

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

**کمال صالحی<sup>۱</sup>، بهزاد شاهمرادی<sup>۲</sup>، افشین ملکی<sup>۳</sup>، برهان منصوری<sup>۴</sup>، فردین غریبی<sup>۵</sup>**

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

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

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

### چکیده

**زمینه و هدف:** شبکه های عصبی مصنوعی، ساختاری غیر خطی بوده که عملکرد آنها بر مبنای مغز انسان می باشد. این شبکه ها ابزاری قوی برای مدل سازی، خصوصاً برای زمانی که ارتباط بین داده ها نامعلوم باشد، می باشند. بنابراین هدف این مطالعه استفاده از شبکه های عصبی مصنوعی برای مدل سازی و بهینه سازی حذف رنگزای اسید بلاک ۱ از محلول های آبی با استفاده از نانو کامپوزیت  $TiO_2-Ni$  می باشد.

**روش بودرسی:** این تحقیق، یک مطالعه کاربردی- توسعه ای است که طی آن نانو کامپوزیت  $TiO_2-Ni$  سنتز و خصوصیات شیمیایی آن توسط تصویر میکروسکوپ الکترونی ارزیابی شد. برای طراحی آزمایشات، پیش بینی و مدل سازی حذف رنگدانه، به ترتیب از روش تاگوچیو شبکه های عصبی مصنوعی استفاده شد.

**یافته ها:** نتایج نشان داد که شبکه با تابع انتقال سی گموئیدی، الگوریتم آموزش مارکورات، یک لایه پنهان و ۵ نورون در لایه پنهان، بهتر می تواند میزان حذف رنگزای اسید بلاک ۱ را پیش بینی کند.

**بحث و نتیجه گیری:** با توجه به نتایج بدست آمده، نتیجه می گیریم که مدل شبکه های عصبی می تواند رفتار فرایند فوتوكاتالیستی را در شرایط مختلف آزمایشگاهی پیش بینی کند.

**واژه های کلیدی:** اسید بلاک ۱، شبکه های عصبی مصنوعی، نانو کامپوزیت  $TiO_2-Ni$

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؛ به طوریکه این فرایندها قادر به پیش‌بینی روابط بین پدیده‌ها نمی‌باشد. امروزه از شبکه‌های عصبی در بسیاری از رشته‌های مهندسی از جمله شیمی برای بهینه‌سازی، شبیه‌سازی، پیش‌بینی و مدل‌سازی روابط بین پدیده‌ها استفاده می‌شود. شبکه‌های عصبی اولین بار در سال ۱۹۴۳ توسط Pitt و Culloch استفاده شدند<sup>(۱)</sup>. این شبکه‌ها از عناصر عملیاتی ساده ساخته می‌شوند که به صورت موازی در کنار هم عمل می‌کنند. شبکه عصبی، شبیه‌سازی از دستگاه عصبی انسان بوده و در واقع، تقليدی از مغز و شبکه اعصاب انسان می‌باشد<sup>(۱۲،۱۳)</sup>. در این شبکه، سعی براین است، ساختاری تهیه شود که همانند مغز، قدرت یادگیری، تعیین‌دهی و تصمیم‌گیری داشته باشد. در این گونه ساختارها هدف این است که با معرفی عملکرد یک سیستم دینامیکی، مدل را آموختش داده، نحوه عملکرد سیستم را در حافظه مدل ذخیره و از آن برای مواردی که قبلًا با آن مواجه نشده است استفاده شود<sup>(۱۴)</sup>. از مزیت‌های استفاده از شبکه‌های عصبی می‌توان به زمان مورد نیاز کمتر برای مدل‌سازی نسبت به روش‌های کلاسیک، عدم نیاز به محاسبات ریاضی برای پیش‌بینی رفتار پارامترهای دخیل در فرایند و همچنین توانایی پیش‌بینی تعداد محدودی آزمایش اشاره کرد<sup>(۱۵،۱۶)</sup>. درنتجه این مطالعه با هدف استفاده از مدل‌های شبکه‌های عصبی برای

