



تخمین محتوای نیترات گوجه‌فرنگی با استفاده از ویژگی‌های تصویر

سید مهدی نصیری^{۱*}، محمد امین نعمت‌اللهی^۲، عبدالعباس جعفری^۳، پیمان سلمرودی^۴

۱- دانشیار، بخش مهندسی بیوسیستم دانشگاه شیراز

۲- دانشیار، بخش مهندسی بیوسیستم دانشگاه شیراز

۳- دانشیار، بخش مهندسی بیوسیستم دانشگاه شیراز

۴- دانش‌آموخته کارشناسی ارشد، بخش مهندسی بیوسیستم، دانشگاه شیراز

چکیده

اطلاعات مقاله

تاریخ‌های مقاله :

تاریخ دریافت: ۱۴۰۱/۱۰/۲۹

تاریخ پذیرش: ۱۴۰۳/۲/۲

کلمات کلیدی:

پردازش تصویر،

رگرسیون،

شبکه عصبی مصنوعی،

گوجه‌فرنگی،

نیترات

DOI:10.22034/FSCT.21.152.1.

* مسئول مکاتبات:

nasiri@shirazu.ac.ir

کاربرد ناصحیح کودهای شیمیایی در تولید محصولات کشاورزی بروز بیماری برای مصرف‌کنندگان را ممکن می‌سازد. در این مطالعه تخمین مقدار نیترات تجمع یافته در میوه گوجه‌فرنگی به کمک پردازش تصویر بررسی شد. این پژوهش در قالب طرح کاملاً تصادفی با چهار تیمار نیتروژن در سطوح ۴۰۰، ۸۰۰، ۱۲۰۰ و ۱۶۰۰ کیلوگرم بر هکتار انجام شد. از هر تیمار ۵۰ نمونه به طور تصادفی برای تهیه تصاویر و ایجاد مدل تخمین انتخاب شد. نمونه‌ها با ضخامت یکسان برش زده شدند، عکس‌برداری صورت گرفت و سپس نیترات نمونه‌ها به روش آزمایشگاهی اندازه‌گیری شد. مولفه‌های رنگی R، G و B مرتبط با سطح و محتوای داخلی نمونه‌ها و همچنین ویژگی‌های غیررنگی از جمله مساحت پیکسل‌های سفید و رقه‌ها، مساحت کل ورقه‌ها و نسبت مساحت پیکسل‌های سفید به مساحت کل استخراج شدند. نتایج نشان داد متناسب با سطوح نیتروژن اعمال شده، مقدار نیترات نمونه‌ها به ترتیب ۱/۶، ۲/۷، ۲/۸ و ۳/۳ در صد اندازه‌گیری شد که این افزایش معنادار بود ($P < 0.05$). افزون بر آن، مشخص شد محتوای رنگی ورقه‌ها، مساحت پیکسل‌های سفید ورقه‌ها و نسبت مساحت پیکسل‌های سفید به مساحت پیکسل‌های سفید به م‌ساحت پیکسل‌های سفید به م‌ساحت کل همبستگی بالایی با محتوای نیترات نمونه‌ها داشت. برای پیش‌بینی میزان نیترات، مدل رگرسیون چندگانه و شبکه عصبی چند لایه پرسپترون بکاربرده شد. روش بهترین زیر مجموعه رگرسیون برای انتخاب مناسب‌ترین مدل رگرسیون بکاربرده شد. برای انتخاب بهترین مدل شبکه عصبی، معماری‌ها و توابع انتقال مختلف به کار برده شد و بر اساس نتایج شبکه با ساختار ۱-۱۵-۳ با کمترین مقدار ریشه میانگین مربعات خطا به عنوان بهترین مدل انتخاب شد. برای واسنجی بهترین مدل رگرسیون و شبکه عصبی از ۶۰ نمونه جدید استفاده شد. ساختار معرفی شده توانست با درصد میانگین خطای نسبی ۳/۵ درصد در مقایسه با مدل رگرسیون با مقدار ۵/۲ درصد مقدار محتوای نیترات را تخمین بزند.

۱- مقدمه

گوجه‌فرنگی (*Lycopersicon esculentum* M.) یکی از محصولاتی است که بالاترین میزان مصرف را در دنیا به خود اختصاص داده است. گوجه‌فرنگی سرشار از ویتامین سی و لیکوپن است. این میوه امروزه به روش‌های مختلفی به طور خام یا به عنوان یکی از مواد لازم برای تهیه غذا، انواع سس و نوشیدنی مصرف می‌شود و بخش مهمی از رژیم غذایی مردم بسیاری از کشورها را تشکیل می‌دهد [۱]. به علت اهمیت اقتصادی، این گیاه موضوع تحقیق و پژوهش‌های بسیاری قرار دارد.

قدمت کاشت و برداشت گوجه‌فرنگی به هزاران سال پیش بر می‌گردد و یکی از محصولات است که در بین سبزی‌ها بیشترین مصرف را به خود اختصاص داده است [۲]. گوجه‌فرنگی یکی از مهم‌ترین سبزیجات تجاری جهان با سطح زیر کشت حدود سه میلیون هکتار به شمار می‌رود. مطابق آخرین آمار ارائه شده در سال ۲۰۲۰ ایران جزو ده کشور عمده تولیدکننده گوجه‌فرنگی بوده است و سالیان متمادی در این لیست قرار داشته است. میزان تولید جهانی گوجه‌فرنگی بیش از ۱۸۶ میلیون تن گزارش شده است و سهم ایران از کل میزان تولید تقریباً ۳/۱ درصد بوده است که حدود ۴ درصد نسبت به سال قبل آن رشد داشته است [۲].

سرانه مصرف بالای گوجه‌فرنگی در ایران، افزایش سطح زیر کشت را به دنبال داشته است. افزون بر آن، برای افزایش بهره‌وری و عملکرد آن نیز از سموم و کودهای شیمیایی مختلفی استفاده می‌شود. تغذیه بوته‌های گوجه‌فرنگی با مقادیر بهینه نیتروژن برای رشد آن بسیار حائز اهمیت است، اما کاربرد زیاد نیتروژن نیز سبب رشد رویشی و تأخیر گلدهی خواهد شد [۳]. از سوی دیگر، مصرف بیش از حد کودهای نیتروژنه باعث افزایش غلظت نیترات در اندام‌های قابل مصرف محصولات زراعی به خصوص سبزی‌ها می‌شود و آلودگی نیتراتی را به وجود می‌آورد [۴، ۵]. نیتروژن نیتراته به مقدار کم سمی نیست، ولی مصرف مداوم سبزی‌های حاوی میزان زیاد نیترات مخاطراتی را برای سلامت انسان ایجاد می‌کند [۶-۹]. گزارش شده است که نیترات تجمع یافته در میوه

گوجه‌فرنگی باعث ایجاد بافت (لکه) سفید در گوشت آن می‌شود [۱۰].

عامل‌های مختلفی در تجمع نیترات در گیاه اثر گذارند. قسمت‌های مختلف گیاهان استعداد متفاوتی در ذخیره نیترات دارند و بسته به گونه، رقم و سن گیاه میزان تجمع متغیر است. همچنین عامل‌های محیطی مختلفی بر میزان غلظت نیترات گیاه و میزان جذب آن اثرگذار است. روش کاربرد کود ازت، مقدار، منبع و سرعت آزاد شدن آن بر تجمع نیترات در گیاهان اثر مثبت و قابل توجهی دارد [۱۱]. سایر گزارش‌ها حکایت از تجمع نیتروژن بیشتر در سبزی‌های برگی دارد. با این وجود در آزمایش‌های صورت گرفته مقدار نیترات موجود در بافت خوراکی سبزی‌های غده‌ای نیز از جمله گوجه‌فرنگی بیش از مقدار حد مجاز گزارش شده سازمان بهداشت جهانی بوده است [۱۰، ۱۲].

