

Dor: [20.1001.1.20089597.1400.12.24.17.9](https://doi.org/10.1001.1.20089597.1400.12.24.17.9)

بررسی طبقه‌بندی تغییر رنگ برگ گیاه پونه در اثر جذب فلزات سنگین به روش شبکه عصبی مصنوعی (ANN) و پردازش تصویر

محمد مهدی تیرانداز^۱، حکمت ربانی^{۲*}، اسماعیل میرزایی قلعه^۳، محمود خرمی وفا^۴، فرشاد وصالی^۵

۱. کارشناسی ارشد، گروه مهندسی مکانیک بیوسیستم، دانشگاه رازی، کرمانشاه، ایران
۲. دانشیار، گروه مهندسی مکانیک بیوسیستم، دانشگاه رازی، کرمانشاه، ایران
۳. استادیار، گروه مهندسی مکانیک بیوسیستم، دانشگاه رازی، کرمانشاه، ایران
۴. استادیار، گروه مهندسی تولید و ژنتیک گیاهی، دانشگاه رازی، کرمانشاه، ایران
۵. دکتری مهندسی مکانیک بیوسیستم، دانشگاه رازی، کرمانشاه، ایران

(تاریخ دریافت: ۱۴۰۰/۰۵/۲۰؛ تاریخ تصویب: ۱۴۰۰/۰۷/۰۷)

چکیده

روش‌های مختلفی برای حذف و تشخیص فلزات سنگین موجود در محیط‌زیست پیشنهاد شده که اکثر آن‌ها زمان‌بر و پرهزینه می‌باشند. در این میان گیاه پالایی زمان و هزینه کمتری نسبت به سایر روش‌ها برای حذف فلزات سنگین از محیط، نیاز دارد. در تحقیق حاضر به منظور تعیین آلودگی گیاه پونه به سه فلز سنگین سرب، نیکل و کادمیوم از روش پردازش تصویر به کمک تلفن همراه هوشمند استفاده شد. تعداد سی عدد از این گیاه در سی گلدان در پرلیت کاشته شد. به مدت ۲۸ روز، هر روز از این گیاهان به دو حالت تصویربرداری در داخل جعبه و تصویربرداری تماسی به کمک گوشی تلفن همراه عکس‌برداری شد. برای عملیات پردازش تصویر و شبکه‌ی عصبی مصنوعی از محیط برنامه‌نویسی نرم‌افزار متلب R2017b استفاده شد. برای تعیین ساختار شبکه عصبی مصنوعی تعداد ۱۲ نورون شامل (قرمز، سبز و آبی از فضای رنگی RGB، هیو، اشباع و روشنایی از فضای HSB، درخشندگی، کرومای آبی و کرومای قرمز از فضای رنگی YCbCr و روشنی، قرمز/سبز و زرد/آبی از فضای رنگ $L^*a^*b^*$) به عنوان لایه ورودی و برای لایه خروجی یک بار ۴ نورون شامل (سرب، نیکل، کادمیوم و شاهد) بار دیگر ۲ نورون (شامل آلوده به فلز سنگین و شاهد) در هر دو نوع تصویربرداری جعبه و تماسی در نظر گرفته شدند و بهترین شبکه شناسایی و ماتریس اغتشاش به دست آورده شد.

کلید واژه‌ها: پونه، گیاه پالایی، آلاینده‌ها، فلزات سنگین، هیدروپونیک، پردازش تصویر، شبکه عصبی مصنوعی

سرآغاز

فلزات سنگین یکی از عمده‌ترین آلاینده‌های محیط‌زیست هستند (Di Natale et al., 2006) که در تمام نقاط جوامع صنعتی یافت می‌شوند (Lasat, 2002). پایداری فلزات سنگین در محیط‌زیست، مشکلات زیادی را به وجود آورده است. یکی از نتایج مهم پایداری آن‌ها، تجمع‌زیستی در طول زنجیره غذایی است. فلزات سنگین به طور طبیعی از اجزای تشکیل‌دهنده‌ی پوسته‌ی زمین هستند ولی فعالیت‌های انسانی به صورت قابل توجهی، چرخه‌ی ژئوشیمیایی و توازن بیوشیمیایی آن‌ها را تغییر می‌دهد (Giachetti & Sebastiani, 2006). در نتیجه ممکن است منجر به ورود غلظت بسیار بالایی از فلزات سنگین به محیط، گاه ۱۰۰ تا ۱۰۰۰ برابر بالاتر از آن چه در پوسته‌ی زمین است، شود و به لحاظ زیستی اگر در دسترس‌پذیر باشند، موجودات زنده در معرض سطوح بالایی از آلودگی قرار خواهند گرفت (Carral et al., 1995). فلزات سنگینی مانند سرب، نیکل و کادمیوم در صورتی که با غلظت بالا در تماس با انسان قرار گیرند می‌توانند موجب مسمومیت شوند. همچنین ممکن است فعالیت گیاهان را در مراحل مختلف رشد به شدت تحت تاثیر قرار دهند (Walker & Connolly, 2008).

استفاده از موجودات زنده مانند میکرو ارگانیسم‌ها و گیاهان به عنوان راهکارهای زیستی موثر در حذف فلزات سنگین از محیط با کم‌ترین هزینه از لحاظ اقتصادی مورد توجه بسیاری قرار گرفته است که به این روش زیست‌پالایی گفته می‌شود. چنانچه از گیاهان برای پاک‌سازی محیط استفاده شود، به آن گیاه پالایی می‌گویند (Chaney et al., 1997) تا کنون از گونه‌های مختلف گیاهان برای پاک‌سازی آلودگی‌های فلزات سنگین و آلودگی‌های حاصل از ترکیبات آلی همچون حشره‌کش‌ها، مواد منفجره و روغن‌ها استفاده شده است. گیاهان از گسترش آلودگی به نقاط دیگر توسط باد، باران و آب‌های زیرزمینی جلوگیری می‌کنند (Vara Prasad & Freitas, 2003; Macek et al., 2004).