## مقدمه

رنگزهای آلی مصنوعی، یکی از مهم‌ترین آلاندهای فاضلاب‌های صنایعی همچون: نساجی، چرم سازی، رنگرزی، پلاستیک‌سازی و سایل آرایشی، کاغذ سازی، صنایع رنگ سازی و غذایی است<sup>(۱)</sup>. سالانه بیش از  $7 \times 10^5$  تن در ۱۰۰۰۰ نوع رنگزهای مصنوعی آلی در سراسر جهان تولید می‌شوند. تحقیقات نشان دادند که حدود 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 رنگزهای نور برخورداری به سطح آب را جذب و منعکس<sup>(۲-۴)</sup> 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<sup>(۵,۶)</sup>.

روش‌های متعدد فیزیکی، شیمیایی و بیولوژیکی به منظور حذف رنگزهای از پساب‌های نساجی بکار می‌روند. روش‌های تجزیک بیولوژیکی، به‌دلیل سمی بودن زیاد اغلب رنگزهای، برای میکرووارگانیسم‌های موجود در فرایند و مقاوم بودن رنگزهای در برابر تجزیکی بیولوژیکی بازده پایینی در تجزیک رنگ دارند<sup>(۷)</sup>.

یکی دیگر از روش‌هایی که در چند سال اخیر توجه بسیاری از محققان را به خود جلب کرده است، اکسیداسیون پیشرفته می‌باشد. فرایندهای اکسیداسیون پیشرفته بر پاییک تولید رادیکال‌های آزاد هیدروکسیل با قدرت اکسیداسون بالا بوده که سبب تبدیل آلاندهای آلی به مواد معدنی (دی‌اکسیدکربن و آب) می‌شود<sup>(۸-۱۰)</sup> که بیشترین کارایی را در اکسیداسون ترکیبات مقاوم

بلاک ۱ از شرکت الوند ثابت همدان تهیه شد و بدون خالص سازی مورد بررسی قرار گرفت. 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.

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

### روش بررسی مواد

دی اکسید تیتانیوم خالص، اکسید نیکل، N-بوتیل آمین از شرکت مرک آلمان تهیه شدند. رنگدانه اسید

جدول ۱: خصوصیات رنگزای اسید بلاک

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

آلودگی‌های احتمالی و سورفاکtant 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 (جدول ۲). برای جلوگیری از بروز خطأ و براساس اصول آماری بعد از طراحی آزمایشات، عمل تصادفی داده‌ها انجام شد.

سنتز نانو کامپوزیت دی اکسید تیتانیوم با اکسید نیکل برای سنتز نانومواد کاتالیستی، مقدار مشخصی از دی اکسید تیتانیوم و اکسید فلزی نیکل با نسبت‌های مختلف (۱/۱، ۱/۲، ۱/۳) دی اکسید تیتانیوم به اکسید نیکل (با هم ترکیب)، سپس حلal مناسب (HCl)، به میزان ۱۰ میلی لیتر به آن اضافه شد. در مرحله بعد مقدار ۱ میلی لیتر از سورفاکtant 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 سانتی گراد 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 شست و شو می‌دهیم تا

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

شد. میزان تخریب رنگدانه قبل و پس از افزودن نانوذره 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.

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

که  $A_0$  تخریب رنگدانه در زمان صفر و  $A_t$  تخریب رنگدانه پس از گذشت زمان  $t$  دقیقه می‌باشد. در این تحقیق از مقدار حذف مطلق استفاده شد<sup>(۱۷)</sup>.

#### تدوین مدل

در این تحقیق برای بهینه‌سازی مقدار تخریب رنگدانه توسط نانو کامپوزیت دی‌اکسید تیتانیوم 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 نورون‌های لایه ورودی و خروجی به ترتیب 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