مطالعات اخیر نشان داده است که مصرف مواد غذایی حاوی نیترات و نیتريت برخی از ترکیبات ازت مانند نیتروزامین را در جهاز هاضمه بوجود می‌آورد که در ایجاد سرطان و تومورهای مختلف زبان و مری و سایر اعضای بدن دخالت دارند و در مقادیر زیاد ایجاد مسمومیت می‌نمایند. به همین لحاظ در مورد میزان نیترات موجود در مواد غذایی در اکثر کشورها حد مجازی رعایت می‌گردد که بسته به نوع محصول و میزان مصرف محلی محصولات، متفاوت است. با توجه به مصرف بی‌رویه ازت در سبزیکاری و از طرفی مصرف عمومی زیاد سبزیجات در ایران، مطالعات گسترده‌ای در زمینه تعیین مقدار نیترات آن‌ها و سقف استاندارد مجاز نیترات در محصولات سبزی و صیفی با استفاده از روش‌های زمان‌بر آزمایشگاهی صورت گرفته است [۲۱-۱۲]. تعیین نیترات در سبزی‌ها و میوه‌ها با استفاده از روش‌های شیمیایی [۱۲، ۲۰] و یا ترکیبی شیمیایی و دستگاهی چون کروماتوگرافی یونی [۱۳، ۱۵، ۲۳، ۲۴]، کروماتوگرافی گازی [۲۵]، کروماتوگرافی مایعات با عملکرد بالا [۱۲]، اسپکتروسکوپی [۲۶]، و اسپکتروفوتومتری [۱۸، ۲۳، ۲۷] گزارش شده است.

گوجه‌فرنگی مطالعه و در نهایت مدل‌سازی برای تخمین میزان نیترات گوجه‌فرنگی با استفاده از ویژگی‌های استخراج شده رنگی انجام پذیرفت.

۲- مواد و روش‌ها

تعدادی نشاء گوجه‌فرنگی رقم Early Urbana از یک خزانه تولید نشاء واقع در روستای فاروق شهرستان مرودشت خریداری شد و بلافاصله در کرت‌های آماده شده کاشته شد. فاصله بین ردیف‌های کشت ۲ متر و فاصله روی ردیف ۳۰ سانتی‌متر در نظر گرفته شد. گوجه‌ها از مرحله اول (نارس) تا مرحله رسیدگی کامل تحت ۴ تیمار نیتروژن ۴۰۰، ۸۰۰، ۱۲۰۰ و ۱۶۰۰ کیلوگرم بر هکتار قرار گرفتند. مقدار این سطوح با توجه به نتایج آزمایش خاک تعیین شد. برای تهیه محلول غذایی از کود ازت برند گرومورا استفاده شد. عناصر آهن (از منبع Fe-EDTA)، منیزیم (از منبع $MgSO_4 \cdot 7H_2O$) و پتاسیم (از منبع K_2SO_4) به صورت تکمیلی و ثابت به محلول غذایی اضافه شدند. آبیاری به صورت قطره‌ای و هر ۵ روز یک بار به مدت ۱۲ ساعت انجام گرفت. محلول غذایی به صورت دستی و یکسان با توجه به میزان رشد گیاه، به بوته‌ها اعمال شد. سمپاشی و استفاده از کارت زرد برای کنترل آفات و مگس سفید بر اساس توصیه بخش گیاه‌پزشکی دانشگاه شیراز صورت گرفت. عملیات وجین نیز به صورت هفتگی انجام شد.

برداشت گوجه‌ها از ابتدای مهرماه آغاز شد. گوجه‌هایی که در آخرین مرحله فیزیولوژیکی رسیدگی (زمانی که بیش از ۹۰ درصد سطح میوه قرمز شده) قرار داشتند برای آزمایش انتخاب گردیدند و برای اطمینان از اینکه گوجه‌ها در سطح رسیدگی یکسان برداشت شوند از نرم افزار Color Grab (v 3.6.0) استفاده شد و برداشت هر ۳ روز یک بار در ساعت ۱۲ بعدازظهر صورت گرفت. حدود ۱۵۰ نمونه از تیمارهای مختلف برای آزمون‌ها به صورت تصادفی انتخاب شد. قبل از هر اندازه‌گیری نیترات و عکس‌برداری نمونه‌ها ابتدا شسته و خشک شدند و سپس توزین شدند. برای توزین نمونه‌ها ترازوی با دقت ± 0.01 گرم مورد استفاده قرار گرفت. در ادامه نمونه‌ها با ضخامت ۸ میلی‌متر برش زده شدند. این

در فرآیندهای برخط و پیوسته نیاز به اندازه‌گیری سریع خصوصیات شیمیایی و فیزیکی است، بنابراین بکارگیری روش‌هایی که بتواند با دقت قابل قبول ویژگی‌های مورد نیاز را تعیین کند مورد وثوق سامانه‌های چابک و برخط است. خصوصیات رنگی محصولات کشاورزی و مواد غذایی یکی از روش‌هایی است که از قابلیت سنجش سریع برخوردار است و در پژوهش‌های بسیار مورد بررسی قرار گرفته است.

پردازش تصویر بر مبنای امواج نور در محدوده مرئی، قابلیت‌های خود را در تشخیص خصوصیات فیزیکی، شیمیایی و مکانیکی نشان داده است و برای تعیین کیفیت محصولات کشاورزی توسعه داده شده‌اند. از این روش برای تشخیص‌های مخرب یا غیرمخرب کیفیت در محصولات مختلف از جمله گوجه‌فرنگی برای تشخیص آنتی‌اکسیدان‌های گوجه‌فرنگی متأثر از عوامل محیطی و مقدار نیتروژن بهره برده شده است [۲۸]. کاهش محتوای لیکوپن گوجه‌فرنگی و به دنبال آن کاهش رنگ قرمز طی مدت زمان نگهداری به روش پردازش تصویر بررسی شد و رابطه خطی قوی با ضریب همبستگی $0.982/$ گزارش شد [۲۹]. در پژوهش‌های دیگر نیز محتویات گوجه‌فرنگی که امکان درجه‌بندی کیفی را فراهم می‌سازد مورد مطالعه قرار گرفته است. به عنوان نمونه، می‌توان به امکان‌سنجی پیش‌بینی محتوای ترکیبات بیواکتیو و ترکیبات فنولی و لیکوپن میوه گوجه‌فرنگی با استفاده از پردازش تصاویر فراطیفی [۳۰]، و کیفیت‌سنجی سطح میوه گوجه‌فرنگی بر اساس شاخص‌های رنگی برای تفکیک میوه‌ها [۳۱] اشاره نمود. نتایج این پژوهش‌ها به ترتیب با دقت ۹۶ درصد و ۹۸ درصد پیش‌بینی و یا تفکیک را انجام دادند. پردازش تصویر استفاده فراگیر در تعیین کیفیت ظاهری برای کاربردهای درجه‌بندی و دسته‌بندی میوه‌ها و سبزی‌های دارد. این روش بر اساس رنگ و عیوب سطحی برای تفکیک انواع سیب، هندوانه، پیاز و مرکبات آفت زده و معیوب [۳۲]، ارزیابی میوه‌ها و سبزی‌ها [۳۳]، لیمو، پرتقال و گوجه‌فرنگی [۳۴] و دسته‌بندی نمونه‌های سالم و معیوب گوجه‌فرنگی و موز [۳۵] استفاده شده است.