پردازش تصویر دیجیتال، روشی غیر مخرب است که با به کارگیری تجهیزات موجود برای جمع‌آوری تصویر مانند دوربین، کامپیوتر، اسکنر و برنامه‌های تجزیه و تحلیل تصاویر می‌تواند تصاویر را ضبط و پردازش نموده و به تجزیه و تحلیل اطلاعات مستخرج از تصاویر بپردازد (Patil & Bodhe, 2011). شبکه‌های عصبی مصنوعی (ANN) یکی از پویاترین زمینه

های تحقیق در تاریخ معاصر است که افراد زیادی را از حوزه‌های مختلف علمی جذب کرده است (Beale & Jackson, 1990). ساختار ANN یک مدل محاسباتی است که سیستم‌های عصبی مرکزی در انسان (به خصوص مغز) را شبیه‌سازی می‌کند. این شبکه‌ها از مجموعه‌ای از نورون‌ها (یا عناصر پردازشی) با اتصالات داخلی بین یکدیگر تشکیل شده‌اند. نورون‌ها با توابع انتقال می‌توانند مقادیر ورودی را محاسبه کرده و آن‌ها را به هر یک از نورون‌ها در توابع دیگر بخورانند. یک ANN می‌تواند از مثال‌ها یاد بگیرد. یادگیری ANN هنگامی اتفاق می‌افتد که وزن‌های ارتباطی بین لایه‌ها تغییر می‌کنند به طوری که تفاوت بین مقادیر پیش‌بینی شده و مقادیر واقعی قابل قبول است. این وزن‌ها بیانگر حافظه و دانش شبکه هستند. شبکه‌های عصبی در بسیاری از زمینه‌های علوم مهندسی و صنایع غذایی مورد استفاده قرار می‌گیرند (Mohialden et al., 2019; Sick, 2002).

(Hong et al., 2019) در پژوهشی به تخمین غلظت سرب و روی در خاک‌های کشاورزی اطراف شهری با استفاده از طیف سنجی پرداختند. فلزات سنگین را می‌توان با طیف سنجی مادون قرمز مرئی به همراه مدل‌های شیمیایی نظارت کرد. آن‌ها یک الگوریتم مشتق مرتبه کسری (FOD) برای پردازش طیف بازتاب را پیشنهاد کردند. غلظت طیف بازتاب و سرب روی نمونه‌ها در آزمایشگاه به دست آمد. برای برقراری ارتباط بین داده‌های طیفی و دو فلز سنگین از دو روش کالیبراسیون یعنی رگرسیون حداقل مربعات جزئی و جنگل تصادفی (RF) استفاده شد. به طور کلی، بازتاب طیفی با افزایش محتوای سرب و روی کاهش یافت. به طور خلاصه، نتایج آن‌ها مبانی نظری را برای بررسی سریع مناطق آلودگی سرب و روی در خاک‌های کشاورزی پیرامون شهر را فراهم کرده است.

(Issac et al., 2019) یک مطالعه اولیه مبتنی بر بینایی رایانه‌ای برای شناسایی ماهی چنا پونکتاتوس^(۱) در معرض فلز سنگین (جیوه) انجام دادند. شناسایی بقایای فلزات سنگین در نمونه‌های ماهی یک کار چالش برانگیز است و ممکن است نیاز به ابزار و آزمایشات پرخرج و پیچیده داشته باشد. آن‌ها در این پژوهش تغییرات بصری که می‌تواند معیار تمایز بین ماهی‌های پرورش یافته در آب تازه و آن‌هایی که در معرض آب‌های آلوده به فلزات سنگین بودند بررسی کردند. روش پیشنهادی آن‌ها یک روش مبتنی بر پردازش تصویر، غیر مخرب و خودکار بود. چشم

می‌کند. این مطالعه می‌تواند الهام بخش سایر محققان برای تحقیق بر روی موضوع‌های مشابه و به ثمر رساندن موفقیت آمیز آن‌ها باشد.

مواد و روش‌ها

این آزمایش در بهار سال ۱۳۹۷ در آزمایشگاه تحقیقاتی مکانیک بیوسیستم واقع در پردیس کشاورزی و منابع طبیعی دانشگاه رازی کرمانشاه به صورت هیدروپونیک انجام شد. برای انجام آزمایش از ۳۰ گلدان با اندازه یکسان (اندازه ۱۴) استفاده شد (۳) بلوک در هر بلوک ۳ سطح سرب، ۳ سطح نیکل، ۳ سطح کادمیوم و یک شاهد). برای ثابت و راست نگه داشتن ساقه گیاه پونه در داخل گلدان و فراهم آوردن محیطی برای رشد و تغذیه ریشه‌ها گلدان‌ها از پرلیت استفاده شد. از هفته اول تا زمان برداشت، یک روز در میان محلول غذایی هوگلدن با غلظت ۱۰ میلی‌لیتر بر لیتر به تمامی گلدان‌ها اضافه شد. به گلدان‌های حاوی گیاه شاهد در روزهای میانی آب و به سایر گلدان‌ها تیمارها (حدود ۷۵ میلی‌لیتر) اضافه شد. تیمارهای اعمال شده شامل سرب در سه غلظت ۰/۳، ۰/۱ و ۱/۸، نیکل در سه غلظت ۰/۳، ۰/۵ و ۰/۷ و کادمیوم در سه غلظت ۰/۲، ۰/۵ و ۰/۸ میلی‌گرم بر لیتر بدون تاثیرات متقابل بودند. غلظت‌های ذکر شده با توجه به پژوهش انجام شده روی غلظت برخی از فلزات سنگین در آب و رسوب رودخانه تمبی مسجد سلیمان قبل و بعد از ورود به فاضلاب انجام دادند، انتخاب شدند (شنبه‌زاده و همکاران، ۱۳۹۲). در هنگام اضافه کردن کلیه محلول‌ها به بستر کشت شرط خارج نشدن محلول‌ها از زیر گلدان‌ها در نظر گرفته شد.

نهال‌های پونه (حدود ۲۰ تا ۲۵ سانتی‌متر) از منطقه‌ای بین دو دهستان احمدوند و قزانچی از توابع شهر کرمانشاه واقع در عرض جغرافیایی ۵۷/۸" ۲۷' ۳۴° شمالی و طول جغرافیایی ۲۸/۴" ۰۱' ۴۷° شرقی جمع‌آوری و به آزمایشگاه منتقل شد. در آزمایشگاه نهال‌های پونه پس از شست و شوی کامل ریشه (به طوری که گل و لای چسبیده به ریشه جدا شود) در گلدان‌هایی که داخل آن‌ها پرلیت قرار داشت کشت شدند. پس از آماده سازی بستر کشت و سازگار شدن گیاهان به شرایط آزمایشگاهی (پس از کشت ساقه گیاهان خم شده و حالت پلاسیده به خود می‌گیرند اما با گذشت زمان، دادن آب و رسیدن نور خورشید دوباره به حالت ایستاده بر می‌گردند) به منظور اعمال تیمارهای

ماهی از تصاویر دیجیتال که به طور خودکار با استفاده از تبدیل هاف دایره‌ای و آستانه شدت تطبیقی گرفته شده است به عنوان یک بافت مرکزی و معیاری برای تشخیص ماهی پرورش یافته در آب تازه و ماهی در معرض فلز سنگین، در نظر گرفته شد. دقت روش پیشنهادی بالا بود و محاسبات زمان سپری شده امکان استفاده از چنین الگوریتمی برای تشخیص آبی در عرصه‌های مرتبط را نشان می‌دهد.

