

## تعیین ارتفاع برش برگ پیاز با استفاده از پردازش تصویر و شبکه عصبی مصنوعی

محسن حیدری سلطان‌آبادی<sup>۱\*</sup>، بابک بهشتی<sup>۲</sup>، مسلم افروز<sup>۳</sup> و محمدرضا ابراهیم‌زاده<sup>۴</sup>

### چکیده

حذف برگ پیاز یکی از مراحل برداشت این محصول است که عمدتاً به صورت دستی و با صرف هزینه و وقت زیاد انجام می‌شود. از جمله ماشین‌های مورد استفاده در برگ‌زنی مکانیزه پیاز، سرزن غلتکی است. در تحقیق حاضر توده‌ای از پیازها در چهار دسته بر اساس اندازه قطر تقسیم‌بندی شدند. سپس با استفاده از پردازش تصویر، شاخص قطر غده‌ها بر حسب پیکسل تعیین گردید. در ادامه با به‌کارگیری شبکه عصبی چندلایه بردار یادگیر (LVQ) پیازها بر حسب اندازه شاخص قطر در چهار گروه طبقه‌بندی شدند. پیازها در دستگاه سرزن غلتکی سرزنی شده و ارتفاع برش برگ روی غده به روش دستی ثبت گردید. در گام بعدی ارتفاع برش برگ پیاز هر گروه با استفاده از شبکه عصبی پرسپترون چندلایه (MLP) پیش‌بینی گردید. برای ارزیابی شبکه عصبی LVQ از شاخص‌های دقت، صحت، حساسیت و اختصاصی بودن طبقه‌بندی و برای تعیین دقت شبکه عصبی MLP از آماره‌های ریشه میانگین مربعات خطا و میانگین خطای مطلق استفاده شد. نتایج نشان داد که شبکه عصبی LVQ توانست پیازها را با دقت کلی ۹۲/۲۵ درصد طبقه‌بندی نماید. همچنین شبکه عصبی MLP ارتفاع برش برگ‌ها را با مقادیر ضریب تعیین ( $R^2$ )، ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (AME) به ترتیب ۰/۹۹، ۰/۰۵ و ۰/۰۴ پیش‌بینی نمود. از نتایج این پژوهش می‌توان در طراحی و راه‌اندازی سامانه‌های تنظیم خودکار برای تیغه‌های برش سرزن پیاز استفاده نمود.

**واژه‌های کلیدی:** پردازش تصویر، چندلایه‌ساز بردار یادگیر، سرزن پیاز، شبکه عصبی مصنوعی.

**ارجاع:** حیدری سلطان‌آبادی م. بهشتی ب. افروز م. و ابراهیم‌زاده م. ر. ۱۴۰۰. تعیین ارتفاع برش برگ پیاز با استفاده از پردازش تصویر و شبکه عصبی مصنوعی. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی. ۲۰: ۲۱-۳۰.

۱- استادیار پژوهشی، بخش تحقیقات فنی و مهندسی کشاورزی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان اصفهان، سازمان تحقیقات، آموزش و ترویج کشاورزی، اصفهان، ایران.

۲- استادیار گروه مکانیک ماشین‌های کشاورزی، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران، ایران.

۳- دانش‌آموخته دکتری، گروه مکانیک ماشین‌های کشاورزی، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران، ایران.

۴- استادیار گروه کشاورزی، دانشگاه آزاد اسلامی واحد یادگار امام خمینی (ره) شهرری، تهران، ایران.

\* نویسنده مسئول: [mheisol@gmail.com](mailto:mheisol@gmail.com)

تاریخ پذیرش: ۱۳۹۹/۱۱/۲۷

تاریخ دریافت: ۱۳۹۹/۰۸/۲۱

## مقدمه

مکانیزاسیون مراحل مختلف تولید پیاز خوراکی از جمله مرحله برداشت با هدف کاهش هزینه‌ها و افزایش کیفیت محصول از اهمیت خاصی برخوردار است. تاکنون دستگاه‌های مختلفی برای سرزنی مکانیزه پیاز در کشور معرفی شده است. از آن جمله می‌توان به مکانیزم شلاقی، تیغه دوار افقی و سرزن غلتکی پشت تراکتوری اشاره کرد. در سرزن غلتکی پشت تراکتوری، بعد از مرتب شدن پیازهای برگ‌دار بر روی غلتک‌های مرتب کننده، برگ پیاز توسط چرخش دو تیغه قطع می‌شود. بر اساس تحقیقات، طول برگ باقی‌مانده بر روی غده پیاز پس از سرزنی نقش مهمی در کیفیت و بازاریابی آن دارد. مقدار مناسب این طول کمتر از یک سانتی‌متر است. از طرفی سرزنی عمیق پیاز ممکن است به بافت محصول آسیب وارد کند (Heidarisoltanabadi et al., 2013). از این‌رو تنظیم دقیق دستگاه سرزن برای برش مناسب برگ‌ها حائز اهمیت است. استفاده از روش‌هایی مانند پردازش تصویر و شبکه‌های عصبی مصنوعی می‌تواند مقدمه‌ای بر معرفی روش‌های تنظیم خودکار سرزن پیاز باشد.