در پژوهش حاضر رابطه بین ویژگی‌های رنگی قابل استخراج توسط ماشین‌بینایی با میزان نیترات موجود در


شده به یک لپ‌تاپ (CPU core I5 RAM4GB) منتقل شد و با استفاده از نرم افزار متلب نسخه R2014b الگوریتم‌های مورد نیاز طراحی شد. اولین مرحله در تحلیل تصاویر، قطعه‌بندی است. قطعه‌بندی فرآیندی است که تصویر را به قسمت‌های اصلی سازنده آن تقسیم می‌کند. بدین معنی که اشیاء مختلف موجود در تصویر با توجه به کاربرد مورد نظر از هم جدا می‌شوند تا تحلیل تصویر در مراحل بعدی راحت‌تر انجام شود. در مرحله‌ی بعد برای تبدیل تصویر نمونه به تصویر باینری به منظور شمارش پیکسل‌های سفید مرتبط با رگه‌های سفید، مقدار حد آستانه به روش اتسو محاسبه شد و تصویر نمونه به تصویر باینری تبدیل گردید، به حالتی که نمونه میوه مقدار یک (رنگ سفید) و زمینه مقدار صفر (سیاه) را به خود اختصاص داد. سپس با شمارش پیکسل‌های سفید مساحت رگه‌های سفید محاسبه و داده‌ها به نرم‌افزار اکسل منتقل شد. آشکار سازی و شمارش رگه‌های سفید مربوط به این قسمت در شکل ۱ قابل مشاهده است.

برای استخراج ویژگی‌های رنگی تصاویر از فضای رنگی RGB استفاده شد و مولفه‌های R, G, B سطح گوجه و ورقه‌ها پس از حذف پس زمینه (مقدار عددی صفر برای پس زمینه) از تصاویر مربوطه استخراج گردید. با تقسیم حاصل جمع مقادیر هر یک از این مولفه‌ها بر مساحت ورقه‌های میوه (که برابر با تعداد پیکسل‌های ورقه‌های میوه در تصویر بود)، مقدار میانگین هر یک از مولفه‌ها محاسبه شد. مقادیر بدست آمده همانند ویژگی‌های شکلی با نوشتن برنامه‌ای برای تحلیل‌های بعدی به نرم‌افزار اکسل منتقل شد. افزون بر آن، مساحت کل سطح (TSA)، مساحت پیکسل‌های سفید (WPA) و نسبت مساحت پیکسل‌های سفید به کل سطح (WPA/TSA) برای ورقه‌ها محاسبه شد.


ضخامت با چندین پیش‌آزمون برای جلوگیری از له شدن گوجه‌فرنگی هنگام برش بدست آمد. برای این که تمام ورقه‌ها دارای ضخامت یکسان باشند، از یک قالب فلزی با تعداد ۶ تیغه (موکت بری) موازی با فاصله ۸ میلی‌متر استفاده شد. در ادامه، ابتدا از نمونه‌ها عکس برداری و سپس آزمون‌های تشخیص عناصر نیترات و پتاسیم انجام شد.

آزمایش تعیین نیتروژن به روش هضم، تقطیر و تیتراسیون در کلدال (AA670G شرکت Shimatzo ژاپن) انجام شد. در این روش نمونه مورد نظر در اسید سولفوریک غلیظ حل شد تا تمام ازت آن تبدیل به سولفات آمونیم گردد. سپس با اضافه کردن هیدروکسید سدیم و با کمک عمل تقطیر، آمونیاک آن جدا و در داخل محلول اسیدبوریک استاندارد جمع‌آوری شد. سپس با تیتراسیون مقدار ازت آن تعیین شد [۳۶]. برای اندازه‌گیری مواد معدنی نمونه‌های گیاهی در کوره با دمای ۵۰۰ درجه سلسیوس به مدت ۶ ساعت خاکستر شدند. سپس در ۵ میلی‌لیتر محلول اسیدنیتریک ۲ مولار حل شده و در نهایت حجم محلول با آب دوبار تقطیر به ۲۵ میلی‌لیتر رسانده شد و با کاغذ صافی واتمن شماره ۱ صاف گردید. در این پژوهش برای تعیین اثر خالص نیتروژن بر نیترات تجمیع شده، مقدار پتاسیم برای رشد گیاه به خاک اضافه نشد [۷]. در عین حال، مقدار پتاسیم جذب شده از خاک توسط گوجه‌فرنگی با دستگاه فلیم‌فتومتر (مدل Jenway PFP7 ساخت بریتانیا) اندازه‌گیری شد.

عکس برداری از نمونه‌های کامل میوه و ورقه‌های برش خورده در محفظه مخصوص با استفاده از دوربین Canon با وضوح ۱۲ مگاپیکسل (۳۰۰۰ × ۴۰۰۰ پیکسل)، با نورپردازی ۴ عدد لامپ هالوژن انجام شد. تصاویر با فرمت jpg ذخیره و به هر نمونه شماره‌ای اختصاص داده شد. عکس‌های تهیه



(a)



(b)




Figure (1) A sample for exposing white spots of images a) color, b) binary, c) background elimination, d) white area detection and noise elimination

تعداد متغیرهای مستقل و $\hat{\sigma}^2$ خطای استاندارد مدل است. در حالی که تعداد متغیرهای مستقل موثر در مدل با مقدار آماره C_p یکسان یا نزدیک شد (در این حالت خطای استاندارد مدل برابر میانگین مربعات خطا یعنی $SSE/N-P$ خواهد شد و در نتیجه $C_p=P$ می‌شود)، این مدل از لحاظ تعداد متغیرهای مناسب است. چنانچه تعداد متغیرهای مستقل یکسان اما نوع متغیر مدل متفاوت باشد، مقدار ضریب تبیین تنظیم شده برای انتخاب مدل مناسب‌تر مد نظر قرار می‌گیرد. در این شرایط مدل با ضریب تبیین تنظیم شده بیشتر به عنوان مدل نهایی انتخاب می‌شود. با توجه به اینکه ضرایب رگرسیون تابع مقدار و واحد متغیر مستقل متناظر آن است، برای حذف این تاثیر مدل‌های رگرسیون با داده‌های استاندارد (مقدار Z) شده نیز تعیین شد [۴۰].

داده‌ها و متغیرهای مشابه مدل سازی رگرسیون، شامل مساحت پیکسل‌های سفید شمارش شده در کل سطح، نسبت سطح پیکسل‌های سفید به کل سطح و مولفه‌های رنگی ورقه‌ها به عنوان ورودی و میزان نیترات به عنوان خروجی، برای تعلیم شبکه عصبی پرسپترون چند لایه (شکل ۲) استفاده شدند.

برای مدل‌سازی رابطه بین میزان نیترات تجمیع یافته و ویژگی‌های رنگی استخراج شده از تصاویر، دو روش رگرسیون چند متغیره و شبکه عصبی بکاربرده شد. برای تعیین روابط رگرسیون چند متغیره بین محتوای نیترات اندازه‌گیری شده و ویژگی‌های استخراج شده از تصاویر نمونه‌ها از نرم‌افزار MINITAB 16 استفاده شد. برای مدل رگرسیون مناسب‌ترین متغیرهای موثر در رابطه (متغیر مستقل) با روش بهترین زیر مجموعه متغیرها^۱ انتخاب شدند. مناسب‌ترین مدل بر اساس آماره‌های ضریب تبیین تنظیم شده (R_a^2) و مالوز^۲ (C_p) به ترتیب مطابق رابطه‌های ۱ و ۲ انتخاب شد [۳۷-۳۹].

$$R_a^2 = 1 - \frac{(1 - R^2)(N - 1)}{N - P - 1} \quad (1)$$

$$C_p = \frac{SSE}{\hat{\sigma}^2} - N + 2P \quad (2)$$

که در رابطه‌های بالا R^2 ضریب تبیین معادله رگرسیون، SSE مجموع مربعات خطا (باقیمانده) مدل، N تعداد داده‌ها، P




Figure (2) Schematic of multilayer perceptron neural network

$$RMSE = \sqrt{\frac{\sum_{i=1}^m (P_i - O_i)^2}{m}} \quad (3)$$

$$MAPE = \frac{1}{m} \sum_{i=1}^m \frac{|O_i - P_i|}{O_i} \times 100 \quad (4)$$

که m تعداد داده‌های ورودی شبکه، و P و O به ترتیب مقدار خروجی پیش‌بینی شده شبکه و مقدار واقعی اندازه‌گیری شده متناظر خروجی مدل است. برای مدل‌سازی رگرسیون و شبکه عصبی به ترتیب ۷۰ و ۳۰ درصد داده‌ها به عنوان داده‌های آموزش و آزمایش استفاده شد.