(Jun et al., 2019) در تحقیقی به آنالیز کادمیوم باقی مانده در برگ‌های گوجه فرنگی براساس تصویربرداری فراطیفی WT-Vis-NIR و LSSVR پرداختند. اعتبار و قابلیت اطمینان تصویربرداری فراطیفی Vis-NIR برای تعیین مقدار فلزات سنگین در برگ‌های گوجه‌فرنگی تحت تنش‌های مختلف کادمیوم مورد بررسی قرار گرفت. علاوه بر این، روشی که شامل تبدیل موجک و حداقل رگرسیون ماشین بردار پشتیبان مربع (WT-LSSVR) است برای انتخاب طول موج مطلوب و ایجاد مدل تشخیص، ارایه شد. در نهایت ایشان نتیجه گرفتند که WT-LSSVR می‌تواند به طور موثری طول موج مطلوب را انتخاب کند و تصویر برداری متشکل از Vis-NIR از پتانسیل بسیار خوبی برای تشخیص محتوای فلزات سنگین در برگ‌های گوجه‌فرنگی در تنش‌های مختلف کادمیوم برخوردار است.

اگر چه از روش‌های پردازش تصویر به طور گسترده در صنعت، کشاورزی و سایر علوم و پژوهش‌های مختلف استفاده می‌شود ولی تحقیقات بسیار کمی درباره استفاده از این روش‌ها برای تشخیص فلزات سنگین انجام شده است و هیچ کدام از این تحقیقات گزارشی درباره تشخیص فلزات سنگین به وسیله‌ی عکس‌برداری مستقیم از گیاه نداده‌اند. تشخیص فلزات سنگین در آب، خاک و گیاه از ضرورت‌های تحقیق بوده که در اینجا به روش غیر مخرب و ارزان مورد بررسی قرار گرفته است. هدف این تحقیق تعیین یک روش غیر مخرب، بسیار کم هزینه و نوآورانه را برای بررسی وجود و تعیین نوع و مقدار فلزات سنگین در گیاهان و حتی آب‌های سطحی، با استفاده از تکنیک پردازش تصویر به روش شبکه‌های عصبی مصنوعی را معرفی می‌کند. روش‌های تصویربرداری مستقیم از گیاه و همچنین تصویربرداری در داخل جعبه (غیر مستقیم) از دیگر اهداف این تحقیق می‌باشند. نتایج این تحقیق راهی را برای تحقیق‌های بیشتر توسط دیگر محققانی که می‌خواهند روی موضوع تشخیص فلزات سنگین با استفاده از روش‌های سریع و غیر مخرب کار کنند باز

میزان فلز سنگین در گیاه پونه، تصویر برداری هر روز و به دو صورت تصویر برداری با جعبه و تصویر برداری تماسی انجام گرفت.

برای تصویر برداری با جعبه جعبه‌ی یک طرف بازی با ابعاد ۲۵×۲۵×۵۰ سانتی متر از جنس ورق ملامینه ساخته شد که سوراخ گردی به قطر ۲ سانتی متر در مرکز صفحه‌ی بالایی قرار داشت که محل قرار گرفتن دوربین گوشی برای گرفتن تصویر بود. مطابق شکل (۱) به منظور تصویر برداری از گیاه جعبه بر روی گیاه قرار داده می‌شد و برای تامین روشنایی از یک لامپ گرد LED که در داخل جعبه زیر صفحه بالایی قرار داشت استفاده شد.

آزمایشی که شامل غلظت‌های مختلف فلزات سنگین سرب، نیکل و کادمیوم بود، با توجه به حجم گلدان‌ها، جرم مولکولی فلزات سنگین و نمک‌های آن‌ها و نیز با در نظر گرفتن غلظت‌های مختلف فلزات سنگین، مقادیر مشخصی از نمک‌های این فلزات سنگین در آب حل شده و به گلدان‌ها اضافه شد.

برای گرفتن تصاویر از گوشی هوشمند SAMSUNG Galaxy Note 4 مدل N910G ساخت شرکت سامسونگ استفاده شد که مجهز به دوربینی با حسگر ۱۶ مگاپیکسل و پردازنده‌ای از نوع Quad-core 2.7 GHz Krait 450 - Snapdragon 805 بود. همچنین حافظه با دسترسی تصادفی در این تلفن همراه برابر ۳ گیگابایت بود. برای تعیین نوع فلز سنگین و تخمین



الف ب ج

شکل (۱): نحوه تصویر برداری از گیاه با جعبه: (الف) جعبه تصویر برداری و نحوه قراردادن دوربین روی جعبه، (ب) منبع نوری داخل جعبه، (ج) تنظیم کننده نور داخل جعبه

برگ نیز نور به آن بتاباند. برای ساختن این نگهدارنده ابتدا نقشه سه بعدی آن در نرم‌افزار CATIA V5R21 تهیه شد و سپس توسط نرم‌افزار ReplicatorG، نقشه به Gcode مناسب برای چاپگر سه بعدی WinBO ساخت شرکت WinBo Co تبدیل شد تا قطعه توسط چاپگر سه بعدی ساخته شود. نور پشت برگ از طریق لامپ‌های LED کوچکی که به نگه‌دارنده چسبانده شده و از طریق USB OTG به گوشی متصل بود تامین می‌شد. در شکل (۳) نحوه ی تصویر برداری با نور پیش زمینه، قاب طراحی شده و نمونه‌ای از تصاویر گرفته شده نمایش داده شده است.

در طول دوره‌ی آزمایش و یک روز قبل اعمال تیمارها هر روز از ۳۰ گیاه تصویر برداری شد (۲۹ عدد عکس برای هر گیاه) که در مجموع ۸۷۰ عدد عکس با جعبه گرفته شد. تنظیمات دوربین برای تصویر برداری شامل ISO = ۱۰۰، توازن سفیدی Day Light و HDR خاموش بود. در شکل (۲) یک نمونه از تصاویر گرفته شده با جعبه نمایش داده شده است.

در این بخش آزمایش برای افزایش میزان دقت تصاویر تماسی تحت شرایط کنترل شده نوری و حذف مرحله پیش پردازش تصاویر، یک نگه‌دارنده کوچک برای موبایل طراحی شد که بتواند برگ‌های گیاه را جلوی دوربین تلفن همراه نگه دارد و از پشت

از ۳۰ گیاه در طول دوره آزمایش گرفته شد. تنظیم‌های دوربین در حین گرفتن این تصاویر همانند نوع قبل یعنی ISO=۱۰۰، توازن سفیدی DayLight و HDR خاموش بود. در تصاویر تماسی پیش پردازش وجود نداشت اما در تصاویر گرفته شده با جعبه تصاویر ابتدا با استفاده از روش آستانه‌گذاری اتسو پیکسل‌های غیر سبز رنگ هر تصویر به رنگ مشکی در آمده و سپس ویژگی‌ها از پیکسل‌های غیر مشکی تصویر استخراج شد. در هر دو نوع تصویربرداری ۱۲ ویژگی شامل قرمز، سبز و آبی از فضای رنگی RGB، هیو، اشباع و روشنایی از فضای HSB، درخشندگی، کرومای آبی و کرومای قرمز از فضای رنگی YCbCr و روشنی، قرمز/ سبز و زرد/ آبی از فضای رنگ L*a*b* از تصاویر استخراج شد. فرمول محاسبه‌ی این ویژگی‌ها در ادامه در روابط (۱ تا ۱۴) آورده شده است. در روابط ذیل R، G و B نماینده میانگین رنگ‌های قرمز، سبز و آبی پس از جداسازی زمینه بودند (Mendoza et al., 2006).