پردازش تصویر عبارت است از هر نوع پردازش سیگنال که بر روی یک تصویر انجام می‌شود. خروجی پردازش‌گر تصویر می‌تواند یک تصویر یا مجموعه‌ای از متغیرهای مربوط به تصویر باشد. از جمله این متغیرها می‌توان به بافت، ابعاد، رنگ و شکل محصولات مختلف اشاره کرد. در این راستا محققان زیادی از پردازش تصویر برای استخراج خصوصیات یاد شده بهره برده‌اند. (Boniek et al., 2015; Zhang et al., 2014; Nozari & Mazlomzadeh, 2013; Rong et al., 2012; Razak et al., 2017). امروزه شبکه‌های عصبی مصنوعی کاربرد فراوانی در حل مسائل مختلف و در علمی مانند کشاورزی دارند. به عنوان مثال از این تکنیک در پیش‌بینی سینتیک تغییرات رطوبتی محصول (Mohebbi et al., 2007)، پیش‌بینی رطوبت خاک (Chang and Islam, 2000)، ارزیابی کیفیت آب (Zhang et al., 2002)، درجه‌بندی محصولات کشاورزی (Iraji and Tosinia, 2011; Shahin et al., 2001; Qiaohua et al., 2017)، تعیین حجم (Jafarlou & Farrokhi Teimourlou, 2014) و تعیین صدمات مکانیکی محصولات کشاورزی (Golzarian et al., 2017) استفاده شده است. همچنین شبکه‌های عصبی در طبقه‌بندی داده‌ها کاربردهای فراوانی پیدا کرده‌اند. در

طبقه‌بندی یا کلاس‌بندی، داده‌ها بر اساس معیارهایی به دسته‌هایی تقسیم‌بندی شده و عنوان‌دهی می‌شوند. به عنوان مثال در درجه‌بندی، محصولات مختلف بر اساس ویژگی‌هایی مانند رنگ، ابعاد و شکل ظاهری طبقه‌بندی می‌شوند. از جمله شبکه‌های عصبی پرکاربرد در طبقه‌بندی می‌توان به شبکه‌های عصبی چندساز بردار یادگیر<sup>۱</sup> (LVQ)، پرسپترون چندلایه<sup>۲</sup> (MLP) و بردار پشتیبان<sup>۳</sup> (SVM) اشاره کرد. به منظور پیش‌بینی و ترسیم نقشه توزیع جمعیت علف‌هرز تلخه از شبکه‌های عصبی LVQ و MLP در سطح مزرعه استفاده شد. نتایج نشان داد که شبکه عصبی آموزش دیده LVQ دارای قابلیت بالایی در پیش‌بینی مکانی علف‌هرز در نقاط نمونه‌برداری نشده با خطای تشخیص کمتر از ۰/۶۴ درصد بود (Rohani & Makarian, 2011). در پژوهشی، مدل شبکه عصبی LVQ برای مطالعه توزیع مکانی حشرات در اراضی مرتعی استفاده شد و کارایی مطلوبی نشان داد (Zhang et al., 2008). دیگر محققان میزان آلودگی پانیکول برنج به بیماری بلاست را با استفاده از شبکه عصبی LVQ به چند سطح سالم، با آلودگی کم، متوسط و شدید طبقه‌بندی کردند، سپس بر اساس آستانه آلودگی مورد نظر اقدام به کنترل بیماری نمودند (Zhang et al., 2010). به منظور شناسایی و تشخیص شش آفت درختان سیب از تصاویر دیجیتال و شبکه عصبی LVQ استفاده شد. مطابق نتایج این آزمون، روش به کار برده شده با جذر میانگین مربعات خطای ۰/۱۲ دقت مناسبی در تشخیص آفات داشت (Boniecki et al., 2017). در تحقیق دیگری شبکه عصبی LVQ برای تشخیص و دسته‌بندی سه بیماری عمومی محصول سیب به کار برده شد. به این منظور پس از اخذ تصاویر از سیب‌های آلوده و پردازش تصویر آنها، شبکه عصبی بر اساس خصوصیات استخراج شده از تصاویر، نوع بیماری را با دقت ۹۵ درصد مشخص نمود (Jamdar & Patil, 2017). نتایج یک پژوهش نشان داد که با دقت ۸۹ درصد می‌توان از شبکه عصبی LVQ در تشخیص و معرفی ارقام مختلف میوه دورین<sup>۴</sup> بر اساس ویژگی‌های شکل، رنگ و بافت استفاده نمود (Sutarno & Fauliah, 2019). در مطالعه‌ای برای