برای وا سنجی مدل‌های توسعه داده شده رگرسیونی و شبکه عصبی، ۶۰ نمونه مجزا (غیر از نمونه‌های تیمار شده آزمایش) از بازار تهیه و اندازه‌گیری‌های قبلی مجدداً انجام شد. مقدار نترات تخمین زده شده با مدل‌های توسعه داده شده محاسبه و با مقدار اندازه‌گیری شده متناظر مورد مقایسه و ارزیابی قرار گرفت. مقادیر میانگین خطای اریبی (MBE)، شاخص توافق (d) و میانگین درصد خطای مطلق به عنوان شاخص‌های وا سنجی مدل‌ها بررسی شدند. سنجش ارزیابی میانگین خطای اریبی نشان‌دهنده این است که مدل، متغیر مورد نظر را کم یا زیاد برآورد می‌کند. این سنجش مطابق رابطه ۵ محاسبه شد [۴۱]. شاخص توافق میزان تطابق بین دو سری داده را می‌سنجد و در آن اندازه‌گیری و سنجش همبستگی مد نظر نیست، بلکه عاری بودن از خطای مقادیر برآورد شده را ارزیابی می‌کند که مقدار آن بین صفر تا یک متغیر است. چه این شاخص به یک نزدیک‌تر باشد سازگاری دو متغیر بیشتر

برای دستیابی به بهترین معماری شبکه عصبی انتشار برگشتی با حداقل خطا بین داده‌های اندازه‌گیری شده و پیش‌بینی شده، پس از محاسبات متعدد با ساختارهای مختلف شبکه عصبی، پارامترهای بهینه شبکه عصبی مانند تعداد لایه‌های مخفی و نورون‌ها، نوع تابع انتقال و الگوریتم یادگیری انتخاب شدند. برای این منظور، توابع انتقال متداول مانند *tansig*، *logsig* و *pureline* و الگوریتم‌های یادگیری *trainlm*، *trainrp* و *traincgp* مورد ارزیابی قرار گرفت. در نهایت برای این پژوهش از شبکه عصبی انتشار برگشتی با یک لایه مخفی به ترتیب با تابع انتقال *tansig* و الگوریتم بهینه‌سازی سیگموئیدی و لونیبرگ - مارکواریت استفاده شد. ورودی‌های دو مدل انتخاب شده مناسب رگرسیون به عنوان ورودی برای طراحی دو شبکه عصبی بکاربرده شد. بر همین اساس تعداد نرون‌ها برای مدل اول (با سه ورودی WPA^2 ، WPA ، مولفه رنگی قرمز ورقه‌ها R) و مدل دوم (شش ورودی شامل سه ویژگی بیان شده در مدل اول و توان دوم آنها) به ترتیب ۱۵ و ۱۷ عدد انتخاب شد. آموزش شبکه در نرم‌افزار متلب، نسخه ۲۰۱۸، انجام شد و شاخص‌های ریشه میانگین مربعات خطا (RMSE) و میانگین درصد خطای مطلق (MAPE) به عنوان شاخص‌های مقایسه دو مدل شبکه عصبی به شرح زیر مورد استفاده قرار گرفتند. این شاخص‌ها برای مقایسه بین مدل‌های رگرسیونی و شبکه عصبی نیز مورد استفاده قرار گرفت.

نرم افزار SPSS 21 و برای تعیین اختلاف میانگین تیمارها از آزمون دانکن در سطح ۵ درصد استفاده گردید. در هر کدام از تیمارها از ۵۰ نمونه برای صفات اندازه گیری شده استفاده شد.

۳- نتایج و بحث

با توجه به نتایج تجزیه واریانس جدول ۱ مشاهده می شود که تاثیر تیمارهای نیتروژن تغذیه شده به گیاه بر میزان نیترات نمونه ها در سطح ۱ درصد معنادار بوده است و افزایش سطوح نیتروژن باعث افزایش غلظت نیترات در نمونه ها شده است. نتایج مشابهی برای افزایش میزان نیترات ذخیره شده در میوه و برگ گیاه گوجه فرنگی در پی افزایش کود نیتروژن دار گزارش شده است که با نتایج ارائه شده در این پژوهش مطابقت دارد [۴۶-۴۴]. همچنین گزارش شده است که افزایش میزان نیتروژن به صورت محلول آمونیوم مقدار نیترات موجود در میوه گوجه فرنگی را افزایش داده است [۲۳].

است. شاخص میانگین در صد خطای مطلق نیز برای ارزیابی خطای مدل ها محاسبه شد. مقدار کمتر این شاخص نشانگر بالاتر بودن دقت مدل است. برای محاسبه میانگین خطای اریبی و شاخص توافق از رابطه های زیر استفاده شد [۴۲، ۴۳].

$$MBE = \frac{1}{m} \sum_{i=1}^N (P_i - O_i) \quad (5)$$

$$d = 1 - \left[\frac{\sum_{i=1}^m (P_i - O_i)^2}{\sum_{i=1}^m (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \right] \quad (6)$$

در این رابطه ها N تعداد داده های ورودی برای ارزیابی، P_i مقدار پیش بینی شده، O_i مقدار واقعی، و \bar{O} میانگین مقادیر واقعی است. این آزمایش در قالب طرح کاملا تصادفی انجام شد. برای واکاوی واریانس داده ها از

Table 1- Effect of nitrogen levels on samples nitrate content (percent)

منابع تغییرات Source of Variations	درجه آزادی df.	مجموع مربعات SS	میانگین مربعات MS	F
نیتروژن Nitrogen	3	85.1	28.4	85.2**
خطا Error	196	65.3	0.3	
کل Total	199	150.3		

** نشان دهنده معناداری در سطح احتمال ۱ درصد است

افزایشی را در پی داشته است و بیشترین مقدار محتوای نیترات در بالاترین سطح اعمال نیتروژن رخ داده است.

نتایج مقایسه میانگین (شکل ۲) نشان می دهد با افزایش سطح نیتروژن، میانگین مقادیر نیترات در نمونه ها روند




Figure (2) Mean comparison of nitrate content (%) of treatments (Different letters show significant difference at 5 % probability level)

نمونه در سطح احتمال ۵ درصد معنادار شده است. عدم اختلاف بین مولفه‌های رنگی سطح میوه را می‌توان به برداشت گوجه‌ها در زمان رسیدگی با سنجه مشابه مرتبط دانست به نحوی که نمونه‌ها دارای سطح رسیدگی (رنگی) یکسانی بوده است [۵۱، ۵۲]. برای مولفه‌های رنگی ورقه‌ها با افزایش سطوح نیتروژن، مقادیر R کاهش معنادار می‌یابد در حالی که مقادیر G و B روند افزایشی دارند. بیشترین مقدار R مربوط به تیمار ۴۰۰ کیلوگرم بر هکتار و کمترین مقدار R مربوط به تیمار ۱۶۰۰ کیلوگرم بر هکتار است. در پژوهش‌های دیگر کاهش محتوای لیکوپن گوجه و به تبع کاهش قرمزی آن در اثر افزایش سطوح نیتروژن گزارش شده است که می‌تواند در تغییرات مقدار مولفه رنگی قرمز نمونه‌ها موثر باشد [۲۸، ۲۹].