شکل (۲): یک نمونه از تصویر گرفته شده با جعبه

در مجموع ۱۵۶۰ تصویر تماسی (۸۷۰ از آن‌ها مربوط به برگ‌های بالایی و ۶۹۰ از آن‌ها مربوط به برگ‌های پایینی بود)



ج



ب



الف

شکل (۳): الف) نحوه‌ی تصویر برداری با نور پیش زمینه، ب) قاب طراحی و ساخته شده برای نصب دوربین و هدایت لنز دوربین به روی برگ گیاه، ج) نمونه‌ای از تصاویر گرفته شده به این روش

$$\text{Hue} \begin{cases} 10 \times \left(\frac{G - B}{C} \right) + t, & \max(R, G, B) = R \\ 10 \times \left(2 + \frac{B - R}{C} \right), & \max(R, G, B) = G \\ 10 \times \left(4 + \frac{G - B}{C} \right), & \max(R, G, B) = B \end{cases} \quad (۱)$$

که در آن

$$C = \max(R, G, B) - \min(R, G, B) \quad (۲)$$

$$t = \begin{cases} 0 & G \geq B \\ 6 & G < B \end{cases} \quad (۳)$$

$$\text{Saturation} = \begin{cases} 0 & \max(R, G, B) = 0 \\ \frac{C}{\max(R, G, B)} & \max(R, G, B) \neq 0 \end{cases} \quad (۴)$$

$$\text{Brightness} = \frac{\max(R, G, B)}{255} \quad (۵)$$

$$Y = 0.257 \cdot R + 0.504 \cdot G + 0.098 \cdot B + 16 \quad (۶)$$

$$Cb = -0.148 \cdot R - 0.291 \cdot G + 0.439 \cdot B + 128 \quad (۷)$$

$$Cr = 0.439 \cdot R - 0.368 \cdot G - 0.071 \cdot B + 128 \quad (۸)$$

برای محاسبه‌ی ویژگی‌های L^* ، a^* و b^* داریم:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.412453 & 0.357580 & 0.180423 \\ 0.212671 & 0.715160 & 0.072169 \\ 0.019334 & 0.119193 & 0.950227 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (۹)$$

$$[X_n \ Y_n \ Z_n] = [0.950450 \ 1.000000 \ 1.088754] \quad (۱۰)$$

$$\begin{cases} L^* = 116 \left(\frac{Y}{Y_n}\right)^{1/3} - 16 & \text{for } \frac{Y}{Y_n} > 0.008856 \\ L^* = 116 \left(\frac{Y}{Y_n}\right)^{1/3} - 16 & \text{for } \frac{Y}{Y_n} \leq 0.008856 \end{cases} \quad (۱۱)$$

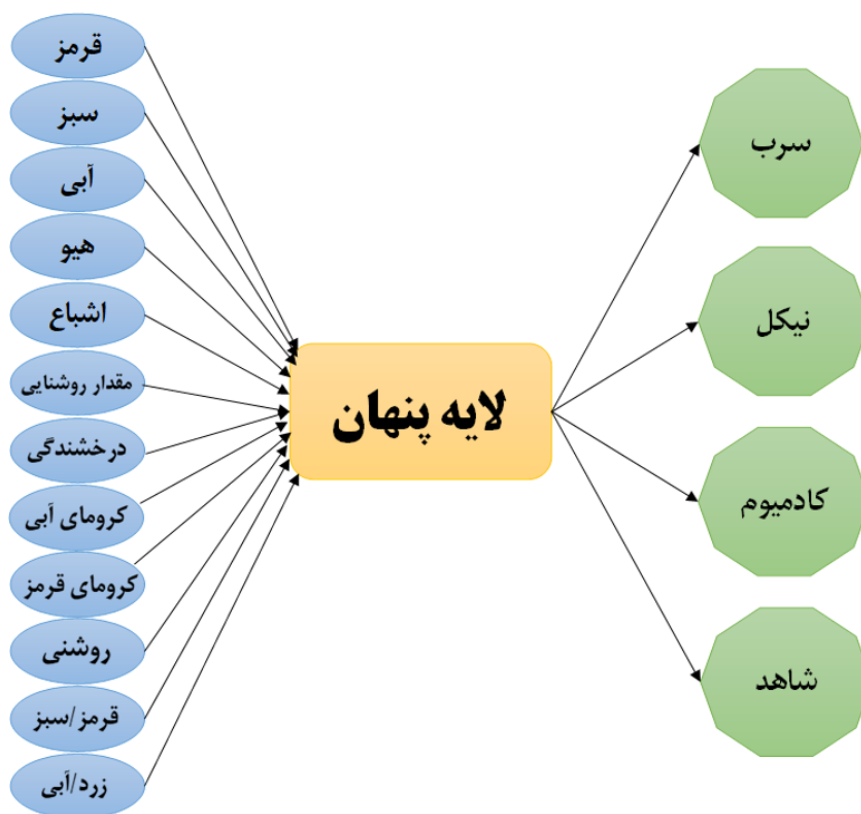
$$a^* = 500 \left(f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right) \quad (۱۲)$$

$$b^* = 200 \left(f\left(\frac{X}{X_n}\right) - f\left(\frac{Z}{Z_n}\right) \right) \quad (۱۳)$$

$$\begin{cases} f(u) = u^{1/3} & \text{for } u > 0.008856 \\ f(u) = 7.787u + \frac{16}{116} & \text{for } u \leq 0.008856 \end{cases} \quad (۱۴)$$

مورد ارزیابی و تست قرار داده شد. ۱۲ مولفه رنگی (قرمز، سبز، آبی، هیو، اشباع، مقدار روشنایی، درخشندگی، کرومای آبی، کرومای قرمز، روشنی، قرمز/ سبز و زرد/ آبی) استخراج شده از تصاویر به عنوان نورون‌های لایه ورودی استفاده شد. همچنین برای خروجی یک بار ۴ نورون (سرب، نیکل، کادمیوم و شاهد) و یک بار ۲ نورون (فلز سنگین و شاهد) استفاده شد. در شکل (۴) نمای کلی از مدل شبکه عصبی تهیه شده نشان داده شده است.