1- Learning Vector Quantization

2- Multi-Layer Perceptron

3- Support Vector Machine

4- Durio zibethinus

(Pormah, 2017). طبق نتایج دقت درجه‌بندی یا طبقه‌بندی هویج‌ها در دو روش پرسپترون (MLP) و ماشین بردار پشتیبان (SVM) به ترتیب ۹۸/۵ و ۸۹/۶۲ درصد گزارش گردید (Jahanbakhshi & Kheiralipour, 2019). همان‌گونه که بیان شد سرزنی مکانیزه پیاز مستلزم تنظیم مناسب ارتفاع برش برگ پیاز است. در صورتی که بتوان طول برگ باقی‌مانده هر پیاز را قبل از سرزنی و بر اساس ابعاد پیاز پیش‌بینی کرد، امکان تنظیم خودکار قسمت برش دستگاه فراهم خواهد شد. تحقیق حاضر با هدف استفاده از پردازش تصویر و شبکه‌های عصبی مصنوعی در طبقه‌بندی پیازها و پیش‌بینی ارتفاع برش برگ آنها در یک دستگاه سرزن غلتکی انجام شد.

### مواد و روش‌ها

از جمله الگوریتم‌های شبکه عصبی که برای کلاس‌بندی به کار می‌رود، الگوریتم LVQ است (Abry, et al., 2015). در شبکه LVQ یادگیری رقابتی با نظارت همراه است. پس به یک مجموعه نمونه‌های ورودی - خروجی آموزشی، مطابق معادله (۱) نیاز است (Shahbazi et al., 2009):

$$\{(p^i, t^i), i = 1, 2, 3, \dots, Q\} \quad (1)$$

که در آن  $p^i$  بردار ورودی در مرحله  $i$ ام آموزش و  $t^i$  بردار پاسخ مطلوب مربوط به آن است. در هر تکرار، بردار ورودی به شبکه اعمال و سپس فاصله بین بردار ورودی با هر یک از بردارهای نمونه محاسبه می‌شود. نوروں‌های لایه میانی به رقابت می‌پردازند و نوروں برنده پس از مشخص شدن، دارای خروجی یک و دیگر نوروں‌ها دارای خروجی صفر می‌شوند (معادله (۲)).

$$\begin{cases} a_{i^*}^1 = 1 \\ a_i^1 = 0 \quad \forall i \neq i^* \end{cases} \quad (2)$$

سپس برای محاسبه بردار خروجی لایه دوم، مطابق روابط زیر عمل می‌شود:

$$a_i^2 = W^2 a_i^1 \quad (3)$$

$$\begin{cases} w_{ji}^2 = 0 & j \neq j^* \\ & i = 1, 2, \dots, S_1 \\ & j = 1, 2, \dots, S_2 \\ w_{ji}^2 = 1 & j = j^* \end{cases} \quad (4)$$


که در آن،  $a^2$  خروجی لایه دوم،  $a^1$  خروجی لایه اول،  $W^2$  ماتریس وزن لایه دوم،  $j^*$  طبقه‌ای که بردار ورودی در آن تعلق دارد، عبارت  $a^2$  تنها یک عنصر غیر صفر مانند  $j^*$  دارد. سپس قانون یادگیری کوهنن (Kohonen, 1972) برای