با توجه به تاثیر معنادار مقدار نیتروژن بر ویژگی‌های رنگی ورقه‌ها، همبستگی بین مولفه‌ها و مقدار نیترات موجود در نمونه‌ها محاسبه شد (جدول ۲). همچنین ضرایب همبستگی بین مقادیر نیترات و ویژگی‌های غیر رنگی (مساحت و نسبت لکه‌های سفید) نیز محاسبه شد (جدول ۳). همبستگی قوی مساحت پیکسل‌های سفید با محتوای نیترات نشان می‌دهد، افزایش سطوح نیتروژن باعث کاهش لیکوپن گوجه‌فرنگی و در نتیجه افزایش مساحت پیکسل‌های سفید شده است [۲۸]. مطابق این داده‌ها مولفه رنگی قرمز و مساحت پیکسل‌های سفید ورقه بیشترین ارتباط خطی را با میزان نیترات تجمعی در گوجه فرنگی داشتند.

گزارش شده است که افزایش ترکیب کود پتاسیم و نیتروژن بر مقدار جذب نیتروژن اثر معکوس دارد [۴۴]. بنابراین، همان‌طور که در بخش مواد و روش‌ها بیان شد برای جلوگیری از تاثیر منفی پتاسیم بر جذب نیتروژن توسط گیاه، از اعمال کود پتاسیم اضافه خودداری شد. با این وجود، میزان پتاسیم جذب شده گیاه از خاک اندازه‌گیری شد. مقدار پتاسیم نمونه‌ها افزایش معناداری از ۹/۰۸ درصد به ۹/۵۳ درصد در تیمارهای اعمال شده نیتروژن از ۴۰۰ به ۸۰۰ کیلوگرم در هکتار را نشان داد و پس از آن با افزایش سطح نیتروژن اعمال شده (از ۱۲۰۰ به ۱۶۰۰ کیلوگرم بر هکتار)، با کاهش معنادار از ۹/۲ درصد به مقدار ۹/۰۹ درصد رسید ($P < 0.05$). این تغییرات پتاسیم را می‌توان حاصل برهمکنش پتاسیم (ثابت) و سطوح مختلف نیتروژن اعمالی دانست. در پژوهش‌های دیگر مشابه چنین رفتار افزایشی و کاهشی [۴۴، ۴۷، ۴۸] و همچنین عدم تاثیر بین نیتروژن و پتاسیم [۴۹] گزارش شده است. افزون بر آن، تفاوت در برهمکنش‌های نیتروژن و پتاسیم را می‌توان به شرایط محیطی از جمله دمای زمان رشد، شدت تابش آفتاب، میزان و دفعات آبیاری، میزان قلیایی بودن خاک، سم و نوع گیاه نسبت داد [۲۷، ۵۰].

به دنبال این نتایج، اثر نیتروژن بر مولفه‌های رنگی گوجه‌فرنگی روی سطح میوه و ورقه بررسی شد. نتایج مربوط به مقایسه مقادیر میانگین R، G و B استخراج شده از سطح نمونه‌ها و همچنین ورقه‌ها در شکل ۳ نشان داده شده است. مطابق این نتایج، سطوح نیتروژن بر مولفه‌های رنگی اندازه‌گیری شده از ورقه‌ها برخلاف مقادیر متناظر روی سطح




Figure (3) Mean of extracted color components from tomatoes' surface and slice
(In each color component and each part, the same letters show non-significant difference at 5 % probability)

Table 2- Correlation coefficients between nitrate content and color components

ورقه Slice			سطح Surface		
R	G	B	R	G	B
-0.810	0.522	0.736	-0.058	-0.063	-0.065

Table 3- Correlation coefficients between nitrate content and non-color features of slice

نسبت مساحت پیکسل های سفید به مساحت کل سطح ورقه WPA/TSA	مساحت پیکسل های سفید WPA	مساحت کل سطح TSA
0.835	0.920	0.603

سفید ورقه‌ها است. لازم به ذکر است که مدل رگرسیون با ورودی‌های WPA، TSA، نسبت WPA به TSA، و مولفه‌های رنگی R، G و B ورقه‌ها و ضریب تبیین تنظیم شده ۰/۹۱۰ در جایگاه انتخاب دوم قرار گرفت که رابطه متناظر آن در ادامه (رابطه ۹) بیان شده است. این مدل نیز دارای ریشه میانگین مربعات خطای ۰/۲۵۴ و میانگین درصد خطای مطلق ۷/۷۷ بود. متناظر با رابطه داده‌های بدون بعد (رابطه ۸)، برای این مدل نیز رابطه داده‌های استاندارد شده بدست آمد (رابطه ۱۰).

$$N = -4.00 \times 10^{-6} WPA + 2.00 \times 10^{-6} TSA + 16.50 \frac{WPA}{TSA} - 7.60 \times 10^{-4} R + 3.95 \times 10^{-3} G - 1.76 \times 10^{-3} B - 4.48 \quad (9)$$

$$N = -0.88 WPA + 0.90 TSA + 1.37 \frac{WPA}{TSA} - 9.3 \times 10^{-3} R + 3.94 \times 10^{-2} G - 1.59 \times 10^2 B \quad (10)$$

تغییرهای ورودی و خروجی متناظر دو مدل رگرسیون با بالاترین ضریب تبیین تنظیم شده، برای تعلیم شبکه عصبی پیش‌خور به کار گرفته شد که قادر به تخمین میزان نیترات باشد. نتایج تعدادی از معماری‌های استفاده شده برای آموزش این دو شبکه در جدول ۴ درج شده است. دو معماری ۱-۱۷-۶ و ۱-۱۵-۳ به ترتیب برای سه (مدل اول) و شش ورودی (مدل دوم) با حداقل مقادیر ریشه میانگین مربعات خطا و میانگین درصد خطای مطلق معرفی شدند. با لحاظ داشتن نتایج جدول ۴ و روش رگرسیون، مدل اول با سه ورودی کم‌ترین پراکنش را برای تخمین میزان نیترات تجمیع شده در هر دو روش مدل سازی رگرسیون و شبکه عصبی داشته است.

با در نظر گرفتن مقادیر قوی همبستگی بین خصوصیات رنگی و غیر رنگی ورقه، و میزان نیترات اندازه‌گیری شده نمونه‌ها، مدل‌های شبکه عصبی و رگرسیون خطی چند متغیره توسعه داده شد. از تمام ویژگی‌های رنگی (R، G و B) و غیر رنگی (مساحت پیکسل‌های سفید، مساحت کل ورقه‌ها و نسبت مساحت پیکسل‌های سفید به مساحت کل) ورقه برای تعیین رابطه رگرسیونی تخمین محتوای نیترات نمونه‌ها استفاده شد. افزون بر آن، با اضافه کردن مربع مساحت پیکسل‌های سفید به عنوان یک متغیر در کنار سایر متغیرهای پیش‌گفته و اعمال روش همه مدل‌های مناسب در نرم‌افزار Minitab، با توجه به مقادیر ضریب تبیین تنظیم شده بیشینه (۰/۹۳۵) و کمیت مالوز مناسب (۲/۸) حاصل از مدل‌های مختلف رگرسیون، رابطه نهایی ۷ برای داده‌های اصلی انتخاب شد. متغیرهای مستقل ورودی انتخاب شده تاثیرگذار در تخمین نیترات با مقادیر محاسبه شده ضرایب همبستگی در جدول‌های ۲ و ۳ هم‌تایید شده است. این مدل دارای ریشه میانگین مربعات خطای ۰/۲۱۶ و میانگین درصد خطای مطلق ۶/۴۵ است.

