



## تخمین محتوای نیترات گوجه‌فرنگی با ویژگی‌های استخراج شده پردازش تصویر

سید مهدی نصیری<sup>۱\*</sup>؛ عبدالعباس جعفری<sup>۲</sup>؛ پیمان سلمرودی<sup>۲</sup>

<sup>۱</sup>دانشیار، بخش مهندسی بیوسیستم دانشگاه شیراز؛ [nasiri@shirazu.ac.ir](mailto:nasiri@shirazu.ac.ir)

<sup>۲</sup>دانشیار، بخش مهندسی بیوسیستم دانشگاه شیراز؛ [ajafari@shirazu.ac.ir](mailto:ajafari@shirazu.ac.ir)

<sup>۲</sup>دانش آموخته کارشناسی ارشد مهندسی مکانیک بیوسیستم (فناوری پس از برداشت)، بخش مهندسی بیوسیستم دانشگاه شیراز؛

[peymansalamrudi@gmail.com](mailto:peymansalamrudi@gmail.com)

### چکیده

کاربرد ناصحیح کودهای شیمیایی در تولید محصولات کشاورزی بروز بیماری برای مصرف‌کنندگان را ممکن می‌سازد. از جمله این موارد مصرف بی‌رویه کودهای نیتروژن‌دار است که باعث تجمع نیترات و ایجاد بافت سفید در میوه گوجه‌فرنگی می‌شود. 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 و از هر تیمار ۵۰ نمونه به طور تصادفی برای تهیه تصاویر و انجام آزمایش‌ها انتخاب شد. نمونه‌ها با ضخامت یکسان برش زده شدند و عکس‌برداری صورت گرفت، سپس نیترات نمونه‌ها به روش آزمایشگاهی اندازه‌گیری شد. ویژگی‌های رنگی مرتبط با سطح و محتوای داخلی نمونه‌ها و همچنین ویژگی‌های غیر رنگی از جمله مساحت سفید ورقه‌ها، مساحت کل ورقه‌ها و نسبت مساحت سفید به مساحت کل استخراج شدند. نتایج نشان داد افزایش سطوح نیتروژن باعث افزایش غلظت نیترات در نمونه‌ها می‌شود. همچنین واکاوی داده‌ها برای ارزیابی نتایج الگوریتم‌ها صورت پذیرفت و مشخص شد که محتوای رنگی ورقه‌ها، مساحت سفید ورقه‌ها و نسبت مساحت سفید به مساحت کل همبستگی بالایی با محتوای نیترات نمونه‌ها داشت. به منظور پیش‌بینی میزان نیترات، مدل رگرسیون مناسب ارائه گردید. افزون بر آن، با داده‌های مشابه آموزش شبکه عصبی انجام شد. برای افزایش دقت پیش‌بینی و یافتن بهترین عملکرد شبکه عصبی، دو لایه مخفی با توپولوژی‌ها و توابع انتقال مختلف به کار برده شد و بر اساس نتایج به دست آمده، شبکه با ساختار ۱-۱۱-۱۲-۹ با کمترین مقدار میانگین مربعات خطا (۰/۰۳۶) به عنوان بهترین شبکه انتخاب گردید. برای واسنجی مدل‌ها از داده‌های متناظر ۶۰ نمونه که از بازار تهیه شده بود استفاده شد. این شبکه توانست با خطای نسبی ۹/۵ درصد در مقایسه با مدل رگرسیون با خطای نسبی ۱۵ درصد مقدار محتوای نیترات را دقیق‌تر تخمین بزند.

کلمات کلیدی: پردازش تصویر، رگرسیون، شبکه عصبی مصنوعی، گوجه‌فرنگی، ماشین بینایی، نیترات.



## Estimation of nitrate content in tomato with image processing extracted features

Seyed Mehdi Nassiri<sup>1</sup>, Abdolabbas Jafari<sup>2</sup>, Peyman Salamrudi<sup>3</sup>

- 1- Associate professor, Department of Biosystems Engineering, Shiraz University  
; [nasirii@shirazu.ac.ir](mailto:nasirii@shirazu.ac.ir)  
2- Associate professor, Department of Biosystems Engineering, Shiraz University; [ajafari@shirazu.ac.ir](mailto:ajafari@shirazu.ac.ir)  
3- M.Sc. Graduate student, Department of Biosystems Engineering, Shiraz University;  
[peymansalamrudi@gmail.com](mailto:peymansalamrudi@gmail.com)