تشخیص چهار نوع برگ گیاه سویا شبکه عصبی LVQ به کار رفت. خصوصیات برگ‌ها شامل چهار خصوصیت رنگ و دو خصوصیت بافت برگ بود. توسط این شبکه برگ‌ها با دقت ۹۳ درصد جانمایی شدند (Jadhav et al., 2019). در پژوهشی دیگر محققان به تفکیک سیب‌زمینی از کلوخه‌ها بر اساس پاسخ صوت و تفکیک پاسخ‌ها با استفاده از روش LVQ پرداختند. دقت تشخیص روش یاد شده به میزان ۹۶ درصد گزارش گردید (Mesri Gundoshmian et al., 2011). کاربرد شبکه‌های عصبی MLP و LVQ در تشخیص و جداسازی گردوهای سالم و پوک نیز گزارش گردیده است. در این روش خصوصیات استخراجی از تحلیل صدای برخورد گردوها در مسیر به عنوان ورودی و سالم یا پوک بودن گردو به عنوان خروجی دو شبکه یاد شده در نظر گرفته شد. دقت تشخیص گردوی سالم در شبکه MLP و LVQ به ترتیب ۹۹/۷ و ۹۷/۵ درصد به دست آمد (Dousti et al., 2013). در پژوهشی برای دسته‌بندی نمونه‌های برنج در سه دسته مختلف از شبکه عصبی LVQ4 استفاده شد. دقت دسته‌بندی به ترتیب برای سه رقم فجر، شیرودی و طارم با استفاده از ویژگی‌های ماتریس سطوح خاکستری ۹۷/۹۶، ۱۰۰ و ۹۷/۸۳ درصد، ماتریس هم‌وقوعی ۹۶/۲۳، ۱۰۰ و ۱۰۰ درصد، ماتریس الگوی دودویی محلی ۱۰۰، ۹۷/۵ و ۱۰۰ درصد و با استفاده از ماتریس همه ویژگی‌های یاد شده ۱۰۰، ۹۷/۶۷ و ۱۰۰ درصد به دست آمد. این نتایج نشان داد که پردازش تصویر ابزار مناسبی برای شناسایی ارقام مختلف برنج است (Fayyazi et al., 2014). در مطالعه‌ای کنترل خودکار کیفیت گوجه فرنگی براساس به‌کارگیری شبکه‌های عصبی SVM، LVQ و MLP در دسته‌بندی ویژگی‌های به‌دست آمده از پردازش تصویر، مورد بررسی قرار گرفت. نتایج نشان داد که SVM نسبت به روش‌های دیگر دقت بیشتری داشت (Shadro et al., 2007). در تحقیق مشابهی دقت طبقه‌بندی الگوریتم SVM در کلاس‌بندی انواع میوه بر اساس شکل ۸۸/۲ درصد به‌دست آمد (Yudong & Lenan, 2012). دقت طبقه‌بندی میوه پرتقال بر حسب رنگ و بافت توسط شبکه عصبی RBF حدود ۹۷/۲۵ درصد برآورد گردید (Capizzi et al., 2015). همچنین پیاز با استفاده از شبکه عصبی با دقت ۹۰ درصد در دو گروه سالم و خراب طبقه‌بندی شد (Shahin et al., 2002). محصول خیار با دقت ۹۷/۱ درصد توسط شبکه عصبی مصنوعی MLP طبقه‌بندی شد (Kheiralipour &

میانگین ارتفاع برش برگ توسط شبکه عصبی MLP قابل پیش‌بینی خواهد بود. از این اطلاعات می‌توان در تنظیم خودکار ارتفاع برش تیغه‌ها استفاده کرد.

### مراحل پردازش تصویر

تصاویر مربوط به ۴۰۰ عدد پیاز رقم سفید نگراس با قطرهای مختلف با استفاده از یک دوربین عکاسی Canon مدل EOS 760D (ساخت ژاپن) تهیه گردید. با توجه به این‌که تصویربرداری صحیح و دقیق از پیازها نقش به‌سزایی در دقت پردازش تصویر دارد، برای رسیدن به این هدف مطابق شکل ۳ گیره‌ای طراحی شد که در آن فاصله دوربین تا محل تصویربرداری قابل تنظیم بود. جهت تأمین نور کافی از یک لامپ فلورسنت حلقوی استفاده شد. بعد از رسیدن هر پیاز در زیر دوربین، حرکت سرزن متوقف و عملیات تصویربرداری انجام می‌شد. سپس به پیاز اجازه داده می‌شد تا به مسیر خود روی غلتک‌های سرزن ادامه داده و عملیات قطع برگ انجام پذیرد.



شکل ۱- ساختمان شبکه عصبی LVQ



شکل ۲- دستگاه سرزن غلتکی پیاز

تنظیم پارامترهای لایه میانی شبکه LVQ به شکل معادله (۵) به کار می‌رود:

$$\exists a_j^2 = t_j^*(k+1) = 1 \Rightarrow w_{i^*}^1(k+1) = w_{i^*}^1(k) + \alpha(p^T(k+1) - w_{i^*}^1(k)) \quad (5)$$

عبارت  $\alpha$  نرخ یادگیری شبکه یا تغییر وزن‌ها در هر مرحله است. در این حالت  $p$  به درستی طبقه‌بندی شده است. بنابراین بردار وزن  $w_{i^*}^1$  از نورون برنده در لایه مخفی به سمت بردار ورودی  $p$  حرکت می‌کند (معادله (۶)).

که در این حالت  $p$  به درستی طبقه‌بندی نشده است. بنابراین این نورون به غلط برنده رقابت شده است و بردار  $w_{i^*}^1$  از بردار  $p$  دور می‌شود. در شکل ۱ ساختمان یک شبکه رقابتی LVQ نشان داده شده است. در شبکه LVQ هر نورون در لایه دوم، به سمت بردارهایی حرکت می‌کند که به طبقه‌هایی تعلق دارد که آن نورون، زیر طبقه‌ای را در آن می‌سازد. این نورون برعکس، از بردارهای ورودی که به طبقات دیگر تعلق دارند، دور می‌شود.