$$N = -4.77 \times 10^{-12} WPA^2 + 1.00 \times 10^{-5} WPA + 6.53 \times 10^{-3} R - 2.75 \quad (V)$$

برای کاهش مقدار ضرایب رگرسیون معادله برای داده‌های استاندارد شده (بدون بعد) نیز به صورت رابطه ۸ بدست آمد.

$$N = -1.49 WPA^2 + 2.45 WPA + 0.08 R \quad (8)$$

که در رابطه‌های بالا N محتوای نیترات، R مقادیر عددی مولفه رنگی قرمز و WPA مساحت پیکسل‌های


Table 4- Comparison of statistical indices of some multilayer perceptron neural network topology for nitrate prediction

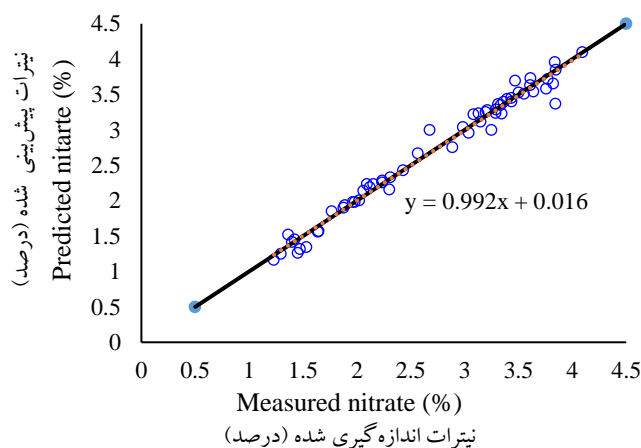
الگوریتم یادگیری	توپولوژی	تابع انتقال	RMSE	MAPE %
Learning algorithm	Topology	Transfer function		

trainrp	3-13-1	tansig	0.1504	6.0976
	3-15-1	logsig	0.1310	5.4769
trainlm	3-13-1	tansig	0.0540	4.8170
	3-15-1	logsig	0.0249	3.7912
traincgf	3-13-1	tansig	0.1495	5.4510
	3-15-1	logsig	0.0812	4.9399
trainrp	6-15-1	tansig	0.1914	6.5672
	6-17-1	logsig	0.1810	5.9941
trainlm	6-15-1	tansig	0.1827	5.2778
	6-17-1	logsig	0.1798	4.9422
traincgf	6-15-1	tansig	0.1885	5.6317
	6-17-1	logsig	0.1812	5.3830

پس از نهایی شدن مدل‌های پیش‌بینی کننده مناسب، داده‌های جدید حاصل از اندازه‌گیری ویژگی‌های رنگی و غیر رنگی و میزان نیترات نمونه‌های خریداری شده برای واسنجی هر دو مدل رگرسیون و شبکه عصبی مورد استفاه قرار گرفت. خروجی هر دو مدل در مقابل مقادیر واقعی (خط یک به یک) ترسیم شد (شکل ۴) و آماره‌های پیش معرفی شده (ریشه میانگین مربعات خطا، میانگین خطای اریبی، شاخص توافق و میانگین درصد خطای مطلق) محاسبه شد (جدول ۵). بر اساس نتایج مندرج در جدول ۵، شبکه عصبی با میانگین خطای ۳/۵ درصد دقت بیشتری در تعیین میزان نیترات تجمیع یافته در نمونه‌ها را داشت، اما

چنانچه لازم باشد از مدل‌های ساده‌تر استفاده نمود، رابطه رگرسیون نیز با مقدار ضریب همبستگی بالا و مقدار پایین خطای تخمین، قادر است مقادیر نیترات تجمعی را با حدود ۵ درصد خطا تخمین بزند. این دو مقدار محاسبه شده از مقادیر محاسبه شده در زمان اعتبارسنجی مدل‌های رگرسیون و شبکه عصبی (به ترتیب ۳/۷۹ و ۶/۴۵ درصد) کمتر بوده است و واسنجی مدل‌های معرفی شده را تایید می‌نماید. بر اساس شکل ۴ بیشترین خطای تخمین مدل رگرسیون در مقادیر بیشتر نیترات تجمعی است.





(b)

Figure (4) Verification of models a) regression and b) neural network

Line and dash-line show 1:1 line and predicted data fit line, respectively.

Table 5- Statistical indices for models verification

Model	Verification indices			
	MAPE	d	MBE	R ²
Regression	5.172	0.9647	-0.2440	0.903
Neural Network	3.529	0.9952	-0.0063	0.988

۳- نتیجه گیری

در این پژوهش امکان تخمین میزان نیترات ذخیره شده در بافت گوجه‌فرنگی با کمک پردازش تصویر بررسی شد. نتایج نشان داد که برخی از ویژگی‌های استخراج شده از تصاویر از جمله مولفه رنگی قرمز و مساحت سطح پیکسل‌های سفید رابطه قوی با محتوای نیترات دارند. دو مدل رگرسیون چندگانه و شبکه عصبی پرسپترون با یک لایه مخفی برای پیش‌بینی مقادیر نیترات استفاده شد و نتایج نشان داد که شبکه عصبی با میانگین درصد خطای مطلق ۳/۵ درصد و مدل رگرسیون با مقدار متناظر حدود ۵/۲ درصد قادر به تخمین محتوای نیترات است. با توجه به این‌که تغییرات رنگ هم به صورت مخرب (ایجاد ورقه) و هم به صورت غیر مخرب (نمونه کامل) بررسی شد، تغییر میزان نیترات تجمیع شده هیچگونه علائمی را بر سطح نمونه‌ها ایجاد ننمود. بنابراین، از جمله محدودیت‌های این

در پژوهش رضایی و همکاران (۲۰۱۴) رابطه خط‌وارگی بین امواج جذبی و نیترات گوجه‌فرنگی ($y = 0.119x + 0.02$) مقدار جذب موج در طول موج ۵۳۸ نانومتر و y مقدار نیترات) در دامنه ۲/۵ تا ۱۵ میلی‌گرم بر کیلوگرم تعریف شد [۱۱]، در حالی که در پژوهش حاضر میزان نیترات تجمعی با مدل‌های شبکه عصبی و رگرسیون به ترتیب تا بیشینه ۴۵ (معادل ۴/۵ درصد) و ۳۰ گرم در کیلوگرم (معادل ۳ درصد) بطور میانگین با خطای ۴/۴ تخمین زده شد. با توجه به شاخص سازمان بهداشت جهانی و فائو برای مقدار ایمن نیترات سبزی‌ها (۲۵۰۰ میلی‌گرم بر کیلوگرم یا معادل ۰/۲۵ درصد)، مشخص شد مصرف مقدار ۴۰۰ کیلوگرم کود نیتروژنه در هر هکتار باعث آلوده شدن گوجه‌فرنگی تا حدود ۱/۵ درصد خواهد شد که از مقدار توصیه شده بسیار بیشتر است [۸، ۱۳].

اندازه‌گیری و بهره‌گیری از آن در آزمون‌ها و کاربردهای
برخط است و هم‌چنان برای هر دو منظور پژوهش و کاربرد
قابلیت مطالعه دارد.