در این تحقیق از نرم‌افزار MATLAB R2017B برای استخراج ویژگی‌ها از تصاویر گرفته شده از گیاه پونه در دو حالت تماسی و جعبه و برای طبقه‌بندی فلزات سنگین استفاده شد. همه‌ی ۱۲ ویژگی استخراج شده از تصاویر برای ایجاد و آموزش شبکه عصبی مورد استفاده قرار گرفت. از ۷۰ درصد از داده‌ها برای آموزش شبکه عصبی و ۱۵ درصد از داده‌ها برای اعتبارسنجی استفاده شد و در نهایت شبکه با ۱۵ درصد باقیمانده از داده‌ها



شکل (۴): نمای کلی از مدل شبکه عصبی

پیکسل‌های غیر سیاه تصویر استخراج شد. در شکل (۵) نمونه‌ای از جداسازی پیکسل‌های سبز رنگ از پس‌زمینه آورده شده است.



شکل (۵): (الف) تصویر ابتدایی، (ب) تصویر جدا شده

برای تعیین ساختار شبکه عصبی مصنوعی تعداد ۱۲ نورون به عنوان لایه ورودی مدل و ۴ نورون به عنوان لایه خروجی در نظر گرفته شد. برای تعیین تعداد نورون‌های لایه پنهان به منظور کسب بیشترین ضریب تبیین و کم‌ترین خطای میانگین

در این پژوهش از خطای میانگین مربعات (MSE) و ضریب تبیین (R^2) برای ارزیابی عملکرد شبکه‌های طراحی شده استفاده شد. در نهایت ساختاری که بهترین ضریب تبیین را داشت مورد استفاده قرار گرفت. خطای میانگین مربعات و ضریب تبیین مقداری بین صفر و یک را دارند. خطای میانگین مربعات هر چه به صفر نزدیک‌تر باشد و ضریب تبیین هر چه به یک نزدیک‌تر باشد شبکه عملکرد بهتری را داشته است.

نتایج و بحث

همان‌طور که گفته شد عملیات آماده‌سازی تصاویر در دو نوع تصویربرداری متفاوت بود. در تصویربرداری تماسی نیازی به پیش پردازش وجود نداشت اما در تصاویر گرفته شده با جعبه نیاز بود که قبل از شروع استخراج ویژگی از تصاویر، فرآیند پیش پردازش بر روی تصاویر انجام شود. زیرا، همان‌طور که در قسمت الف شکل (۵) مشخص است پیکسل‌های زیادی از تصویر را جعبه و سایر اشیای موجود در تصویر فرا گرفته است. با استفاده از کد نویسی در برنامه متلب کدی نوشته شد که پیکسل‌های غیر سبز از تصویر به رنگ سیاه در آمده و سپس ویژگی‌ها از

ماتریس ۵۳/۹ درصد می‌باشد. سپس گروه‌ها کمتر شده و به دو گروه (دو خروجی) شامل آلوده به فلزات سنگین و شاهد تبدیل شدند تا بتوان دقت را بالاتر برد. شکل (۷) ماتریس اغتشاش کلی شبکه عصبی با ساختار ۲-۳۳-۱۲ برای طبقه بندی تصاویر جعبه را نشان می‌دهد.

Overall Confusion Matrix

Output Class	1	783 90.0%	87 10.0%	90.0% 10.0%
	2	0 0.0%	0 0.0%	NaN% NaN%
		100% 0.0%	0.0% 100%	90.0% 10.0%
		1	2	
		Target Class		

شکل (۷): ماتریس اغتشاش شبکه عصبی برای طبقه‌بندی تصاویر جعبه در دو گروه فلزات سنگین و شاهد

در شکل (۷) کلاس‌های ۱ و ۲ به ترتیب گیاهان آلوده به سه فلز سنگین (سرب، نیکل و کادمیوم) و شاهد هستند. همان طور که در خانه‌ی آبی رنگ ماتریس اغتشاش مشاهده می‌شود عدد سبز ۹۰٪ را نشان می‌دهد که یعنی دقت کلی برای این حالت طبقه بندی ۹۰ درصد است اما مشخص است که در گروه فلزات سنگین ۷۸۳ عدد تصویر را به درستی در این گروه طبقه بندی کرده ولی در گروه دوم یعنی شاهد هیچ تصویری را در این گروه طبقه‌بندی نکرده است.

مانند بخش قبل برای تعیین ساختار شبکه عصبی تعداد ۱۲ نورون به عنوان لایه ورودی مدل و ۴ نورون به عنوان لایه خروجی در نظر گرفته شد و به منظور اکتساب بهترین ضریب تبیین تعداد نورون‌های متفاوت به ترتیب به شبکه عصبی داده شدند. در شکل (۸) ماتریس اغتشاش شبکه عصبی مصنوعی با ساختار ۴-۲۵-۱۲ برای تصاویر تماسی برگ‌های بالایی که

مربعات قاعده مشخصی وجود ندارد. بنابراین، با استفاده از روش آزمون و خطا و تغییر تعداد نورون‌های لایه مخفی بهترین ساختار مشخص شد و ماتریس اغتشاش برای این ساختار محاسبه شد. در شکل (۶) ماتریس اغتشاش شبکه عصبی مصنوعی با ساختار ۱۲-۲۱-۴ برای تصاویر جعبه که توسط نرم‌افزار متلب رسم شده را نشان می‌دهد. لازم به ذکر است در این شکل مقادیر درصد برای هر کدام از خانه‌های جدول براساس مقدار کلی به دست آمده یعنی شامل هر سه مرحله آموزش، اعتبارسنجی و تست است. در نهایت دقت کلی در خانه‌ی سمت راست پایین (آبی رنگ) به دست آمده است.


Overall Confusion Matrix

Output Class	1	173 19.9%	36 4.1%	59 6.8%	28 3.2%	58.4% 41.6%
	2	30 3.4%	162 18.6%	69 7.9%	32 3.7%	55.3% 44.7%
3	55 6.3%	63 7.2%	133 15.3%	26 3.0%	48.0% 52.0%	
4	3 0.3%	0 0.0%	0 0.0%	1 0.1%	25.0% 75.0%	
		66.3% 33.9%	62.1% 37.9%	51.0% 49.0%	1.1% 98.9%	53.9% 46.1%
		1	2	3	4	
		Target Class				

شکل (۶): ماتریس اغتشاش شبکه عصبی برای طبقه‌بندی تصاویر جعبه در چهار گروه سرب، نیکل، کادمیوم و شاهد