به منظور اندازه‌گیری ارتفاع برش برگ پیاز در یک دستگاه سرزن غلتکی از روش پردازش تصویر و شبکه‌های عصبی مصنوعی استفاده شد. نمونه اولیه دستگاه سرزن پشت تراکتوری قبلاً ساخته شده بود (شکل ۲). مشخصات سرزن در جدول ۱ نشان داده شده است. در این روش ابتدا تصاویری از پیازها در حالتی که برای سرزنی آماده بودند، گرفته شد. سپس به کمک پردازش تصاویر به دست آمده، اندازه شاخص قطر هر غده به صورت شمارش پیکسل استخراج گردید. در ادامه پیازها سرزنی و ارتفاع برش برگ به صورت دستی اندازه‌گیری شد. از داده‌های به دست آمده در شبکه LVQ برای طبقه‌بندی پیازها بر اساس اندازه شاخص قطر و از شبکه عصبی پرسپترون چند لایه برای پیش‌بینی ارتفاع برش برگ پیازها استفاده گردید.

شبکه عصبی LVQ یک شبکه پرکاربرد در طبقه‌بندی داده‌ها بر اساس ویژگی‌های درخواستی است. همچنین شبکه عصبی MLP به صورت گسترده در تعیین روابط بین داده‌های ورودی و خروجی و پیش‌بینی مقادیر خروجی استفاده می‌شود.

خروجی سامانه طراحی شده به این صورت خواهد بود که پس از طراحی و آموزش شبکه‌های عصبی، با تصویر برداری از هر پیاز در مسیر سرزنی، پیازها در یکی از چهار گروه قطری که شبکه LVQ تشخیص می‌دهد، طبقه‌بندی شده و


جدول ۱- مشخصات فنی سرزن استفاده شده در تحقیق

ظرفیت دستگاه (کیلوگرم در ساعت)	مکانیزم برش برگ	سرعت غلتک‌ها (دور در دقیقه)	قطر غلتک‌ها (سانتی‌متر)	طول غلتک‌ها (سانتی‌متر)	جنس غلتک‌ها
۲۲۶۰	دو تیغه‌ای	۲۰۰	۱۲/۷	۱۵۲/۵	فولادی

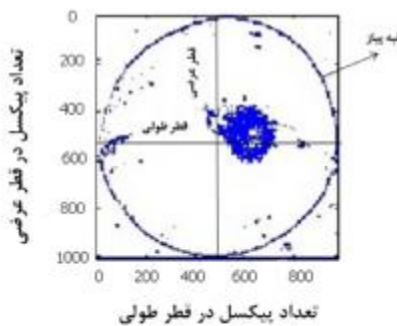
$$\text{Sensitivity} = \frac{n_{TP}}{n_{TP} + n_{FN}} \quad (10)$$

$$\text{Specificity} = \frac{n_{TN}}{n_{TN} + n_{FP}} \quad (11)$$

در این روابط  $n_{TP}$  تعداد نمونه‌هایی است که به درستی مثبت تشخیص داده شده‌اند،  $n_{FP}$  تعداد نمونه‌هایی است که به اشتباه مثبت تشخیص داده شده‌اند (خطای نوع ۱)،  $n_{TN}$  تعداد نمونه‌هایی است که به درستی منفی تشخیص داده شده‌اند و  $n_{FN}$  تعداد نمونه‌هایی بود که به اشتباه منفی تشخیص داده شدند (خطای نوع ۲).



شکل ۳- نحوه قرارگیری دوربین تصویربرداری و جهت چرخش غلتک‌ها (۱: دوربین، ۲: منبع نور (لامپ فلورسانت حلقوی)، ۳: شاسی نگهدارنده، ۴: پیاز، ۵: غلتک سرزن)



شکل ۴- تعیین لبه‌ها و قطرهای تصویر پیاز

پس از طبقه‌بندی پیازها لازم است تا ارتفاع برش برگ پیاز (طول برگ باقی‌مانده بعد از سرزنی) در هر طبقه پیش‌بینی شود. به این منظور تمامی پیازها توسط ماشین سرزن، سرزنی شده و طول برگ باقی‌مانده روی پیاز به روش دستی اندازه‌گیری و ثبت شد. با در اختیار داشتن دو مقدار  $x_{max}$  و