۵-منابع

- [1] Lugasi, A., Bíró, L., Hóvárie, J., Sági, K. V., Brandt, S., & Barna, E. (2003). Lycopene content of foods and lycopene intake in two groups of the Hungarian population. *Nutrition Research*, 23(8), 1035-1044.
- [2] Anonymous. (2020). FAO statistics: Crop product. Available at: <https://www.fao.org/faostat/en/#data/QV>.
- [3] Manrique, L. A. (1993). Greenhouse crops: A review. *Journal of Plant Nutrition*, 16(12), 2411-2477.
- [4] Malakooti, M. J., & Tabatabaei, S.J. (1998). Application of organic and chemical fertilizers for potato production and control nitrate concentration of potatoes' tubers in Iran. Nashre Amozesh Keshavarzi Publication. Karaj, Iran. (in Farsi)
- [5] Mazaheri Tehrani, M., Mortazavi, S. A., Ziaolhagh, H. R., & Ghandi, A. (2007). *Tomato production and processing. Volume 1*. Marzedanesh Publication, Tehran. Iran. (in Farsi)
- [6] Ahmadi, H., Delshad, M., & Babalar, M. (2014). Effect of K and N concentration in nutrient solution on growth and quality of tomato transplants. *Iranian Journal of Horticultural Sciences*, 2(45), 197-205. (in Farsi)
- [7] Matthew, N. B., Augustine, A. U., Shaibu, S. E., Akomie, K. G., Etim, E. U., Efiog, N. E., & Oleh, F. (2019). Spectroscopic Evaluation of Nitrate and Nitrite Concentrations in Selected Fruits and Vegetables. *International Journal of Scientific Engineering and Science*, 3(9), 32-35.
- [8] Sharafati Chaleshtori, R., & Jadi, z. (2019). Fruits contaminated with lead, cadmium and nitrate are the risks to human health: A seasonal study. *Iranian Journal of Toxicology*, 13(4), 27-32. (In Farsi)
- [9] Uddin, R., Thakur, M. U., Uddin, M. Z. & Islam, R. (2021). Study of nitrate levels in fruits and vegetables to assess the potential health risks in Bangladesh. *Scientific Report*, 11, 4704. <https://doi.org/10.1038/s41598-021-84032-z>
- [10] Pascale, S. D., Maggio, A., Fogliano, V., Ambrosino, P., & Ritieni, A. (2001). Irrigation with saline water improves carotenoids content and antioxidant activity of tomato. *The Journal*

روش می‌توان به عدم امکان بهره‌گیری به صورت غیر
مخرب (مگر تغییرات در سطح نمونه کامل ظاهر شود)، و
وابستگی کامل به تغییرات رنگی نمونه مورد آزمون اشاره
داشت. با این وجود، مزیت اصلی این روش سرعت

of horticultural Science and Biotechnology, 76(4), 447-453.

- [11] Hoff, J. E., and Wilcox, G. E. (1997). Accumulation of nitrate in tomato fruit and its effect on detaining. *Journal of the American Society of Horticultural Science*, 95, 92-4.
- [12] Pourmoghim, M., Khosh Tinat, Kh., Sadeghi Barmaki, A., Komeili Fonod, R., Golestan, B., & Pirali, M. (2010). Determining amount of nitrate in letus, tomato and potato presented in Tehran wholesale market by HPLC. *Iranian Journal of Nutrition Sciences and Food Technology*, 1, 63-70. (in Farsi)
- [13] Rezaei, M., Fani, A., Latif-Moini, A., Mirzajani, P., Malekirad, A. A., & Rafiei, M. 2014. Determining nitrate and nitrite content in beverages, fruits, vegetables and stews marketed in Arak, Iran. *International Scholarly Research Notices*. DOI: 10.1155/2014/439702. (in Farsi)
- [14] Beheshti, M., Shahbazi, K., Bazargan, K., & Malekzadeh, E. (2019). Study of nitrate statues in tomatoes and cucumbers distributed in the Alborz province market. *Alborz University of Medical Science Journal*, 8(3), 281-299. (in Farsi)
- [15] Shahbazzadegan S, Hashemimajd K, & Shahbazi B. (2010). Determination of nitrate concentration of consumed vegetables and fruits in Ardabil. *Research Journal of Ardabil Medical Sciences*, 10(1), 8-47.
- [16] Petersen, A., & Stoltze, S. (2010). Nitrate and nitrite in vegetables on the Danish market: content and intake. *Food Additives & Contaminants*, 16(7), 291-299. <https://doi.org/10.1080/026520399283957>.
- [17] Doomary, H., Kamkar, A., & Sharifi, H. (2017). Study of Nitrate content and the effective factors on it in the cucumbers of Jiroft area. *Journal of Veterinary Research*, 72(3), 363-373. (in Farsi)
- [18] Hassani Moghaddam, E., Bazdar, A. R., Shaaban, M. (2019). Study of nitrate rate in some vegetables cultivated in Poldokhtar and Khorramabad, Lorestan Province. *Iranian Journal of Health and Environment*, 12(1), 101-112.
- [19] Asadi, S., & Fazeli, F. (2020). Nitrate contents of some highly consumed products on sale in wholesale fruit and vegetable markets in spring

- and winter in District 4, Tehran, Iran. *Scientific Journal of School of Public Health and Institute of Public Health Research*, 18(1), 111-120.
- [20] Fatemi Ghomsheh, A., & Nezami, S. (2020). Study of nitrate status in some vegetables collected from Kermanshah vegetables markets. *Iranian Journal of Health and Environment*, 13(1), 77-86. (in Farsi)
- [21] Seilsepour, M. (2020). Study of nitrate concentration in Varamin plain leafy vegetables and evaluation of its risk for human. *Journal of Horticultural Plant Nutrition*, 3(1), 69-86. (in Farsi)
- [22] Huang, J., Pope, S., & Willis, M. (2019) A simple electrochemical method for nitrate determination in leafy vegetables. *Journal of Human Nutrition*, 3(1), 67-71.
- [23] Delashad, M., Babalar, M., & Kashi, A. K. (2000). Effect of $\text{NH}_4/\text{NH}_4+\text{NO}_3$ ratio of nutrient solutions on greenhouse tomato cultivars in hydroponic systems. *Iranian Journal of Agricultural Science*, 31(3), 613-625. (in Farsi)
- [24] McMullen, S. E., Casanova, J. A., Gross, L. K., & Schenck, F. J. (2005). Ion chromatographic determination of nitrate and nitrite in vegetable and fruit baby foods. *Journal of AOAC International*, 88(6), 1793-1796.
- [25] Campnella, B., Onor, M., & Pagliano, E. (2017). Rapid determination of nitrate in vegetables by gas chromatography mass spectrometry, *Analytica Chimica Acta*, doi: 10.1016/j.aca.2017.04.053.
- [26] Matthew, N. B., Augustine, A. U., Shaibu, S. E., Akpomie, K. G., Etim, A. U., Efiog, N. E., & Oleh, F. (2019) Spectroscopic evaluation of nitrate and nitrite concentrations in selected fruits and vegetables. *International Journal of Scientific Engineering and Science*, 3(9), 32-39.
- [27] Tabande, L., & Zarei, M. (2018). Overview of nitrate concentration in some vegetables produced in Zanjan province. *Journal of Soil Research*, 32(3), 373-384. (in Farsi)
- [28] Dumas, Y., Dadomo, M., Di Lucca, G., & Grolier, P. (2003). Effects of environmental factors and agricultural techniques on antioxidant content of tomatoes. *Journal of the Science of Food and Agriculture*, 83(5), 369-382.
- [29] Nassiri, S. M., Khajavi, S., & Ramazanian, A. (2014). Application of image processing for determination of tomato color and lycopene content at different storing temperature. 1st National Conference on Harvest and Postharvest Novel Technologies of Agricultural Products. Mashhad, Iran. (in Farsi)
- [30] Liu, C., Liu, W., Chen, W., Yang, J., & Zheng, L. (2015). Feasibility in multispectral imaging for predicting the content of bioactive compounds in intact tomato fruit. *Food Chemistry*, 173, 482-488.
- [31] Zaborowicz, M., Boniecki, P., Koszela, K., Przybylak, A., & Przybyl, J. (2017). Application of neural image analysis in evaluating the quality of greenhouse tomatoes. *Scientia Horticulturae*, 218, 222-229.
- [32] Dubey, S. R., & Jalal, A., S. (2015) Application of image processing in fruit and vegetable analysis: A review. *Journal of Intelligent Systems*, 24(4), 405-424.
- [33] Bhargava, A., & Bansal, A. (2018) Fruits and vegetables quality evaluation using computer vision: A review. *Journal of King Saud University- Computer and Information Sciences*, 33, 243-257.
- [34] Mirra, K. B., Pooja, P., Ranchani, S., & Rajakumari, R. (2020) Fruit quality analysis using image processing. *International Journal of Engineering and Advanced Technology*, 9(5). 88-91.
- [35] Riyaz, S., Venkatesh, T., Maheshwar Reddy, S., & Rahhika, K. (2022) Image processing based fruit and vegetables quality analysis on machine technology. *International Journal of Research Publication and Reviews*, 3(6), 3886-3890.
- [36] Anonymous. (2006). Official Methods and Recommended Practices of the American Oil Chemists Society (A1 2-75, Bc 5-49, Bc 6-49, Da 15-48, Cc 17-95, and Da 14-48 methods) Champaign, IL: AOCS press. Retrieved from <http://www.AOCS.org/methods>.
- [37] Hire, J. F., Anderson, R. E., Tatham, R. L., & Black, W. C. (2006). *Multivariate Data Analysis*. Pearson Education. New Delhi, India.
- [38] Siniksaram, E. (2007). A Geometric interpretation of Mallows` Cp statistics and an alternative plot in variable selection. *Computational Statistics and Data Analysis*, 52, 3459-3467.
- [39] Kazemi, A., Mohamed, A., shareef, H., & Zayandehroodi, H. (2013). Optimal power quality monitor placement using genetic algorithm and Mallows`s Cp. *Electrical Power and Energy Systemms*, 53, 564-575. (in Farsi)
- [40] Gujarati, D. N. (2006). *Basic Econometrics*. Tata McGraw-Hill Publishing Company Ltd. New Delhi, India.
- [41] Quej, V. H., Almorox, J., Ibrakhimov, M., & Saito, L. (2016). Empirical models for estimating daily global solar radiation in Yucatán Peninsula, Mexico. *Energy Conversion and Management*, 110, 448-456.