در شکل (۶) کلاس‌های ۱ تا ۴ به ترتیب سرب، نیکل، کادمیوم و شاهد بودند. پیش‌بینی عضویت توسط شبکه‌ی عصبی در واقع همان Output Class می‌باشد. به عنوان مثال در شکل (۶) شبکه عصبی برای گروه سرب ۱۷۳ عدد داده ورودی را به درستی در گروه واقعی سرب (Target Class)، پیش‌بینی کرده و ۳۰ عدد را به اشتباه در گروه نیکل، ۵۵ عدد را به اشتباه در گروه کادمیوم و ۳ عدد را به اشتباه در گروه شاهد پیش‌بینی کرده است. در ماتریس اغتشاش شکل (۶) مشخص است که بهترین دقت طبقه‌بندی برای گروه سرب با دقت ۶۶/۳ درصد و کم‌ترین دقت برای گروه شاهد با دقت ۱/۱ درصد می‌باشد. دقت کلی این

عدد از تصاویر را به درستی در این گروه پیش‌بینی کرده است و ۷۹ عدد از تصاویر را به اشتباه در گروه سرب و ۴۴ عدد از تصاویر را به اشتباه در کادمیوم پیش‌بینی کرده است. دقت کلی در این ماتریس ۳۳/۷٪ می‌باشد. با توجه به دقت پایین ۳۳/۷ درصدی در طبقه‌بندی تصاویر در ۴ گروه، این بار تصاویر تماسی گرفته شده از برگ‌های بالایی گیاه پونه در دو گروه آلوده به فلز سنگین و شاهد در نظر گرفته شد. شکل (۹) ماتریس اغتشاش کلی شبکه عصبی با ساختار ۲-۳۳-۱۲ برای طبقه‌بندی تصاویر تماسی برگ‌های بالایی را نشان می‌دهد. شکل (۹) عکس بهترین ساختار شبکه برای تصاویر تماسی برگ‌های بالایی با دو خروجی را نمایش می‌دهد.



شکل (۹): ساختار شبکه برای تصاویر تماسی بالایی با ساختار ۲-۳۳-۱۲

نتایج شبکه عصبی برای تعیین تعداد نورون در لایه مخفی براساس ضریب تبیین و میانگین مربعات خطا در جدول (۱) آورده شده است.

توسط نرم‌افزار متلب رسم شده را نشان داده شده است. لازم به ذکر است در شکل (۸) مقادیر درصد برای هر کدام از خانه‌های جدول براساس مقدار کلی به دست آمده یعنی شامل هر سه مرحله آموزش، اعتبار سنجی و تست است.

Overall Confusion Matrix

Output Class	1	2	3	4	
1	82 9.4%	79 9.1%	68 7.8%	21 2.4%	32.8% 67.2%
2	121 13.9%	138 15.9%	120 13.8%	58 6.7%	31.6% 68.4%
3	58 6.7%	44 5.1%	73 8.4%	8 0.09%	39.9% 60.1%
4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
	31.4% 68.6%	52.9% 47.1%	28.0% 72.0%	0.0% 100%	33.7% 66.3%
	1	2	3	4	

Target Class

شکل (۸): ماتریس اغتشاش شبکه عصبی برای طبقه بندی تصاویر تماسی برگ‌های بالایی در چهار گروه سرب، نیکل، کادمیوم و شاهد

در شکل (۸) کلاسه‌های ۱ تا ۴ به ترتیب سرب، نیکل، کادمیوم و شاهد بودند. همان‌طور که ملاحظه می‌شود در این ماتریس بالاترین دقت مربوط به نیکل با دقت ۵۲/۹٪ می‌باشد که ۱۳۸

جدول (۱): نتایج شبکه عصبی مصنوعی برای تعیین بهترین ساختار برای تصاویر تماسی بالایی با ۲ خروجی


ردیف	ساختار	R ²	MSE
۱	۱۲-۲۸-۲	۰/۰۲۶۲۳۰۳۹۴	۰/۰۸۶۷۶۷۷
۲	۱۲-۲۹-۲	۰/۰۲۵۶۵۵۰۷	۰/۰۸۶۸۹۹۹
۳	۱۲-۳۰-۲	۰/۰۳۳۷۷۲۹۴	۰/۰۸۶۰۸۵۴
۴	۱۲-۳۱-۲	۰/۰۱۱۴۱۲۲۲۲	۰/۰۹۰۴۴۵۷
۵	۱۲-۳۲-۲	۰/۰۱۱۸۲۵۴۷۵	۰/۰۸۸۶۰۸۹
۶	۱۲-۳۳-۲	۰/۰۴۳۳۹۲۲۲۳	۰/۰۸۵۳۹۵۲
۷	۱۲-۳۴-۲	۰/۰۲۴۹۲۷۰۴۲	۰/۰۸۶۹۶۳۴
۸	۱۲-۳۵-۲	۰/۰۱۹۲۲۲۴۳۶	۰/۰۸۷۴۲۹۷
۹	۱۲-۳۶-۲	۰/۰۲۰۵۰۹۹۶۳	۰/۰۹۰۴۸۶۴
۱۰	۱۲-۳۷-۲	۰/۰۲۷۸۷۱۹۶۹	۰/۰۸۷۷۲۲۴
۱۱	۱۲-۳۸-۲	۰/۰۳۱۷۲۳۱۷۲	۰/۰۸۶۳۳۸۱

همان‌گونه که مشاهده می‌شود، بعد از اجرای مدل شبکه، جواب مناسب در اپک ۳ به دست آمد. در اپک ۳ بهترین عملکرد اعتبارسنجی با میانگین مربعات خطای 0.099735 به دست آمد. در شکل (۱۱) وضعیت آموزش شبکه برای تصاویر جعبه با ساختار ۲-۳۳-۱۲ گزارش شده است.

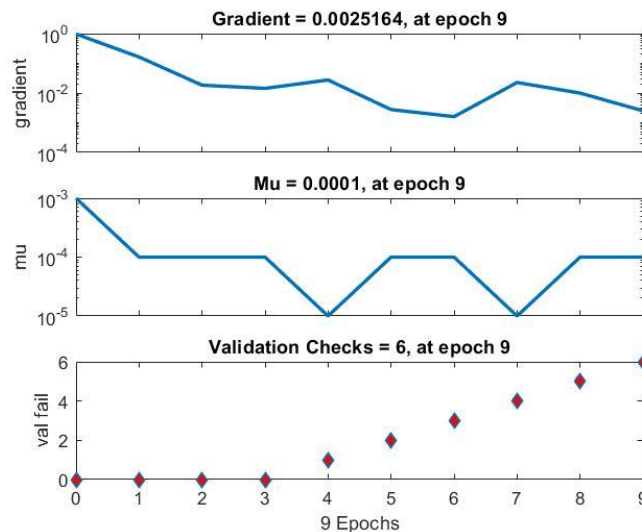
در ماتریس اغتشاش شکل (۱۲) کلاس‌های ۱ و ۲ به ترتیب گیاهان آلوده به سه فلز سنگین (سرب، نیکل و کادمیوم) و شاهد بودند. همان‌طور که در خانه‌ی آبی رنگ ماتریس اغتشاش مشاهده می‌شود عدد سبز $94/7\%$ را نشان می‌دهد که یعنی دقت کلی برای این حالت طبقه بندی $94/7\%$ درصد است.