### ABSTRACT

Inappropriate application of chemical fertilizers for crop production provides unsafe food source for consumers. As one of the case, nitrogen fertilizer results in nitrate accumulation in tomato fruit. In the present research, estimation of accumulated nitrate in tomato by computer vision was studied. Experiments were conducted in completely randomized design at four nitrogen levels of 400, 800, 1200 and 1600 kg.ha<sup>-1</sup>. Fifty samples were randomly selected from each treatment to prepare images. Samples were sliced with the same thickness and their images were prepared. Then, the nitrates of the same samples were measured in laboratory. Color features associated with the surface and slices and non-color features including white surface area (WSA), total slice surface area (TSA) and the ratio of white surface area to total slice surface area (WSA/TSA) were extracted. The results showed that increasing in nitrogen levels increased nitrate concentration in tomatoes. Statistical analysis signify correlation between color content of the slices, and the WSA and WSA/TSA with nitrate content. For prediction of tomato nitrate content, extracted features were used for establishing a regression model. In addition, same data were applied for training neural network. Several hidden layers with different topologies and transform functions were built and it was found that the MLP model with the structure of 9-12-11-1 was the best network (MSE: 0.036). Final models were verified by 60 extra samples. Neural network model with mean relative error (MRE) of 9.5 percent could estimate the nitrate contents more precise than regression model with 15 percent MRE.

**Keywords:** Image processing, Machine vision, Neural network, Nitrate, Regression, Tomato.

### ۱- مقدمه

گوجه‌فرنگی (*Lycopersicon esculentum* M.) یکی از محصولات 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 (Lugasi et al., 2003). 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. 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 ۲۰۱۴ ایران رتبه ششم تولید گوجه‌فرنگی دنیا را به خود اختصاص داده است. میزان تولید جهانی آن بیش از ۱۷۰ میلیون تن گزارش شده است که سهم ایران از کل میزان تولید ۳/۵ درصد است (Anonymous, 2014). گوجه‌فرنگی و سرانه مصرف بالای آن در ایران باعث شده است که سطح کشت بالایی را به خود اختصاص دهد. از اینرو برای افزایش بهره‌وری و عملکرد آن نیز از سموم و کودهای شیمیایی مختلفی استفاده می‌شود. چنانچه میزان استفاده از مواد شیمیایی در مراحل کشت گوجه‌فرنگی کنترل نشود، تجمع آنها در گوجه‌فرنگی آثار زیان‌باری برای مصرف‌کننده بدنال دارد. یکی از این موارد نیترات تجمع‌یافته در میوه‌ی گوجه‌فرنگی است که باعث ایجاد بافت سفید در آن می‌شود (Pascale et al., 2001). غلظت زیاد نیترات در مواد غذایی برای سلامتی انسان خطرناک است، بنابراین کنترل مقدار آن در محصولات گیاهی امری ضروری است (Ahmadi et al., 2014). در رشد بوته‌های گوجه‌فرنگی، تغذیه بهینه نیتروژن بسیار حائز اهمیت است، اما کاربرد زیاد نیتروژن نیز سبب رشد رویشی و تأخیر گلدهی خواهد شد (Manrique, 1993). مصرف بیش از حد کودهای نیتروژنه باعث افزایش غلظت نیترات در اندام‌های قابل مصرف محصولات زراعی به خصوص



## یازدهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران



انجمن مهندسی ماشین‌های کشاورزی و مکانیزاسیون ایران

Buali Sina University

سبزی‌ها می‌شود. بسیاری از سبزی‌ها نیتروژن نیتراته را در بافت‌های خود ذخیره می‌کنند. نیتروژن نیتراته سمی نبوده ولی برای اشخاصی که از این گونه سبزی‌ها مصرف می‌کنند مضر است. عموماً آلودگی نیتراتی بر اثر استفاده بی‌رویه و غیر علمی نیتروژن به وجود می‌آید (Malakooti and Tabatabaei, 1998). کود ازته مشخص‌ترین عاملی است که باعث تجمع نیترات در بسیاری از سبزیجات و گراس‌ها می‌شود (Mazaheri Tehrani et al., 2007).