#### روش انجام آزمایش

برای انجام آزمایشات فوتوکاتالیستی، ابتدا محلول مادر اسید بلاک ۱ (۱۰۰۰ میلی گرم 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 میلی گرم در لیتر از محلول مادر و تنظیم pH بین ۱۱-۳، مقدار مشخصی از نانو کامپوزیت (۰/۵-۲/۵ گرم در لیتر) به آن اضافه شد و محلول به مدت ۲ ساعت در معرض اشعه فرابنفش (UV) قرار داده شد. طی آزمایشات فوتوکاتالیست در فواصل زمانی مشخص (بازه زمانی ۲۰ دقیقه)، از محلول ساخته شده نمونه برداری انجام شد. نمونه‌های گرفته شده از محلول در سانتیریفوژ (با دور ۲۰۰۰ قرار داده شدند و در نهایت با استفاده از دستگاه اسپکتروفوتومتر (UV-VIS) مقدار تخریب رنگدانه در طول موج ۶۱۸ nm، خوانده

بعد از مشخص شدن داده های ورودی و خروجی مدل، عمل چیدن تصادفی داده ها روی صفحه گستردۀ انجام شد. داده ها به سه قسمت داده های آموزش، اعتبار سنجی و تست تقسیم شدند. ۸۰٪ داده ها برای آموزش، ۱۰٪ برای اعتبار سنجی و ۱۰٪ داده ها برای آزمون در نظر گرفته شدند. همچنین برای کاهش خطاهای 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.

### یافته ها

**الگوریتم های آموزش و تابع انتقال قانون آموزش** در این مطالعه، برای تعیین مناسب ترین مقدار مومنتوم برای دو تابع انتقال تائزانت هیبروبولیک و سیگموئیدی مدل های مختلف شبکه عصبی که در آن ها مقدار مومنتوم ۰/۱، ۰/۳، ۰/۲، ۰/۴، ۰/۵، ۰/۶، ۰/۷، ۰/۸، ۰/۹ و ۰/۰ در نظر گرفته شد. نتایج نشان داد که توابع انتقال تائزانت هیبروبولیک و تابع انتقال سیگموئیدی به ترتیب با مقدار مومنتوم ۰/۱ و 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 و اجرا 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 پیش بینی میزان حذف رنگزا توسط فرایند فتو کاتالیستی را دارا می باشد.

### تعداد لایه میانی و تعداد نورون های لایه پنهان

در این مطالعه برای یافتن بهترین تعداد لایه پنهان، شبکه های عصبی مختلفی با تعداد ۱-۴ ساخته و اجرا شدند. نتایج نشان داد که شبکه ای با یک لایه پنهان،

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

### معیارهای آماری

برای مقایسه مدل های مختلف تدوین شده توسط شبکه عصبی مصنوعی از معیارهای آماری ضریب همبستگی و مجازور میانگین مربعات خطای استفاده شد.

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

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

$y_{obs}$ : مقادیر مشاهده شده (واقعی)،  $y_{est}$ : مقادیر مشاهده شده،  $y_{est}^-$ : مقادیر برآورد شده (خروچی مدل)،  $n$ : میانگین مقادیر برآورد شده و تعداد خروچی می باشد <sup>(۱۸)</sup>.

### داده های ورودی و خروجی مدل

ابتدا داده های ورودی که شامل: غلظت رنگرا، غلظت نانو کامپوزیت، pH و زمان به صورت ستونی وارد یک پوشۀ از صفحات گستردۀ اکسل شد و به عنوان داده های ورودی<sup>۱</sup> برای مدل تعریف شدند. سپس داده های مقدار تحریب رنگزا، به صورت ستونی وارد پوشۀ مربوط به آن شد و به عنوان داده های خروچی برای مدل تعریف شد.

شد. با بررسی جدول ۳ ملاحظه شد که کمترین مقدار خطأ و بیشترین ضریب همبستگی، مربوط به تابع انتقال سیگموئیدی و قانون آموزش مارکورات می باشد. به این ترتیب، شبکه‌ای با تابع انتقال سیگموئیدی و قانون آموزش مارکورات به عنوان 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<sup>(۱۳)</sup>. در مطالعه‌ای دیگر، Kardam و همکاران نشان دادند که شبکه‌ای با قانون آموزش مارکورات، عملکرد بالایی در مدل‌سازی جذب سرب با استفاده از نانوفیرهای سلولزی دارد<sup>(۱۴)</sup>.