- [42] Genel, K., Kurnaz, S. C., and Durman, M. (2003). Modeling of tribiological properties of alumina fiber reinforced zinc–aluminum composites using artificial neural network. *Materials Science and Engineering*, 363(2), 203-210.
- [43] Deo, R. C., and Şahin, M. (2015). Application of the extreme learning machine algorithm for the prediction of monthly Effective Drought Index in eastern Australia. *Atmospheric Research*, 153, 512-525.
- [44] Farzaneh, N., Golchin, A., & Hashemi Majd, K. (2010). Effect of different levels of nitrogen and potassium supplements on yield and concentration of N and K in tomato leaves. *Journal of Science and Technology of Greenhouse Culture*, 1, 27-33. (in Farsi)
- [45] Jalini, M., & Dosti, F. (2012). Study of nitrate accumulation in potato and tomato products. *Quarterly Journal of Environmental Science and Engineering*, 50, 62-71. (in Farsi)
- [46] Soto, F., Gallardo, M., Thompson, R.B., Peña-Fleitas, M.T., & Padilla, F.M. (2015). Consideration of total available N supply reduces N fertilizer requirement and potential for nitrate leaching loss in tomato production. *Agriculture, Ecosystems & Environment*, 20, 62-70.
- [47] Gunes, A., Alpaslan, M., & Inal, A. (1998). Critical nutrient concentrations and antagonistic and synergistic relationships among the nutrients of NFT-grown young tomato plants. *Journal of Plant Nutrition*, 21(10), 2035-2047.
- [48] Ozores, M., Di Gioia, F., Sato, S., Simonne, E., & Morgan, K. (2015). Effects of nitrogen rates on nitrogen, phosphorous, and potassium partitioning, accumulation, and use efficiency in seepage-irrigated fresh market tomatoes. *HortScience*, 50(11), 1636-1643.
- [49] Djidonou, D., Zhao, X., Simonne, E. H., Koch, K. E., & Erickson, J. E. (2013). Yield, water and nitrogen-use efficiency in field-grown, grafted tomatoes. *HortScience*, 48(4), 485-492.
- [50] Tabande, L., & Safarzadeh Shirazi, S. (2018). Evaluation of nitrate accumulation and factors affecting it in some leafy vegetables in Zanjan province. *Journal of Soil Research*, 32(2), 189-201.
- [51] Goel, N., & Sehgal, P. (2015). Fuzzy classification of pre-harvest tomatoes for ripeness estimation—An approach based on automatic rule learning using decision tree. *Applied Soft Computing*, 36, 45-56.
- [52] Semary, N. A., Tharwat, A., Elhariri, E., & Hassanien, A. E. (2015). Fruit-based tomato grading system using features fusion and support vector machine. *Intelligent Systems*, 21, 401-410.



Estimation of nitrate content in tomato using image features

Seyed Mehdi Nassiri^{1*}, Mohammad Amin Nematollahi², Abdolabbas Jafari³, Peyman Salamrudi⁴

1- Associate professor, Department of Biosystems Engineering, Shiraz University

2- Associate professor, Department of Biosystems Engineering, Shiraz University

3- Associate professor, Department of Biosystems Engineering, Shiraz University

4- Former M.Sc. student, Department of Biosystems Engineering, Shiraz University

ARTICLE INFO

Article History:

Received:2023/1/19

Accepted:2024/4/21

Keywords:

IMAGE PROCESSING,
NEURAL
NETWORK,
NITRATE,
REGRESSION,
TOMATO.

DOI: 10.22034/FSCT.21.152.1.

*Corresponding Author E-Mail:
nasiri@shirazu.ac.ir

ABSTRACT

The improper use of chemical fertilizers in crop production can result in unsafe food sources for consumers. This research focuses on estimating the accumulation of nitrate in tomatoes by analyzing images of tomato tissues. The experiments were conducted using a completely randomized design with four nitrogen levels: 400, 800, 1200, and 1600 kg.ha⁻¹. Fifty samples were randomly selected from each treatment to create images for feature processing and develop a prediction model. The samples were sliced to a consistent thickness, and their images were prepared. The nitrate contents of the same samples were then measured in the laboratory. Color features, including R, G, and B color components, as well as non-color features such as white pixel area (WPA), total slice surface area (TSA), and the ratio of white pixel area to total slice surface area (WPA/TSA), were extracted from the images. The results showed that the nitrate content of the samples increased significantly ($P < 0.05$) in response to the applied nitrogen fertilizer, with measurements of 1.6%, 2.7%, 2.8%, and 3.3%, respectively. Moreover, a strong correlation was found between the color components, WPA, TSA, WPA/TSA, and nitrate accumulation in the samples. Multiple regression and multilayer perceptron neural network (MLP) models were employed to predict the nitrate content. The best subset method was used to build an appropriate regression model. Various topologies and transform functions were applied to identify the best MLP model. The results indicated that an MLP model with a 3-15-1 topology and the lowest mean relative percentage error (MRPE) was the most accurate neural network model. The final regression and neural network models were validated using 60 intact samples. The neural network model achieved a MRPE of approximately 3.5%, demonstrating its precise estimation of nitrate contents compared to the regression model with an MRPE of around 5.2%.