مطالعات اخیر دانشمندان نشان داده است که بر اثر وجود نیترات و نیتريت در مواد غذایی در جهاز هاضمه‌ی (لوله یا مجرای است که در آن اعضای مختلفی جهت عبور غذا، تجزیه‌ی مواد غذایی یا هضم، جذب و دفع مواد جذب نشده انجام وظیفه می‌کنند) برخی از ترکیبات ازت مانند نیتروزامین بوجود می‌آید که در ایجاد سرطان و تومورهای مختلف زبان و مری و سایر اعضای بدن دخالت دارند و نیز در مقادیر زیاد ایجاد مسمومیت می‌نمایند. به همین لحاظ در مورد میزان نیترات در مواد غذایی در اکثر کشورها حد مجازی رعایت می‌گردد که 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 لازم است مطالعات گسترده‌ای در زمینه تعیین مقدار نیترات آن‌ها و سقف استاندارد مجاز نیترات در محصولات سبزی و سیفی صورت گیرد (Mazaheri Tehrani et al., 2007).

عامل‌های مختلفی در تجمع نیترات در گیاه اثر گذارند. قسمت‌های مختلف گیاهان استعداد ذخیره‌سازی متفاوتی در ذخیره نیترات دارند و بسته به گونه، رقم، قسمت‌های مختلف و سن گیاه، میزان تجمع نیترات در گیاهان متفاوت است. همچنین عامل‌های محیطی مختلفی بر میزان غلظت نیترات گیاه و میزان جذب آن اثر گذار است. روش کاربرد کود ازت، مقدار، منبع و سرعت آزاد شدن آن بر تجمع نیترات در گیاهان اثر مثبت دارد. در حقیقت کود ازت مشخص‌ترین عاملی است که باعث تجمع نیترات در بسیاری از سبزی‌ها می‌شود (Hoff and Wilcox, 1997). استفاده از پردازش تصویر برای تشخیص‌های مخرب یا غیر مخرب کیفیت در محصولات مختلف از جمله گوجه‌فرنگی صورت پذیرفته است. تشخیص آنتی‌اکسیدان‌های گوجه‌فرنگی متأثر از عوامل محیطی و مقدار نیتروژن مورد مطالعه قرار گرفت (Dumas et al., 2003). کاهش محتوای لیکوپن گوجه‌فرنگی و به تبع کاهش قرمزی طی مدت زمان نگهداری بررسی شد (Nassiri et al. 2014). رابطه قوی با ضریب تبیین ۰/۹۶۴ در این پژوهش گزارش شد. در پژوهش‌های دیگر نیز محتویات گوجه‌فرنگی که امکان درجه‌بندی کیفی را فراهم می‌سازد مورد مطالعه قرار گرفته است. به عنوان نمونه، امکان‌سنجی پیش‌بینی محتوای ترکیبات بیواکتیو و ترکیبات فنولی و لیکوپن میوه گوجه‌فرنگی با استفاده از پردازش تصاویر فراطیفی (Liu et al., 2015)، و کیفیت‌سنجی سطح میوه‌ی گوجه‌فرنگی بر اساس شاخص‌های رنگی برای تفکیک میوه‌ها (Zaborowicz et al., 2017) اشاره نمود. نتایج این پژوهش‌ها به ترتیب با دقت ۹۶ درصد و ۹۸ درصد پیش‌بینی و یا تفکیک را انجام دادند. در پژوهش حاضر رابطه‌ی بین ویژگی‌های ظاهری قابل استخراج توسط ماشین‌بینایی با میزان نیترات گوجه فرنگی و در نهایت ایجاد مدل شبکه عصبی برای تعیین میزان نیترات گوجه‌فرنگی با استفاده از ویژگی‌های استخراج شده مورد مطالعه قرار گرفت.

## ۲- مواد و روش‌ها

تعداد ۱۶۰ عدد نشاء گوجه‌فرنگی رقم Early Urbana از یک خزانه خریداری شد و بلافاصله در کرت‌های آماده شده در تاریخ ۱۱ تیر ۱۳۹۶ 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 ۲۰-۲۰-۲۰ گرومور استفاده شد. عناصر آهن (از منبع Fe-EDTA)، منیزیم (از منبع MgSO<sub>4</sub>.7H<sub>2</sub>O) و پتاسیم (از منبع K<sub>2</sub>SO<sub>4</sub>) به صورت تکمیلی به محلول غذایی اضافه شدند. آبیاری به صورت قطره‌ای و هر ۵ روز یک‌بار 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 یکبار در ساعت ۱۲ بعدازظهر صورت گرفت.