برای یافتن بهترین تعداد لایه پنهان، شبکه‌های عصبی مختلفی با تعداد ۱-۴ ساخته و اجرا شدند. در آموزش این شبکه‌ها از قانون آموزش مارکورات و تابع انتقال سیگموئیدی که در مرحله قبل انتخاب شده بودند، استفاده شد. با توجه به نتایج آماری ارائه شده در جدول ۴ ملاحظه می‌شود که مدلی با یک لایه پنهان، دقت پیش‌بینی بالایی در حذف رنگزای اسید بلاک ۱ 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 فرابینش ترکیبی با پراکسید سولفات پیش‌بینی کند که عملکرد بالایی در مدل‌سازی فرایند دارد<sup>(۲۰)</sup>.

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

عملکرد بالایی در پیش‌بینی میزان حذف رنگزا دارد. همچنین برای یافتن بهترین تعداد نورون در لایه پنهان شبکه‌های عصبی، سعی شد با تعداد کمی نورون (۱-۱۰) که بیشترین عملکرد را برای شبکه فراهم می‌کند، انتخاب شود. نتایج آماری آموزش این شبکه‌ها در جدول ۴-۷ 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 از نظر عملکرد مورد ارزیابی قرار گیرد. همان طوریکه در جدول شماره ۴-۷ مشاهده می‌شود، پس از آزمون شبکه مشخص شد که شبکه ساخته شده عملکرد بالایی در پیش‌بینی میزان حذف توسط فرایند فوتوكاتالیستی دارد.

### بحث و نتیجه گیری

برای تدوین مدل و بدست آوردن بهترین مدل پیش‌بینی کننده حذف رنگزا توسط فرایند فوتوكاتالیستی، ابتدا از قانون‌های آموزش مومنتوم، گرادیان مزدوج و مارکورات استفاده شد. نتایج نشان داد که قانون آموزش مومنتوم با مقدار او 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 و اجرا شدند.

قانون آموزش و تابع انتقالی که کمترین مقدار جذر میانگین مربعات خطأ و ضریب همبستگی بالای داشته باشد، به عنوان قانون و تابع یکینه انتخاب خواهد

پس از مشخص ساختن قانون آموزش، تابع انتقال، تعداد لایه پنهان و تعداد نورون مناسب، لازم است که شبکه ساخته شده از نظر عملکرد مورد ارزیابی قرار گیرد. به همین دلیل از ۱۰٪ کل داده‌هایی که قبلًاً 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 می‌شود که مدل شبکه‌های عصبی، دقت بالایی در پیش‌بینی حذف رنگزای اسید بلاک ۱ توسط فرایند فوتوکاتالیستی دارند. این ممکن است به دلیل روابط غیر خطی موجود میان شاخص‌های مؤثر بر مقدار حذف رنگزا و همچنین به دنبال آن افزایش دقت در پیش‌بینی حذف توسط مدل شبکه‌های عصبی باشد.

میزان خطای عمومی مدل افزایش یافته و منجر به ایجاد بایاس قبل توجه و در نتیجه کم برآش یافتن مدل می‌شود؛ همچنین در صورتی که تعداد نورون‌ها در لایه مخفی از حد مطلوبی بیشتر شود، مقدار خطای آموزش کاهش می‌یابد؛ اما باید در مقابل، در نتیجه بیش برآش شدن مدل، خطای عمومی و بایاس آماری و واریانس افزایش یابند<sup>(۲۱، ۲۲)</sup>.

در این مطالعه، برای یافتن بهترین تعداد نورون در لایه پنهان شبکه عصبی، سعی شد با تعداد کمی نورون (۱-۱۰) که بیشترین عملکرد را برای شبکه فراهم می‌کند انتخاب شود. در اجرای این شبکه‌ها از همان داده‌های ورودی اولیه با قانون آموزش مارکورات و تابع انتقال سیگموئیدی و همچنین از یک لایه پنهان که در مراحل قبل انتخاب شده بودند، استفاده شد. نتایج آماری آموزش این شبکه‌ها 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 می‌باشد. به این 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.

