{\frac{\Sigma_{i=1}^{n}((y_{est})_i-(y_{obs})_i)^2}{n}}$$

y_{obs}:مقادیر مشاهده شده(واقعی)، $\bar{y}_{obs}$: میانگین مقادیر مشاهده شده، y_{est}:مقادیر برآورد شده (خروجی مدل) ، $\bar{y}_{est}$:میانگین مقادیر برآورد شده و n :تعداد خروجی می باشد [۱۸].

داده های ورودی وخروجی مدل

ابتدا داده‌های ورودی که شامل: غلظت رنگزا ، غلظت نانوکامپوزیت ، pHو زمان به صورت ستونی وارد یک پوشه از صفحات گسترده اکسل شد و به‌عنوان داده‌های ورودی[1] برای مدل تعریف شدند. سپس داده‌های مقدار تخریب رنگزا، به‌صورت ستونی وارد پوشه مربوط به آن شد و به‌عنوان داده های خروجی برای مدل تعریف شد.

بعد از مشخص شدن داده های ورودی و خروجی مدل، عمل چیدن تصادفی داده‌ها روی صفحه گسترده انجام شد. داده‌ها به سه قسمت داده‌های آموزش ، اعتبار سنجی و تست تقسیم شدند. ۸۰٪ داده‌ها برای آموزش، ۱۰٪ برای اعتبار سنجی و۱۰٪ داده‌ها برای آزمون درنظرگرفته شدند. همچنین برای کاهش خطاها و افزایش دقت در برآورد وزن های شبکه و مقادیر پیش بینی شده برای هر یک از مراحل آموزش، اعتبار سنجی و تست شبکه، ۱۰ مرتبه تکرار در نظر گرفته شد.

یافته‌ها

الگوریتم‌های آموزش و تابع انتقال قانون آموزش

در این مطالعه، برای تعیین مناسب‌ترین مقدار مومنتوم برای دو تابع انتقال تانژانت هیپربولیک و سیگموئیدی مدل‌های مختلف شبکه عصبی که در آن‌ها مقدار مومنتوم ۰/۱، ۰/۲، ۰/۳ ، ۰/۴ ، ۰/۵ ، ۰/۶ ، ۰/۷ ، ۰/۸ ، ۰/۹ و ۱ در نظر گرفته شد. نتایج نشان داد که توابع انتقال تانژانت هیپربولیک و تابع انتقال سیگموئیدی به ترتیب با مقدار مومنتوم ۱و ۰/۸ در تدوین مدل، عملکرد بهتری داشته است؛همچنین برای انتخاب نوع تابع انتقال و قانون آموزش مناسب، شبکه های عصبی مختلف با تغییر تابع انتقال و قانون آموزش ساخته واجرا شد. نتایج آن در جدول ۳ ارائه شده است. با بررسی جدول ۴ ملاحظه می شود که تابع انتقال سیگموئیدی و قانون آموزش مارکورات، عملکرد بالایی در پیش‌بینی میزان حذف رنگزا توسط فرایند فوتوکاتالیستی را دارا می باشد.

تعداد لایه میانی و تعداد نورون‌های لایه پنهان

در این مطالعه برای یافتن بهترین تعداد لایه پنهان، شبکه‌های عصبی مختلفی با تعداد ۴-۱ ساخته و اجرا شدند. نتایج نشان دادکه شبکه‌ای با یک لایه پنهان،

[Downloaded from zanko.muk.ac.ir on 2026-11-09]

عملکرد بالایی در پیش‌بینی میزان حذف رنگزا دارد. همچنین برای یافتن بهترین تعداد نورون در لایه پنهان شبکه‌عصبی، سعی شد با تعداد کمی نورون (۱۰-۱) که بیشترین عملکرد را برای شبکه فراهم می‌کند، انتخاب شود. نتایج آماری آموزش این شبکه ها درجدول ۷-۴ ارائه شده است ؛همان طوریکه در این جدول مشاهده می‌شود، مدل شبکه عصبی با ۵ نورون در لایه پنهان به عنوان شبکه‌ای با بهترین ساختار معرفی شد.

آزمون مدل

پس از مشخص شدن قانون آموزش، تابع انتقال، تعداد لایه پنهان و تعداد نورون مناسب، لازم است که شبکه ساخته شده ازنظرعملکرد مورد ارزیابی قرار گیرد. همان طوریکه در جدول شماره ۷-۴ مشاهده می شود، پس از آزمون شبکه مشخص شد که شبکه ساخته شده عملکرد بالایی در پیش‌بینی میزان حذف توسط فرایند فوتوکاتالیستی دارد.