قبل از هر عکس‌برداری نمونه‌ها ابتدا شسته و خشک شدند و سپس توزین شدند. برای توزین نمونه‌ها ترازوی با دقت ۰/۱± گرم مورد استفاده قرار گرفت. در ادامه نمونه‌ها با ضخامت ۸ میلی‌متر برش زده شدند. برای اینکه تمام ورقه‌ها دارای ضخامت یکسان از یک قالب استفاده شد. عکس‌برداری در محفظه مخصوص با استفاده از دوربین Canon با وضوح ۱۲ مگاپیکسل (۳۰۰۰×۴۰۰۰ پیکسل)، و برای نورپردازی از ۴ عدد لامپ

<sup>1</sup> Grow More, made in USA, [www.growmore.com](http://www.growmore.com)



## یازدهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران



هالوژن استفاده شد. تصاویر با فرمت jpg ذخیره و به هر نمونه شماره‌ای اختصاص داده شد. عکس‌های تهیه شده به یک لپ‌تاپ (CPU core I5, RAM4GB) منتقل شد و با استفاده از نرم افزار MATLAB نسخه R2014b الگوریتم‌های مورد نیاز طراحی شد. پس از عکس‌برداری، نمونه‌ها برای آزمایش نیتروژن کل و پتاسیم آماده شدند.

آزمایش تعیین نیتروژن به روش کلدال (روش هضم، تقطیر و تیتراسیون) در بخش علوم خاک دانشگاه شیراز انجام گردید. 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 جمع آوری خواهد شد. سپس با تیتراسیون مقدار ازت آن تعیین شد (Anonymous, 2006).

برای اندازه‌گیری مواد معدنی نمونه‌های گیاهی در کوره با دمای ۵۰۰ درجه سانتی‌گراد 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. مقدار پتاسیم توسط دستگاه فلیم‌فتومتر اندازه‌گیری شد.

### ۱-۲- پردازش تصویر

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.




Figure 1. A sample for exposing white spots of images  
شکل ۱- نمونه آشکارسازی رگه‌های سفید در تصاویر

برای استخراج ویژگی‌های رنگی تصاویر از فضای رنگی RGB استفاده شد و مولفه‌های B، G، R 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.

برای مدل سازی از دو روش رگرسیون چند متغیره و شبکه‌های عصبی مصنوعی استفاده گردید. 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 این منظور برای یافتن مناسب‌ترین متغیرها از روش حذف رو به عقب استفاده شد. تمام داده‌های استخراج شده شامل ویژگی‌های رنگی سطح و داخل نمونه، تعداد پیکسل‌های سفید شمارش شده، نسبت پیکسل‌های سفید به کل و میزان نیتروژن اندازه‌گیری شده توسط نرم‌افزار Excel دسته‌بندی و برای تعلیم شبکه عصبی پرسپترون چند لایه استفاده شدند. برای پیش‌بینی میزان نیترات، ابتدا ویژگی‌های استخراج شده از واکاوی تصاویر و نتایج آزمایش نمونه‌ها به عنوان ورودی به شبکه داده شد تا قابلیت یادگیری شبکه مورد ارزیابی قرار گیرد. برای این منظور نمونه‌های اولیه را به شبکه اعمال می‌کنند. شبکه، سنج‌ها را بر اساس این نمونه‌ها تنظیم می‌کند. اگر نمونه‌های جدیدی به این شبکه‌ی آموزش دیده اعمال شود، خروجی مناسب را

<sup>5</sup> Backward elimination



با در صد خطای کوچک می‌توان بدست آورد. با این ترتیب شبکه‌های عصبی می‌توانند با تغییر شرایط به صورت هوشمندانه، خود را تطبیق یا اصلاح نمایند. تعیین تعداد لایه‌ها و این که در هر لایه چند نورون باید قرار گیرد نیز معمولاً به روش سعی و خطا انجام می‌شود تا شبکه‌ای بهینه طراحی شود. برای یافتن بهترین نگاشت بین مقادیر ورودی و خروجی در شبکه‌ی طراحی شده از دو لایه‌ی پنهان و از دو تابع انتقال سیگموئید تانژانتی و Softmax استفاده شد.

این آزمایش در قالب طرح کاملاً تصادفی انجام شد. برای واکاوی واریانس داده‌ها از نرم‌افزار SPSS 21 و برای تعیین اختلاف معناداری تیمارها از آزمون دانکن در سطح ۵ درصد استفاده گردید. برای ارزیابی هر دو مدل شبکه عصبی مصنوعی و رگرسیون چند متغیره از آزمون عدم برازش در سطح احتمال ۵٪ و از نرم‌افزار MINITAB 16 استفاده گردید. همچنین مقادیر میانگین خطای اریبی و شاخص توافق و میانگین خطای نسبی نیز برای هر مدل محاسبه و نتایج در قالب جدول ارائه گردید. سنجش ارزیابی میانگین خطای اریبی نشان دهنده‌ی این است که مدل، متغیر مورد نظر را کم یا زیاد برآورد می‌کند. این سنجش مطابق معادله زیر محاسبه شد (Quej et al., 2016):