**جدول ۳: ضریب همبستگی و مجدد مریعات خطا برای داده‌های آموزش و اعتبار سنجی توابع مختلف انتقال با قانون آموزش مومنتوم**

داده‌های اعتبار سنجی		داده‌های آموزش		تعداد نورون		لایه پنهان	قانون آموزش	تابع انتقال
R <sup>2</sup>	RMS E	R <sup>2</sup>	RMSE					
۰/۸۸	۰/۰ ۸۲۷	۰/۹۱	۰/۰۴	۴		۱	مومنتوم	تائزانت
۰/۹۴۸	۰/۰ ۱۸۱	۰/۹۳	۰/۰۱۹۵	۴		۱	مومنتوم	سیگموئیدی

**جدول ۴: مقدار جذر میانگین مربعات، ضریب همبستگی، برای داده های آموزش و اعتبار سنجی از قابع مختلف آموزش با توابع مختلف انتقال**

داده های اعتبار سنجی		داده های آموزش		تعداد نورون		لایه پنهان		قانون آموزش		تابع انتقال
R <sup>2</sup>	RMS E	R <sup>2</sup>	RMSE							
۰/۹۳۱	۰/۰۲۲۶	۰/۰۹۲۳	۰/۰۰۲۴	۴		۱		مومنتوم		تائزانت
۰/۹۶	۰/۰۱۳	۰/۹۴۳	۰/۰۱۴	۴		۱		گرادیان شبی		تائزانت
۰/۹۶۴	۰/۰۰۹۴	۰/۹۴۸	۰/۰۱۲	۴		۱		مارکورات		تائزانت
۰/۹۶	۰/۰۱۰	۰/۹۵	۰/۰۱۷	۴		۱		مومنتوم		سیگموئیدی
۰/۹۳	۰/۰۲۱	۰/۹۲۹	۰/۰۲۸	۴		۱		گرادیان شبی		سیگموئیدی
۰/۹۸	۰/۰۰۴	۰/۹۷	۰/۰۱۶	۴		۱		مارکورات		سیگموئیدی

**جدول ۵: 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**

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

**جدول ۶: مقدار جذر میانگین مربعات، ضریب همبستگی، برای داده های آموزش و اعتبار سنجی با تابع آموزش مارکورات و تابع انتقال سیگموئیدی برای نورون های مختلف**

داده های اعتبار سنجی		داده های آموزش		تعداد نورون		لایه پنهان		قانون آموزش		تابع انتقال
R <sup>2</sup>	RMS E	R <sup>2</sup>	RMSE							
۰/۹۸۷	۰/۰۰۳۶	۰/۹۷۶	۰/۰۰۵	۴		۱		مارکورات		سیگموئیدی

**جدول ۷: ضریب همبستگی و مجذور مربعات خطای داده های آموزش و تست شبکه در مدل شبکه های عصبی مصنوعی**

داده های تست		داده های اعتبار سنجی		داده های آموزش		داده های آموزش		تعداد نورون		لایه پنهان		قانون آموزش		تابع انتقال
R <sup>2</sup>	RM SE	R <sup>2</sup>	RMS E	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE							
۰/۹۸۱	۰/۰۰۳۱	۰/۹۸۷	۰/۰۰۳۶	۰/۹۷۶	۰/۰۰۵	۰/۰۰۵	۰/۰۰۵	۴		۱		مارکورات		سیگموئیدی

## 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 Valor.* 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, Limae 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 SnO<sub>2</sub>/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<sup>2+</sup> using single wall carbon nanotubes. *Separation 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

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, Mirsaedghazi 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 5<sup>th</sup> 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.

## Application of artificial neural network to modeling and optimization of removal of acid black1 using TiO<sub>2</sub>-Ni nanocomposite

**Kamal Salehi<sup>1</sup>, Behzad Shahmoradi<sup>2</sup>, Afshin Maleki<sup>3</sup>, Borhan Mansouri<sup>4</sup>, Fardin Gharibi<sup>5</sup>**

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<sub>2</sub>-Ni nanocomposite.

**Material and Methods:** This study was an applied research in which TiO<sub>2</sub>-Ni nanocomposite was synthesized and its chemical properties was evaluated by SEM. For experiments design, predicting, and modeling dye removal were used taguchi method, Artificial 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<sub>2</sub>-Ni Nanocomposite.