### پردازش تصاویر و طبقه‌بندی آنها بر اساس قطر

به منظور پردازش تصاویر از نرم‌افزار متلب (Matlab 2014a) استفاده شد. در این برنامه ابتدا تصاویر از فایلی در رایانه به محیط نرم‌افزار متلب فراخوانی و تصاویر برای برنامه قابل شناسایی شدند. در مرحله بعدی تصاویر رنگی پیازها به خاکستری تبدیل گردید. تصاویر خاکستری پیاز لبه‌یابی شده و محدوده آن در پس‌زمینه مشخص و جداسازی گردید. سپس با استفاده از دستورات موجود، حداکثر پیکسل‌های موجود بر روی دو محور عمود بر هم تعیین (شکل ۴) و قطر  $d$  به عنوان شاخص یا متوسط قطر هر پیاز از معادله (۷) تعریف شد:

$$d = \frac{x_{max} + y_{max}}{2} \quad (7)$$

در این رابطه  $d$  شاخص قطر هر پیاز،  $x_{max}$  حداکثر قطر در جهت طول و  $y_{max}$  حداکثر قطر در جهت عرض تصاویر پیازها است. برای طبقه‌بندی پیازها بر اساس قطر به دست آمده از پردازش تصویر ( $d$ ) از شبکه عصبی چندی‌ساز بردار یادگیر در نرم‌افزار متلب استفاده شد. با توجه به بازه قطر پیازهای مورد آزمون که بین ۳۰ تا ۱۰۵ میلی‌متر بود، چهار طبقه شامل طبقه یک (قطر ۳۰ تا ۴۸/۷۵ میلی‌متر)، طبقه دو (قطر ۴۸/۸۰ تا ۶۷/۵۰ میلی‌متر)، طبقه سه (قطر ۶۷/۵۵ تا ۸۶/۲۵ میلی‌متر) و طبقه چهار (قطر ۸۶/۳۰ تا ۱۰۵ میلی‌متر) در نظر گرفته شد.

### ارزیابی شبکه عصبی LVQ

با تغییر تعداد نورون‌های لایه پنهان و آموزش شبکه عصبی به روش سعی و خطا، مناسب‌ترین عملکرد شبکه از طریق بررسی ماتریس اغتشاش انتخاب گردید. در ماتریس اغتشاش، شاخص‌های آماری صحت، دقت، حساسیت و اختصاصی بودن به ترتیب از معادلات (۸) تا (۱۱) به دست آمد (Daneshmand Vaziri et al., 2018; Sahan et al., 2005):

$$\text{Accuracy} = \frac{n_{TP} + n_{TN}}{n_{TP} + n_{TN} + n_{FN} + n_{FP}} \quad (8)$$

$$\text{Precision} = \frac{n_{TP}}{n_{TP} + n_{FP}} \quad (9)$$

### نتایج و بحث

#### ارزیابی دقت آموزش شبکه عصبی LVQ

شکل ۵ نتایج طبقه‌بندی پیازها در چهار کلاس اندازه شاخص قطر و جدول ۲ ماتریس اغتشاش حاصل از طبقه‌بندی پیازها را در شبکه عصبی LVQ نشان می‌دهد. شماره هر ردیف نمایانگر طبقه‌بندی شبکه و شماره هر ستون نشان دهنده طبقه یا گروه واقعی پیازها است. جدول ۳ نتایج محاسبه چهار شاخص دقت، صحت، حساسیت و درصد اختصاصی بودن حاصل از اجرای شبکه عصبی LVQ را نشان می‌دهد. طبق این نتایج در طبقه شماره دو میزان صحت، دقت، حساسیت و درصد اختصاصی بودن به ترتیب ۹۱/۲۱، ۹۲/۹۴، ۹۰ و ۹۴/۷۳ به دست آمد. با توجه به نتایج جدول ۲ بهترین عملکرد الگوریتم طبقه‌بند LVQ مربوط به طبقه ۴ با دقت ۹۹/۱۹ درصد و ضعیف‌ترین عملکرد مربوط به طبقه ۲ با دقت ۹۲/۹۴ درصد بوده است. بیشترین شاخص صحت، حساسیت و اختصاصی بودن مربوط به طبقه ۴ به ترتیب با مقادیر ۹۷/۹۵، ۹۶ و ۹۹/۶۸ درصد به دست آمد. علت افزایش این شاخص‌ها در طبقه چهار این است که قطر پیازها در این طبقه دارای بیشترین مقادیر است و تمایز آنها از سایر قطرها در شبکه با خطای کمتری صورت گرفته است. طبقه‌بندی پیازها در شبکه عصبی LVQ با دقت کلی ۹۲/۲۵ درصد انجام شده که نمایانگر ۷/۷۵ درصد خطا است. این دقت از تقسیم پیازهای درست طبقه‌بندی شده به کل پیازها به دست آمد. در تحقیقات مشابه پیاز با استفاده از شبکه عصبی با دقت ۹۰ درصد در دو گروه سالم و خراب طبقه‌بندی شد (Shahin et al., 2002).

#### ارزیابی دقت شبکه عصبی MLP

در شکل ۶ ضریب تعیین ( $R^2$ ) در پیش‌بینی ارتفاع برش توسط شبکه عصبی MLP (داده‌های آزمون) نشان داده شده است. مقدار این دقت ۰/۹۹ به دست آمد. ریشه میانگین مربعات خطا و میانگین خطای مطلق در سه قسمت آموزش، آزمون و کل داده‌ها در جدول ۴ ارائه شده است.