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

$N$ : تعداد کل

$P_i$ : مقادیر پیش‌بینی شده

$O_i$ : مقادیر واقعی

شاخص توافق ( $d$ )، 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 ۱ متغیر است و هر چه این شاخص به ۱ نزدیک‌تر باشد سازگاری دو متغیر بیشتر است (دارند و زند کریمی، ۱۳۹۴). برای محاسبه شاخص توافق از رابطه زیر استفاده شد (Deo & Sahin, 2015):

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

$N$  تعداد کل،  $P_i$  مقادیر پیش‌بینی شده،  $O_i$  مقادیر واقعی، و  $\bar{O}$  میانگین مقادیر واقعی است.

شاخص میانگین خطای نسبی (MRE) نیز برای ارزیابی خطای مدل‌ها محاسبه شده مقدار کمتر این شاخص برای مدل نشانگر بالاتر بودن دقت مدل است. این شاخص مطابق رابطه زیر محاسبه گردید (Genel et al., 2003):

$$MRE = \frac{1}{n} \sum_{i=1}^n \frac{|d_i - o_i|}{d_i} \times 100 \quad (3)$$

$o_i$  مقادیر پیش‌بینی شده،  $d_i$  مقادیر واقعی، و  $n$  تعداد کل داده‌ها است.

برای ارزیابی از داده‌های استخراج شده از گوجه‌فرنگی‌های خریداری شده استفاده شد.

<sup>6</sup> Lack of fit

<sup>1</sup> Mean bias error (MBE)

<sup>2</sup> Index of agreement (d)

<sup>3</sup> Mean relative error (MRE)



### ۳- نتایج و بحث

با توجه به نتایج تجزیه‌ی واریانس جدول ۱ مشاهده می‌شود که تاثیر تیمارها بر میزان نیترات نمونه‌ها در سطح ۱ درصد معنادار بوده است و افزایش سطوح نیتروژن باعث افزایش غلظت نیترات در نمونه‌ها شده است. نتایج مشابهی برای افزایش میزان نیترات ذخیره شده در گوجه در پی افزایش کود نیتروژن دار گزارش شده است که با نتایج ارائه شده در این پژوهش مطابقت دارد (Jalini and Dosti, 2012; Soto et al., 2015).

جدول ۱- اثر سطوح نیتروژن اعمال شده بر میزان نیترات نمونه‌ها (درصد)  
**Table 1. Effect of nitrogen levels on samples nitrate contents (percent)**

Source of Variations	df.	SS	MS	F
Nitrogen	3	85.1	28.4	85.2 **
Error	196	65.3	0.3	
Total	199	150.3		

\*\* نشان دهنده‌ی معناداری در سطح احتمال ۱ درصد است.

نتایج جدول مقایسه‌ی میانگین (جدول ۲) نشان می‌دهد که با افزایش سطح نیتروژن، میانگین مقادیر نیترات در نمونه‌ها روند افزایشی را در پی داشته است.

جدول ۲- آزمون مقایسه‌ی میانگین برای میزان نیترات تیمارها

**Table 2. Mean comparison of nitrate contents**

Nitrogen level (kg/ha)	Nitrate content (%)
400	1.6±0.4 <sup>c</sup>
800	2.7±0.7 <sup>b</sup>
1200	2.8±0.7 <sup>b</sup>
1600	3.3±0.5 <sup>a</sup>

حروف مشابه نشان دهنده‌ی عدم تفاوت معنادار در سطح احتمال ۵ درصد است.

بدنبال این نتایج، اثر نیتروژن بر مولفه‌های رنگی گوجه‌فرنگی روی سطح میوه و در داخل آن (ورقه‌ها) بررسی شد. نتایج مربوط به مقایسه مقادیر میانگین R، G و B استخراج شده از سطح نمونه‌ها و همچنین ورقه‌ها در جدول ۳ درج شده است. مطابق این نتایج، سطوح نیتروژن بر مولفه‌های رنگی اندازه‌گیری شده از ورقه‌ها برخلاف مقادیر متناظر روی سطح 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 (Semary et al., 2015; Goel and Sehgal, 2015). 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 را گزارش کردند (Dumas et al., 2003; Nassiri et al., 2014).