مقادیر پارامترهای ارزیابی طبقه‌بندی تصاویر تماسی برگ‌های بالایی در دو دسته آلوده به فلزات سنگین و شاهد مطابق با ماتریس اغتشاش آورده شده در شکل (۱۲) در جدول (۲) آورده شده است.

عملکرد شبکه یا تعداد تکرارهای آزمایش برای ایجاد شبکه مناسب در شکل (۱۰) آورده شده است.



شکل (۱۰): عملکرد شبکه برای تصاویر تماسی بالایی با ساختار ۲-۳۳-۱۲



شکل (۱۱): وضعیت آموزش شبکه برای تصاویر تماسی بالایی با ساختار ۲-۳۳-۱۲

جدول (۲): مقادیر پارامترهای ارزیابی طبقه بندی تصاویر تماسی بالایی با ساختار ۲-۳۳-۱۲

کلاس‌های طبقه‌بندی شده		
شاهد	آلوده به فلزات سنگین	
۰/۴۷۱	۱	نرخ تصمیم‌گیری صحیح مثبت (TPR)
۰	۰/۵۲۹	نرخ تصمیم‌گیری غلط مثبت (FPR)
۱	۰/۹۴۵	دقت (Precision)
۰/۶۴۱	۰/۹۷۱	امتیاز F (F Score)
۰/۶۶۷	۰/۶۶۷	ضریب همبستگی متیوز (MCC)
۰/۷۳۶	۰/۷۳۶	مساحت زیر منحنی (AUC)

مانند بخش‌های قبل برای تعیین ساختار شبکه عصبی تعداد ۱۲ نورون به عنوان لایه ورودی مدل و ۴ نورون به عنوان لایه خروجی در نظر گرفته شد و به منظور اکتساب بهترین ضریب تبیین تعداد نورون‌های متفاوت به ترتیب به شبکه عصبی داده شدند. شکل (۱۳) ماتریس اغتشاش شبکه عصبی مصنوعی با ساختار ۴-۲۵-۱۲ برای تصاویر تماسی برگ‌های پایینی که توسط نرم‌افزار متلب رسم شده را نشان می‌دهد. لازم به ذکر است در این شکل مقادیر درصد برای هر کدام از خانه‌های جدول براساس مقدار کلی به دست آمده یعنی شامل هر سه مرحله آموزش، اعتبارسنجی و تست است.

در شکل (۱۳) کلاس‌های ۱ تا ۴ به ترتیب سرب، نیکل، کادمیوم و شاهد بودند. همان‌طور که ملاحظه می‌شود در این ماتریس بالاترین دقت مربوط به سرب با دقت ۶۸/۶٪ می‌باشد که ۱۴۲ عدد از تصاویر را به درستی در این گروه پیش‌بینی کرده است و ۳۸ عدد از تصاویر را به اشتباه در گروه نیکل و ۲۷ عدد از تصاویر را به اشتباه در کادمیوم پیش‌بینی کرده است.

نرخ طبقه‌بندی صحیح برای این نوع از دسته‌بندی تصاویر تماسی بالایی برابر با ۹۴/۷٪ می‌باشد.

Overall Confusion Matrix

		1	2	
Output Class	1	783 90.0%	46 5.3%	94.5% 5.5%
	2	0 0.0%	41 4.7%	100% 0.0%
		1	2	
		100% 0.0%	47.1% 52.9%	94.7% 5.3%
		Target Class		

شکل (۱۲): ماتریس اغتشاش شبکه عصبی برای طبقه‌بندی تصاویر تماسی بالایی در دو گروه فلزات سنگین و شاهد

Overall Confusion Matrix

		1	2	3	4	
Output Class	1	142 20.6%	94 13.6%	80 11.6%	36 5.2%	40.3% 59.7%
	2	38 5.5%	73 10.6%	46 6.7%	21 3.0%	41.0% 59.0%
	3	27 3.9%	40 5.8%	81 11.7%	11 1.6%	39.9% 60.1%
	4	0 0.0%	0 0.0%	0 0.0%	1 0.1%	100% 0.0%
		1	2	3	4	
		68.6% 31.4%	35.3% 64.7%	39.1% 60.9%	1.4% 98.6%	43.0% 57.0%
		Target Class				

شکل (۱۳): ماتریس اغتشاش شبکه عصبی برای طبقه‌بندی تصاویر تماسی برگ‌های پایینی در چهار گروه سرب، نیکل، کادمیوم و شاهد

پونه به فلزات سنگین سرب در ۳ سطح (۰/۳، ۱ و ۱/۸ میلی‌گرم بر لیتر)، نیکل در ۳ سطح (۰/۳، ۰/۵ و ۰/۷ میلی‌گرم بر لیتر) و کادمیوم در سه سطح (۰/۲، ۰/۵ و ۰/۸ میلی‌گرم بر لیتر) با استفاده از پردازش تصویر وجود داشته و این روش میزان آلوده بودن و یا نبودن تصاویر تماسی برگ‌های بالایی را در سطح ۹۴/۷٪ تشخیص داد. با توجه به این که این سطوح از فلزات سنگین با توجه به نتایج به‌دست آمده از وجود این فلزات در آب رودخانه برای این آزمایش انتخاب شده بود، می‌توان نتیجه گرفت که امکان تشخیص آلودگی آب رودخانه‌ها به سه فلز سنگین یاد شده با کشت گیاه پونه و تصویربرداری تماسی از برگ‌های بالایی این گیاه در سطح ۹۴/۷٪ وجود دارد. سالاری و همکاران (۲۰۱۸)، پارامترهای اصلی کیفیت آب شامل اکسیژن محلول، کل مواد جامد محلول، هدایت الکتریکی و قلیائیت را با استفاده از روش‌های ریاضی و شبکه‌های عصبی مصنوعی تخمین زدند میزان این پارامترها با ضریب همبستگی ۰/۹۹ به‌خوبی تخمین زده شد (Salari et al., 2018). وصالی و همکاران (۲۰۱۵) و لیو و همکاران (۲۰۱۰)، نیز گزارش کردند که استفاده از پردازش تصویر و شبکه عصبی با دقت بالایی قادر به تخمین میزان کلروفیل برگ ذرت و برنج می‌باشد (Vesali et al., 2010 and Liu et al., 2015). حقی‌یابی و همکاران (۲۰۱۸)، از روش‌های هوش مصنوعی شامل شبکه عصبی مصنوعی (ANN)، روش گروهی پردازش داده‌ها (GMDH) و ماشین بردار پشتیبان (SVM) برای تخمین مولفه‌های کیفیت آب رودخانه تیره در جنوب‌غربی ایران استفاده کردند و براساس نتایج حاصله مدل‌های ANN و SVM عملکرد مناسبی داشتند (Haghiabi et al., 2018).