$y_{max}$  (حداکثر قطر پیازها در جهت طول و عرض که در پردازش تصویر به دست آمد) و ارتفاع برش برگ که به روش دستی به دست آمد، می‌توان با آموزش شبکه عصبی، ارتفاع برش برگ در پیازهای مشابه را تخمین زد. به این منظور از شبکه عصبی پرسپترون چند لایه در محیط متلب، استفاده گردید. شبکه مذکور یک شبکه سه لایه شامل لایه ورودی، لایه پنهان و لایه خروجی بود که در آن از ساختار شبکه‌های استاندارد پیشخور با الگوریتم پس انتشار خطا برای یادگیری استفاده شد. دو مقدار  $x_{max}$  و  $y_{max}$  (حداکثر قطر پیازها در جهت طول و عرض) به عنوان ورودی‌های شبکه و مقدار ارتفاع برش برگ به عنوان خروجی شبکه در نظر گرفته شد. همچنین تابع فعال‌سازی سیگموئیدی در لایه پنهان و تابع خطی در لایه خروجی به کار رفت.

#### ارزیابی شبکه عصبی MLP

برای انتخاب بهترین شبکه عصبی در پیش‌بینی ارتفاع برش برگ پیاز از پارامترهای آماری ریشه میانگین مربعات خطا<sup>۱</sup> و میانگین خطای مطلق<sup>۲</sup> استفاده شد. کوچکترین مقادیر این پارامترها نشان دهنده بیشترین دقت بود. این دو پارامتر آماری به ترتیب از روابط ۱۲ و ۱۳ محاسبه گردید (Daneshmand Vaziri et al., 2018):

$$RMSE = \sqrt{\frac{\sum (obs-sim)^2}{n}} \quad (12)$$


$$MAE = \frac{100}{n} \sum_{i=1}^n |obs-sim| \quad (13)$$

در این دو معادله obs ارتفاع برش برگ در هر پیاز به روش اندازه‌گیری دستی، sim ارتفاع برش برگ محاسبه شده به کمک شبکه عصبی و n تعداد نمونه‌ها است.

با تغییرات مختلف در معماری شبکه عصبی و با توجه به لزوم رسیدن به پایین‌ترین میزان میانگین مربعات خطای (MSE)، سهم آموزش، اعتبارسنجی و آزمون شبکه از کل ۴۰۰ زوج داده ورودی (طول و عرض پیاز)، به ترتیب ۵، ۹۰ و ۵ درصد تعیین گردید. در هر دوره اجرای شبکه (epoch) به صورت تصادفی داده‌ها با نسبت‌های یاد شده انتخاب و مقادیر میانگین مربعات خطا محاسبه می‌شود. با ثابت شدن مقدار خطای داده‌های اعتبارسنجی، فرآیند آموزش و اجرای شبکه به پایان می‌رسد.

1- Root Mean Square Error (RMSE)

2- Mean Absolute Error (MAE)



شکل ۵- داده‌های طبقه‌بندی شده در شبکه عصبی LVQ

جدول ۲- ماتریس اغتشاش برای چهار طبقه شاخص قطر در شبکه عصبی LVQ


طبقه‌بندی بر اساس قطر واقعی				طبقه‌بندی بر اساس خروجی شبکه عصبی LVQ
۴	۳	۲	۱	
۰	۰	۵	۶۵	۱
۰	۸	۱۳۵	۵	۲
۲	۱۲۱	۱۰	۰	۳
۴۸	۱	۰	۰	۴

\* طبقه ۱ = (قطر ۳۰ تا ۴۸/۷۵ میلی‌متر)، طبقه ۲ = (قطر ۴۸/۸۰ تا ۶۷/۵۰ میلی‌متر)، طبقه ۳ = (قطر ۶۷/۵۵ تا ۸۶/۲۵ میلی‌متر) و طبقه ۴ = (قطر ۸۶/۳۰ تا ۱۰۵ میلی‌متر)

جدول ۳- شاخص‌های آماری مستخرج از ماتریس اغتشاش در طبقه‌بندی پيازها

شاخص‌های آماری (درصد)				طبقه *
اختصاصی بودن	حساسیت طبقه‌بندی	دقت طبقه‌بندی	صحت طبقه‌بندی	
۹۸/۳۸	۹۲/۸۵	۹۷/۳۶	۹۲/۸۵	۱
۹۴/۷۳	۹۰	۹۲/۹۴	۹۱/۲۱	۲
۹۵/۳۸	۹۳/۰۷	۹۴/۶۱	۹۰/۹۷	۳
۹۹/۶۸	۹۶	۹۹/۱۹	۹۷/۹۵	۴