جدول ۳- مقایسه میانگین مقادیر مولفه‌های رنگی استخراج شده از سطح و ورقه‌ها گوجه‌فرنگی

**Table 3. Mean comparison for extracted color components from tomatoes' surface and slices**

Nitrogen level (kg/ha)	Slices			Surface		
	R	G	B	R	G	B
400	193.0±2.3 <sup>a</sup>	93.7±6.3 <sup>c</sup>	67.5±3.9 <sup>d</sup>	216.8±7.2 <sup>a</sup>	19.0±5.4 <sup>a</sup>	24.7±7.2 <sup>a</sup>
800	185.2±2.0 <sup>b</sup>	101.0±7.6 <sup>b</sup>	73.6±6.8 <sup>c</sup>	216.8±7.2 <sup>a</sup>	19.4±5.1 <sup>a</sup>	23.0±7.2 <sup>a</sup>
1200	176.5±3.5 <sup>c</sup>	103.1±8.4 <sup>b</sup>	75.9±5.2 <sup>b</sup>	216.7±2.9 <sup>a</sup>	19.1±4.6 <sup>a</sup>	23.0±5.0 <sup>a</sup>
1600	166±4.2 <sup>d</sup>	106.5±6.8 <sup>a</sup>	82.1±5.7 <sup>a</sup>	216.3±5.2 <sup>a</sup>	18.0±5.1 <sup>a</sup>	23.6±6.6 <sup>a</sup>

در هر ستون حروف مشابه نشان دهنده‌ی عدم تفاوت معنادار در سطح احتمال ۵ درصد است.



## یازدهمین کنگره ملی مهندسی مکانیک بیوسیستم و مکانیزاسیون ایران



با توجه به تاثیر معنادار مقدار نیتروژن بر خصوصیات رنگی ورقه‌ها، همبستگی بین مولفه‌ها و مقدار نیترات موجود در نمونه‌ها محاسبه شد (جدول ۴). همچنین ضرایب همبستگی بین مقادیر نیترات و ویژگی‌های غیر رنگی نیز محاسبه شد (جدول ۵). همبستگی قوی مساحت پیکسل‌های سفید با محتوای نیترات نشان می‌دهد افزایش سطوح نیتروژن باعث کاهش لیکوپن گوجه و در نتیجه افزایش مساحت پیکسل‌های سفید شده است (Dumas *et al.*, 2003).

جدول ۴- ضرایب همبستگی بین مقادیر نیترات و ویژگی‌های رنگی

Table 4. Correlation coefficients between nitrate content and color components

Slices			Surface		
R	G	B	R	G	B
0.79	0.77	-0.75	-0.058	-0.063	-0.065

جدول ۵- ضرایب همبستگی بین مقادیر نیترات و ویژگی‌های غیر رنگی ورقه‌ها

Table 5. Correlation coefficients between nitrate content and non-color features of slices

WPA/TSA	WPA	TSA
0.80	0.91	0.58

WPA, TSA و WPA/TSA به ترتیب مساحت کل سطح، مساحت پیکسل‌های سفید، و نسبت مساحت پیکسل‌های سفید به مساحت کل سطح ورقه‌ها است.

با در نظر گرفتن مقادیر قوی همبستگی خصوصیات رنگی و غیر رنگی ورقه‌ها، مدل شبکه عصبی و رگرسیون چند متغیره برقرار شد. از تمام ویژگی‌های رنگی (R, G و B) و غیر رنگی ورقه‌ها شامل مساحت پیکسل‌های سفید، مساحت کل ورقه‌ها و نسبت مساحت پیکسل‌های سفید به مساحت کل ورقه‌ها برای تعیین رابطه‌ی رگرسیونی تخمین محتوای نیترات نمونه‌ها استفاده شد. با توجه به مقادیر ضریب تبیین حاصل از مدل‌های مختلف رگرسیون رابطه انتخاب شده نهایی بر اساس بیشترین ضریب تبیین (۰/۸۸۱) به صورت زیر انتخاب شد.

$$N = 3 \times 10^{-6} WPA - 0.006 R + 0.007 G + 0.014 B + 0.647 \quad (4)$$

که N نیترات، R مقادیر قرمز ورقه‌ها، G مقادیر سبز ورقه‌ها، B مقادیر آبی ورقه‌ها و WPA مساحت پیکسل‌های سفید ورقه‌ها است. تمام ویژگی‌های استخراج شده از نمونه‌ها برای تعلیم یک شبکه‌ی عصبی با کمترین میزان انتشار خطا به کار گرفته شد که قادر به تخمین میزان نیترات با شد. نتایج این شبکه در جدول ۶ نشان داده شده است. شبکه عصبی تولید شده با توپولوژی ۹-۱۲-۱۱-۱ و تابع انتقال سیگموئید تانژانتی مناسب‌ترین شبکه بوده و نسبت به سایر ساختارهای تولید شده توانست عملکرد بهتری را از خود نشان دهد. تابع Tansig نسبت به تابع انتقال Softmax مقادیر خطای کمتری ایجاد نمود.