بحث و نتیجه گیری

برای تدوین مدل و بدست آوردن بهترین مدل پیش‌بینی کننده حذف رنگزا توسط فرایند فوتوکاتالیستی، ابتدا از قانون‌های آموزش مومنتوم، گرادیان مزدوج و مارکورات استفاده شد. نتایج نشان داد که قانون آموزش مومنتوم با مقدار ۱و تابع انتقال سیگموئیدی در تدوین مدل عملکرد بهتری دارد. همچنین برای انتخاب نوع تابع انتقال و قانون آموزش مناسب، شبکه‌های عصبی مختلف با تغییر تابع انتقال و قانون آموزش ساخته واجرا شدند.

قانون آموزش و تابع انتقالیی که کمترین مقدار جذر میانگین مربعات خطا و ضریب همبستگی بالایی داشته باشد، به‌عنوان قانون و تابع یکینه انتخاب خواهد شد. با بررسی جدول ۳ ملاحظه شد که کمترین مقدار خطا و بیشترین ضریب همبستگی، مربوط به تابع انقال سیگموئیدی و قانون آموزش مارکورات می باشد. به این ترتیب، شبکه‌ای با تابع انقال سیگموئیدی و قانون آموزش مارکورات به‌عنوان شبکه بهینه انتخاب شد. همچنین در مطالعه‌ای که توسط Gheadi و همکاران انجام شد، مشخص شد که شبکه‌ای با قانون آموزش مارکورات و تابع انتقال سیگموئیدی بهتر، توانست میزان حذف رنگزای متیلن بلو و بریلیانت گرین را پیش‌بینی کند [۱۳]. در مطالعه ای دیگر، Kardam و همکاران نشان دادند که شبکه ای با قانون آموزش مارکورات، عملکرد بالایی در مدل‌سازی جذب سرب با استفاده از نانوفیبرهای سلولزی دارد [۱۹].

برای یافتن بهترین تعداد لایه پنهان، شبکه های عصبی مختلفی با تعداد ۴-۱ ساخته و اجراشدند. درآموزش این شبکه‌ها از قانون آموزش مارکورات و تابع انتقال سیگموئیدی که در مرحله قبل انتخاب شده بودند، استفاده شد. باتوجه به نتایج آماری ارائه شده در جدول ۴ملاحظه می‌شود که مدلی با یک لایه پنهان، دقت پیش‌بینی بالایی در حذف رنگزای اسید بلاک۱ دارد. ختایی و همکاران نشان دادند که شبکه‌ای با یک لایه پنهان، بهتر توانست میزان حذف رنگزای بازیک بلو ۳ را با استفاده از فرایند فرابنفش ترکیبی با پراکسید سولفات پیش‌بینی کند که عملکرد بالایی در مدل‌سازی فرایند دارد [۲۰].

یکی از مسائل پر اهمیت و اثرگذار بر عملکرد مدل‌های شبکه‌عصبی، تعداد نورون در لایه مخفی مدل می باشد. در اغلب موارد راهکار عمومی وجامعی برای تعیین تعداد نورون‌ها در لایه مخفی وجود ندارد. چنانچه تعداد نورون‌های لایه مخفی، کم انتخاب شود

[Downloaded from zanko.muk.ac.ir on 2026-11-09]

میزان خطای عمومی مدل افزایش یافته و منجر به ایجاد بایاس قابل توجه و در نتیجه کم‌برازش یافتن مدل می شود؛ همچنین درصورتی که تعداد نورون ها در لایه مخفی از حد مطلوبی بیشتر شود، مقدار خطای آموزش کاهش می‌یابد؛ اما باید در مقابل، در نتیجه بیش برازش شدن مدل ، خطای عمومی و بایاس آماری و واریانس افزایش یابند [۲۱،۲۲].

در این مطالعه، برای یافتن بهترین تعداد نورون در لایه پنهان شبکه عصبی، سعی شد با تعداد کمی نورون (۱۰-۱) که بیشترین عملکرد را برای شبکه فراهم می-کند انتخاب شود. در اجرای این شبکه‌ها از همان داده-های ورودی اولیه با قانون آموزش مارکورات و تابع انتقال سیگموئیدی وهمچنین از یک لایه پنهان که در مراحل قبل انتخاب شده بودند، استفاده شد. نتایج آماری آموزش این شبکه ها در جدول ۵ ارائه شده است؛ همان طوری که در این جدول مشاهده می‌شود، کمترین مقدار خطا و بالاترین ضریب همبستگی مربوط به ۴ نورون در لایه پنهان می باشد. به‌این ترتیب، شبکه‌ای با قانون آموزش مارکورات ، تابع انتقال سیگموئیدی ، یک لایه پنهان و ۵ نورون در لایه پنهان به عنوان شبکه‌ای با بهترین ساختار معرفی شد.