تشکر و قدردانی

بدین‌وسیله از حمایت‌های مادی و معنوی دانشگاه رازی سپاسگزاری می‌شود.

دقت کلی در این ماتریس ۴۳٪ می‌باشد. سپس تصاویر تماسی گرفته شده از برگ‌های پایینی گیاه پونه در دو گروه آلوده به فلز سنگین و شاهد در نظر گرفته شد. شکل (۱۴) ماتریس اغتشاش کلی شبکه عصبی با ساختار ۲-۹-۱۲ برای طبقه‌بندی تصاویر تماسی برگ‌های پایینی را نشان می‌دهد.

Overall Confusion Matrix

		Target Class		
		1	2	
Output Class	1	621 90.0%	69 10.0%	90.0% 10.0%
	2	0 0.0%	0 0.0%	NaN% NaN%
		100% 0.0%	0.0% 100%	90.0% 10.0%

شکل (۱۴): ماتریس اغتشاش شبکه عصبی برای طبقه‌بندی تصاویر تماسی پایینی در دو گروه فلزات سنگین و شاهد

در ماتریس اغتشاش شکل (۱۴) کلاسه‌های ۱ و ۲ به ترتیب گیاهان آلوده به سه فلز سنگین (سرب، نیکل و کادمیوم) و شاهد بودند. همان‌طور که در خانه‌ی آبی رنگ ماتریس اغتشاش مشاهده می‌شود عدد سبز ۹۰٪ را نشان می‌دهد که یعنی دقت کلی برای این حالت طبقه‌بندی ۹۰ درصد است اما مشخص است که در گروه فلزات سنگین ۶۲۱ عدد تصویر را به درستی در این گروه طبقه‌بندی کرده است.

نتیجه‌گیری

در این پژوهش مشخص شد که امکان تشخیص آلودگی گیاه

فهرست منابع

Beale, R. & Jackson, T. 1990. Neural Computing-an introduction. CRC Press.

- Carral, E.; Puente, X.; Villares, R. & Carballeira, A. 1995. Background heavy metal levels in estuarine sediments and organisms in Galicia (northwest Spain) as determined by modal analysis. *Science of the total environment*, Vol. 172, pp. 175-88.
- Chaney, R.; Malik, M.; Li, Y.; Brown, S.; Brewer, E. & Angle, J. 1997. Phytoremediation of soil metals. *Current Opinion in Biotechnology* Vol. pp. 279-284.
- Di Natale, F.; Lancia, A.; Molino, A.; Di Natale, M.; Karatza, D. & Musmarra, D. 2006. Capture of mercury ions by natural and industrial materials. *Journal of hazardous materials*, 132(2-3), pp.220-225.
- Giachetti, G. & Sebastiani, L. 2006. Metal accumulation in poplar plant grown with industrial wastes. *Chemosphere*, 64(3), pp.446-454.
- Haghiabi, A. M.; Nasrolahi, A. H. & Parsaie, A. 2018. Water quality prediction using machine learning methods. *Water Q Res J* 53(1):3-13
- Hong, Y.; Shen, R.; Cheng, H.; Chen, Y.; Zhang, Y.; Zhou, M.; Yu, L. & Liu, Y. 2019. Estimating lead and zinc concentrations in peri-urban agricultural soils through reflectance spectroscopy: Effects of fractional-order derivative and random forest. *Science of the Total Environment*, 651, pp.1969-1982.
- Issac, A.; Srivastava, A.; & Dutta, M.K. 2019. An automated computer vision based preliminary study for the identification of a heavy metal (Hg) exposed fish-channa punctatus. *Computers in biology and medicine*, 111. <https://doi.org/10.1016/j.combiomed.2019.103326>
- Jun, S.; Xin, Z.; Xiaohong, W.; Bing, L.; Chunxia, D. & Jifeng, S. 2019. Research and analysis of cadmium residue in tomato leaves based on WT-LSSVR and Vis-NIR hyperspectral imaging. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 212, pp.215-221.
- Lasat, M.M. 2002. Phytoextraction of toxic metals: a review of biological mechanisms. *Journal of environmental quality*, 31(1), pp.109-120.
- Liu, M.; Liu, X.; Li, M.; Fang, M. & Chi, W. 2010. Neural-network model for estimating leaf chlorophyll concentration in rice under stress from heavy metals using four spectral indices. *Biosyst Eng* 106:223-233
- Macek, T.; Francova, K.; Kochánková, L.; Lovecká, P.; Ryslava, E.; Rezek, J.; Sura, M.; Triska, J.; Demnerova, K. & Mackova, M. 2004. Phytoremediation—biological cleaning of a polluted environment. *Reviews on environmental health*, 19(1), pp.63-82.
- Mendoza, F.; Dejmek, P. & Aguilera, J.M. 2006. Calibrated color measurements of agricultural foods using image analysis. *Postharvest Biology and Technology*, 41(3), pp.285-295.
- Mohialden, K.M.; Omid, M.; Rajabipour, A.; Tajeddin, B. & Firouz, M.S. 2019. Quality and shelf-life prediction of cauliflower under modified atmosphere packaging by using artificial neural networks and image processing. *Computers and Electronics in Agriculture*, 163, pp.104861.
- Patil, S.B. & Bodhe, S.K. 2011. Leaf disease severity measurement using image processing. *International Journal of Engineering and Technology*, 3(5), pp.297-301.
- Salari, M.; Salami Shahid, E.; Afzali, S. H.; Ehteshami, M.; Conti, G. O.; Derakhshan, Z. & Sheibani, S. N. 2018. Quality assessment and artificial neural networks modeling for characterization of chemical and physical parameters of potable water. *Food and Chemical Toxicology*, 118, 212-219.
- Shnbehzadeh, S.; Vahiddastjerdi, M.; Hasanzadeh, A. & Kianizadeh, T. 2014. Investigation of concentration of some heavy metals in water and sediment of Masjed Soleiman River before and after sewage entering it. *Journal of Health System Research*, 9(10), pp.1108-1116. (In Persian)

Sick, B. 2002. On-line and indirect tool wear monitoring in turning with artificial neural networks: a review of more than a decade of research. *Mechanical systems and signal processing*, 16(4), pp.487-546.

Vara Prasad, M.N. & de Oliveira Freitas, H.M. 2003. Metal hyper accumulation in plants: biodiversity prospecting for phytoremediation technology. *Electronic journal of biotechnology*, 6(3), pp.285-321.

Vesali, F.; Omid, M.; Kaleita, A. & Mobli, H. 2015. Development of an android app to estimate chlorophyll content of corn leaves based on contact imaging. *Comput Electron Agric* 116:211–220

Walker, E.L. & Connolly, E.L. 2008. Time to pump iron: iron-deficiency-signaling mechanisms of higher plants. *Current opinion in plant biology*, 11(5), pp.530-535.