جدول ۶- آماره شبکه‌ی عصبی با توپولوژی‌های مختلف

Table 6. Statistics of different neural network topologies

Topology	Transfer function	RMSE	MSE	Epochs
9-9-11-1	Softmax	6.19	0.086	26
9-11-11-1	Softmax	5.81	0.085	25
9-12-11-1	Softmax	6.29	0.102	16
9-9-11-1	Tansig	0.38	0.060	17
9-11-11-1	Tansig	0.58	0.053	15
<b>9-12-11-1</b>	<b>Tansig</b>	<b>0.23</b>	<b>0.036</b>	<b>13</b>

با توجه به شکل ۲، شبکه تولید شده با ساختار ۹-۱۲-۱۱-۱ با چرخه‌ی آموزش ۱۳ و تابع انتقال سیگموئید تانژانتی قادر به پیش‌بینی میزان نیترات نمونه‌ها با ضریب همبستگی ۰/۹۲ بود. استفاده هم‌زمان از ویژگی‌های رنگی و غیر رنگی برای آموزش شبکه باعث افزایش دقت شبکه و کاهش خطا شد.

برای واسنجی هر دو مدل رگرسیون و شبکه عصبی از ۶۰ داده که جداگانه خریداری شده بود استفاده شد. برای این منظور همه خصوصیات رنگی و غیر رنگی نمونه‌ها، و همچنین محتوای نیترات آن‌ها مجدداً محاسبه و اندازه‌گیری شد. سپس خروجی هر دو مدل در مقابل مقادیر واقعی ترسیم شد (شکل‌های ۳ و ۴) و آماره‌های پیش معرفی شده (ریشه میانگین مربعات خطا، میانگین خطای اریبی، شاخص توافق و میانگین خطای نسبی)






Figure 2. Statistics of selected neural network

شکل ۲- شاخص‌های آماری شبکه عصبی منتخب

شاخص آماری ضریب تبیین  $0/881$  (معادل ضریب همبستگی  $0/939$ ) نشان دهنده رابطه قوی خطی بین داده‌ها حکایت دارد. این رابطه دارای ریشه میانگین مربعات خطا (RMSE) معادل  $0/48$  بود. با توجه به شکل ۵ و انحراف مدل واسنجی از خط یک به یک، میانگین خطای اریبی (MBE)  $0/27$  مثبت بود که نشان دهنده این است که در مجموع  $27$  درصد داده‌ها توسط مدل بیش تخمین محاسبه می‌شود. مقدار شاخص توافق (d) برای این مدل  $0/86$  محاسبه شد که نشان دهنده نزدیک بودن مقادیر پیش‌بینی شده به مقادیر واقعی است. با توجه به مقدار میانگین خطای نسبی (MRE) حدود  $15$  درصد می‌توان بیان داشت مدل رگرسیون دارای میانگین خطای  $15$  درصد است.

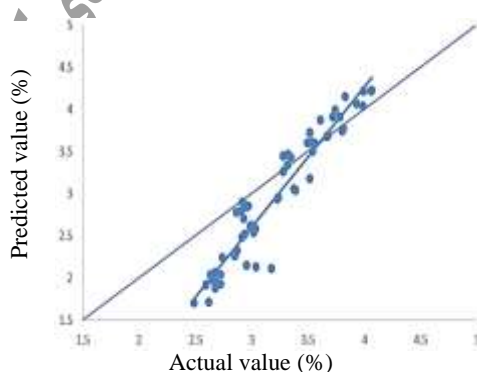



Figure 3. Verification of regression model (Actual vs. predicted values)

شکل ۳- واسنجی مدل رگرسیون (مقادیر واقعی در مقابل مقادیر تخمین زده شده)

روش مشابه برای واسنجی مدل شبکه عصبی مصنوعی دنبال شد. مطابق شکل ۶ و مقدار ضریب تبیین  $0/79$  (معادل ضریب همبستگی  $0/889$ ) رابطه خطی قوی برای داده‌ها متصور است. این رابطه خطی دارای ریشه میانگین مربعات خطای  $0/21$  است که نسبت به واسنجی مدل رگرسیون ( $0/47$ ) از پراکنش کمتری برخوردار است. مقدار میانگین خطای اریبی (MBE) واسنجی شبکه  $0/03$  محاسبه شد. این مقدار در مقایسه با مدل رگرسیون نشان می‌دهد داده‌ها پیرامون خط یک به یک متمرکز هستند و شبکه در تخمین از دقت بالاتری برخوردار است. مقدار بیش تخمینی در حدود  $3$  درصد داده‌ها صورت می‌گیرد که در مقایسه با مدل رگرسیون ( $27$  درصد) قابل چشم‌پوشی است. این خطای کم‌تر را شاید بتوان به



تعداد بیشتر داده‌های ورودی و همچنین تعلیم شبکه نسبت داد.