پس از مشخص ساختن قانون آموزش، تابع انتقال، تعداد لایه پنهان و تعداد نورون مناسب، لازم است که شبکه ساخته شده ازنظرعملکرد مورد ارزیابی قرار گیرد. به‌همین‌دلیل از۱۰٪ کل داده‌هایی که قبلاً بطور تصادفی انتخاب و برای آزمون شبکه به کاربرده نشده بودند، برای ارزیابی شبکه استفاده شد و برای مقایسه عملکرد مدل‌های پیشنهادی از شاخص‌های آماری مانند جذر میانگین مربعات خطا (RMSE)، میانگین و ضریب همبستگی (R)استفاده شد. همان طوریکه در جدول ۶ مشاهده می‌شود، پس از آزمون شبکه مشخص شد که شبکه ساخته شده عملکرد بالایی در پیش‌بینی میزان حذف، توسط فرایند فوتوکاتالیستی دارد.

بر اساس نتایج بدست آمده، استنباط می شود که مدل شبکه‌های عصبی، دقت بالایی در پیش بینی حذف رنگزای اسید بلاک ۱ توسط فرایند فوتوکاتالیستی دارند. این ممکن است به دلیل روابط غیر خطی موجود میان شاخص‌های مؤثر برمقدار حذف رنگزا و همچنین به دنبال آن افزایش دقت در پیش بینی حذف توسط مدل شبکه‌های عصبی باشد.

جدول۳: ضریب همبستگی و مجذور مربعات خطا برای داده‌های آموزش و اعتبار سنجی توابع مختلف انتقال با قانون آموزش مومنتوم

تابع انتقال	قانون آموزش	لایه پنهان	تعداد نورون	داده‌های آموزش		داده‌های اعتبار سنجی	
				RMSE	R^2	RMSE	R^2
تانژانت	مومنتوم	۱	۴	۰/۰۴	۰/۹۱	۰/۰ ۸۲۷	۰/۸۸
سیگموئیدی	مومنتوم	۱	۴	۰/۰۱۹۵	۰/۹۳	۰/۰۱۸۱	۰/۹۴۸

[Downloaded from zanko.muk.ac.ir on 2026-11-09]

جدول ٤: مقدار جذر میانگین مربعات ، ضریب همبستگی ، برای داده های آموزش و اعتبار سنجی از تابع مختلف آموزش با توابع مختلف انتقال

تابع انتقال	قانون آموزش	لایه پنهان	تعداد نورون	داده‌های آموزش		داده‌های اعتبار سنجی	
				RMSE	R^2	RMSE	R^2
تانژانت	مومنتوم	۱	۴	۰/۰۲۴	۰/۰۹۲۳	۰/۰۲۲۶	۰/۹۳۱
تانژانت	گرادیان شیب	۱	۴	۰/۰۱۴	۰/۹۴۳	۰/۰۱۳	۰/۹۶
تانژانت	مارکورات	۱	۴	۰/۰۱۲	۰/۹۴۸	۰/۰۰۹۴	۰/۹۶۴
سیگموئیدی	مومنتوم	۱	۴	۰/۰۱۷	۰/۹۵	۰/۰۱۰	۰/۹۶
سیگموئیدی	گرادیان شیب	۱	۴	۰/۰۲۸	۰/۹۲۹	۰/۰۲۱	۰/۹۳
سیگموئیدی	مارکورات	۱	۴	۰/۰۱۶	۰/۹۷	۰/۰۰۴	۰/۹۸

جدول ٥: مقدار جذر میانگین مربعات ، ضریب همبستگی ، برای داده های آموزش و اعتبار سنجی با تابع آموزش مارکورات و تابع انتقال سیگموئیدی برای لایه های مختلف