**Figure 4. Verification of neural network model (Actual vs. predicted values)**

شکل ۴- واسنجی مدل شبکه عصبی مصنوعی (مقادیر واقعی در مقابل مقادیر تخمین زده شده)

شاخص توافق (d) ۰/۹۴ نیز از فاصله جزیی مدل واسنجی با خط یک به یک دارد. در نهایت شبکه عصبی مصنوعی با میانگین خطای نسبی ۹/۵ درصد در تخمین نیترا ت موجود در گوجه‌فرنگی از دقت بیشتری نسبت به مدل رگرسیون برخوردار بود.

#### ۴- نتیجه‌گیری

در این پژوهش سعی شد میزان نیترا ت ذخیره شده در بافت گوجه‌فرنگی با کمک پردازش تصویر تخمین زده شود. نتایج نشان داد که برخی از ویژگی‌های استخراج شده از تصاویر از جمله ویژگی‌های رنگی ورقه‌ها و محتوای سفید و نسبت مساحت سفید ورقه‌ها به مساحت کل رابطه بالایی با محتوای نیترا ت دارند. از دو مدل رگرسیون چندگانه و شبکه عصبی پرسپترون با دو لایه مخفی برای پیش‌بینی مقادیر نیترا ت استفاده شد. نتایج نشان داد که شبکه عصبی با خطای نسبی ۹/۵ درصد در مقابل ۱۵ درصد خطای نسبی مدل رگرسیون از دقت بیشتری در تخمین محتوای نیترا ت برخوردار است.

#### ۵- مراجع

- Ahmadi, H., Delshad, M. & Babalar Effect of K and N .(2014). concentrations on nutrientsolution on growth and quality of tomatotransplants *Iranian Journal of Horticultural Sciences*, 45(2), 197-205. (Persian) .
- Anonymous, (2006). AOCS. Official Methods and Recommended Practices of the American Oil Chemists Society (Ai 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>
- Anonymous, (2014). FAO statistics: Crop product. Available at: <http://www.fao.org>.
- Deo, R. C., & 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.
- Dumas, Y., Dado, 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.
- Genel, K., Kurnaz, S. C., & Durman, M. (2003). Modeling of tribological properties of alumina fiber reinforced zinc-aluminum composites using artificial neural network. *Materials Science and Engineering*, 363(2), 203-210.



- 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.
- Hoff, J. E., & Wilcox, G. E. (1997). Accumulation of nitrate in tomato fruit and its effect on detinning. *Journal of the American Society of Horticultural Science*, 95, 92-4.
- 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.
- Lugasi, A., Bíró, L., Hóvárie, J., Sági, K. V., Brandt, S., & Barna, É. (2003). Lycopene content of foods and lycopene intake in two groups of the Hungarian population. *Nutrition Research*, 23(8), 1035-1044.
- Jalini, M. & Dosti, F. (2012). Study of nitrate accumulation in potato and tomato products. Quarterly Journal of Environmental Science and Engineering, 50, 62-71. (Persian)
- 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. Neshre Amozesh Keshavarzi Publication. Karaj, Iran. (Persian)
- Manrique, L. A. (1993). Greenhouse crops: A review. *Journal of Plant Nutrition*, 16(12), 2411-2477.
- Mazaheri Tehrani, M., Mortazavi, S. A., Ziaolhagh, H. R. & Ghandi, A. (2007) Tomato production and processing. Volume 1. Marzedanesh Publication, Tehran. Iran. (Persian)
- 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. (Persian)
- 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 of Horticultural Science and Biotechnology*, 76(4), 447-453.
- Quej, V. H., Almorox, J., Ibrakhimov, M., & Saito, E. (2016). Empirical models for estimating daily global solar radiation in Yucatán Peninsula, Mexico. *Energy Conversion and Management*, 110, 448-456.
- 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.
- 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*, 200, 62-70.
- 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.