تابع انتقال	قانون آموزش	لایه پنهان	تعداد نورون	داده‌های آموزش		داده‌های اعتبار سنجی	
				RMSE	R^2	RMSE	R^2
سیگموئیدی	مارکورات	۱	۴	۰/۰۰۷	۰/۹۶۸	۰/۰۰۶۵	۰/۹۷۷
سیگموئیدی	مارکورات	۲	۴	۰/۰۱۶	۰/۹۳	۰/۰۱۵	۰/۹۴۷
سیگموئیدی	مارکورات	۳	۴	۰/۰۲۶	۰/۹۱۹	۰/۰۲۰	۰/۹۲۸
سیگموئیدی	مارکورات	۴	۴	۰/۰۱۲	۰/۹۵۷	۰/۰۰۹	۰/۹۵۷

جدول ٦: مقدار جذر میانگین مربعات، ضریب همبستگی، برای داده‌های آموزش و اعتبار سنجی با تابع آموزش مارکورات و تابع انتقال سیگموئیدی برای نورون های مختلف

تابع انتقال	قانون آموزش	لایه پنهان	تعداد نورون	داده‌های آموزش		داده‌های اعتبار سنجی	
				RMSE	R^2	RMSE	R^2
سیگموئیدی	مارکورات	۱	۴	۰/۰۰۵	۰/۹۷۶	۰/۰۰۳۶	۰/۹۸۷

جدول ۷: ضریب همبستگی و مجذور مربعات خطا برای داده‌های آموزش و تست شبکه در مدل شبکه‌های عصبی مصنوعی

تابع انتقال	قانون آموزش	لایه پنهان	تعداد نورون	داده‌های آموزش		داده‌های اعتبار سنجی		داده‌های تست	
				RMSE	R^2	RMSE	R^2	RMSE	R^2
سیگموئیدی	مارکورات	۱	۴	۰/۰۰۵	۰/۹۷۶	۰/۰۰۳۶	۰/۹۸۷	۰/۰۰۳۱	۰/۹۸۱

[Downloaded from zanko.muk.ac.ir on 2026-11-09]

References

1. Zheng Z, Levin RE, Pinkham JL, Shetty K. Decolorization of polymeric dyes by a novel Penicillium isolate. Process Biochem. 1999; 34: 7-31.
2. Ramakrishna KR, Viraraghavan T. Dye removal using low cost adsorbents. Water Sci Technol. 1997; 36: 96-189.
3. Koprivanac N, Kusic H. Hazardous organic pollutants in colored wastewaters: Nova Science Publishers Hauppauge, 2009.
4. Chowdhury S, Chakraborty S, Saha PD. Removal of crystal violet from aqueous solution by adsorption onto eggshells: Equilibrium, kinetics, thermodynamics and artificial neural network modeling. Waste Biomass Valori. 2013; 4: 64-655.
5. Mahmoodi NM, Hayati B, Arami M, Lan C. Adsorption of textile dyes on< i> Pine Cone</i> from colored wastewater: Kinetic, equilibrium and thermodynamic studies. Desalination. 2011; 268: 117-25.
6. Mahmoodi NM, Arami M, Limaee NY, Gharanjig K. Photocatalytic degradation of agricultural< i> N</i>-heterocyclic organic pollutants using immobilized nanoparticles of titania. J Hazard Mater. 2007;145: 65-71.
7. Karagozoglu B, Tasdemir M, Demirbas E, Kobya M. The adsorption of basic dye (Astrazon Blue FGRL) from aqueous solutions onto sepiolite, fly ash and apricot shell activated carbon: Kinetic and equilibrium studies. J Hazard Mater. 2007; 147: 297-306.
8. Miao J, Jia Z, Lu H-B, Habibi D, Zhang L.C. Heterogeneous photocatalytic degradation of mordant black 11 with ZnO nanoparticles under UV–Vis light. J Taiwan Instit Chem Engin. 2013; 45: 1636-41.
9. Zheng L, Zheng Y, Chen C, Zhan Y, Lin X, Zheng Q, et al. Network structured SnO2/ZnO heterojunction nanocatalyst with high photocatalytic activity. Inorgan Chem. 2009; 48: 819-25.
10. Kaur J, Bansal S, Singhal S. Photocatalytic degradation of methyl orange using ZnO nanopowders synthesized via thermal decomposition of oxalate precursor method. Physica B: Condensed Matter. 2013; 416: 8-33.
11. Aleboyeh A, Kasiri M, Olya M, Aleboyeh H. Prediction of azo dye decolorization by UV/H using artificial neural networks. Dyes Pigmen. 2008; 77: 94-288.
12. Karimi H, Ghaedi M. Application of artificial neural network and genetic algorithm to modeling and optimization of removal of methylene blue using activated carbon. J Ind Engin Chem. 2014; 20: 2471-6.
13. Ghaedi M, Zeinali N, Ghaedi A, Teimuori M, Tashkhourian J. Artificial neural network-genetic algorithm based optimization for the adsorption of methylene blue and brilliant green from aqueous solution by graphite oxide nanoparticle. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2014;125: 77-264.
14. Mehrotra K, Mohan C.K, Ranka S. Elements of artificial neural networks: MIT press, 1997.
15. Geyikçi F, Çoruh S, Kılıç E. Development of experimental results by artificial neural network model for adsorption of Cu^{2+} using single wall carbon nanotubes. Separa Sci Technol. 2013; 48: 9-1490.
16. Ghaedi M, Ansari A, Assefi Nejad P, Ghaedi A, Vafaei A, Habibi MH. Artificial neural network and bees algorithm for removal of Eosin B using cobalt oxide nanoparticle-activated carbon: Isotherm and Kinetics study. Environ Prog Sustainable Energ. 2014; doi: 10.1002/ep.11981

[Downloaded from zanko.muk.ac.ir on 2026-11-09]

17. Chakrabarti S, Dutta B.K. Photocatalytic degradation of model textile dyes in wastewater using ZnO as semiconductor catalyst. Journal of hazardous materials, 2004;112(3): 78-269.
18. Nourbakhsh H, Emam-Djomeh Z, Omid M, Mirsaeedghazi H, Moini S. Prediction of red plum juice permeate flux during membrane processing with ANN optimized using RSM. Comput Electron Agri. 2014; 20: 102:1-9.
19. Kardam A, Raj KR, Arora JK, Srivastava S. Artificial neural network modeling for biosorption of Pb (II) ions on nanocellulose fibers. bionanosci. 2012; 2: 60-153.
20. Khataee A, Movafeghi A, Torbati S, Salehi Lisar S, Zarei M. Phytoremediation potential of duckweed (*Lemna minor L.*) in degradation of CI Acid Blue 92: Artificial neural network modeling. Ecotoxicol Environ Safet. 2012; 80: 8-291.
21. Jin W, Li ZJ, Wei LS, Zhen H. The improvements of BP neural network learning algorithm. Signal Processing Proceedings, 2000 WCCC-ICSP 2000 5th International Conference on; 2000: IEEE.
22. Chen AS, Leung MT, Daouk H. Application of neural networks to an emerging financial market: forecasting and trading the Taiwan Stock Index. Computers & Operations Research, 2003; 30: 23-901.

[Downloaded from zanko.muk.ac.ir on 2026-11-09]

Application of artificial neural network to modeling and optimization of removal of acid black1 using TiO_2-Ni nanocoposite

Kamal Salehi[1], Behzad Shahmoradi[2], Afshin Maleki[3], Borhan Mansouri[4], Fardin Gharibi[5]

1- Department of Environmental Health Engineering, School of Health, Kurdistan University of Medical Sciences, Sanandaj, Iran; E-mail: kamalsalehi1366@gmail.com; Mobile: 09192008133
2- Kurdistan Environmental Health Research Center, Kurdistan University of Medical Sciences, Sanandaj, Iran
3- Kurdistan Environmental Health Research Center, Kurdistan University of Medical Sciences, Sanandaj, Iran.
4- Kurdistan Environmental Health Research Center, Kurdistan University of Medical Sciences, Sanandaj, Iran
5- Deputy of Research, Kurdistan University of Medical Sciences, Sanandaj, Iran

ABSTRACT

Background and Aim: Artificial Neural Network is non-liner mapping structure based on the function of the human brain. They are powerful tools for modelling, especially when the underlying data relationship is known. So, the aim of this study was the used of artificial neural network to modelling and optimization of removal of acid black1 using TiO_2-Ni nanocoposite.

Material and Methods: This study was an applied research in which TiO_2-Ni nanocoposite was synthesized and its chemical properties was evaluated by SEM. For experiments design, predicting, and modeling dye removal were used taguchi method, Artifial Nerual Network (ANNs).

Result: The results showed that network with tan sigmoid transfer functions, Levenberg –Marquardt algorithm, one hidden layer and four neuron in hidden layer estimated better removal dye of acid black1.

Conclusion: It is concluded that ANN model can estimate the behavior of the photocatalyst process under different experimental conditions.

Keyword: Acid Black 1, Artificial Neural Network, TiO_2-Ni Nanocoposite.

[Downloaded from zanko.muk.ac.ir on 2026-11-09]