\* طبقه ۱ = (قطر ۳۰ تا ۴۸/۷۵ میلی‌متر)، طبقه ۲ = (قطر ۴۸/۸۰ تا ۶۷/۵۰ میلی‌متر)، طبقه ۳ = (قطر ۶۷/۵۵ تا ۸۶/۲۵ میلی‌متر) و طبقه ۴ = (قطر ۸۶/۳۰ تا ۱۰۵ میلی‌متر)



شکل ۶- ضریب تعیین پیش‌بینی ارتفاع برش در آزمون شبکه عصبی MLP

جدول ۴- مقادیر میانگین خطای مطلق و ریشه میانگین مربع خطا در شبکه عصبی MLP


میانگین خطای مطلق	ریشه میانگین مربع خطا	داده‌ها
۰/۰۴۱۴	۰/۰۵۱۷	آموزش
۰/۰۶۳۳	۰/۰۵۳۵	آزمون
۰/۰۴۱۲	۰/۰۵۱۵	کل

پردازش تصویر، طبقه‌بندی آنها بر اساس قطر پیازها به کمک شبکه عصبی مصنوعی و تخمین ارتفاع برش برگ پیاز انجام شد. نتایج این تحقیق را می‌توان در مکانیزم‌های خودکار تنظیم ارتفاع سرزنی به کار برد.

به عنوان مثال کنترل ارتفاع تیغه سرزن به کمک یک سامانه هیدرولیکی قابل پیشنهاد است. در این روش پس از تشخیص طبقه هر پیاز و پیش‌بینی ارتفاع برش برگ آن توسط شبکه عصبی، سامانه قادر خواهد بود شرایط سرزنی دستگاه سرزن را بر اساس دستیابی به طول برگ باقی‌مانده مناسب، تنظیم نموده و به طور موفقیت‌آمیزی تلفات سرزنی را کاهش دهد.

بر این اساس مقدار دقت تخمین ارتفاع برش توسط شبکه عصبی در سه قسمت آموزش، آزمون و کل داده‌ها با احتساب ریشه میانگین مربعات خطا به ترتیب  $۹۴/۶۵$ ،  $۹۴/۸۳$  و  $۹۴/۸۵$  درصد به دست آمد. این مقادیر حاکی از دقت قابل قبول تخمین ارتفاع سرزنی پیازها در شبکه عصبی MLP بود. برآورد مقادیر خطا (باقی‌مانده‌ها) در شبکه عصبی MLP نشان داد که خطاها دارای مقادیر تصادفی و بدون همبستگی هستند (شکل ۷).

از اهداف این تحقیق بررسی امکان کاهش تلفات سرزنی پیاز در یک دستگاه پشت تراکتوری با استفاده از پردازش تصویر و شبکه‌های عصبی مصنوعی بود. این امر از طریق تصویربرداری از پیازها و محاسبه ابعاد (قطرها) آنها به کمک



شکل ۷- برآورد مقادیر خطا (باقی‌مانده‌ها) در شبکه عصبی MLP

در این تحقیق شاخص قطر پیازهایی که باید در دستگاه سرزن غلتکی پیاز سرزنی شوند، به کمک پردازش تصویر تعیین گردید و غده‌ها توسط شبکه عصبی مصنوعی LVQ با دقت  $۹۲/۵$  درصد، در چهار گروه قطری طبقه‌بندی شدند. در ادامه ارتفاع برش برگ پیازها با استفاده از شبکه عصبی مصنوعی MLP با مقادیر RMSE و MAE به ترتیب  $۰/۰۵$  و  $۰/۰۴$  پیش‌بینی گردید. به طور خلاصه از روش معرفی شده می‌توان در طبقه‌بندی پیازها بر اساس قطر و پیش‌بینی

### نتیجه‌گیری

امروزه پیشرفت زیادی در کاربرد پردازش تصویر و شبکه‌های مختلف عصبی مصنوعی برای کنترل خودکار ادوات کشاورزی صورت گرفته است. سرزن غلتکی پیاز از جمله ادوات کشاورزی است که در آن حذف برگ پیاز به صورت مکانیزه انجام می‌شود. در این دستگاه تنظیم ارتفاع برش برگ از اهمیت خاصی برخوردار است.



- 35-44. (In Persian).
- Golzarian, M. R., Shamili, M., Doosti Irani, O. & Azarkish, P. (2017). Diagnosis of surface defects caused by mechanical damages on mango of kelk-e sorkh variety with the use of color image processing. *Iranian Food Science and Technology Research Journal*, 12: 652-662. (In Persian).
- Heidarisoltanabadi, M., Taki, O., Abdolapur, S. & Moghadam-Vahed, M. (2013). Development and evaluation of a roller-type onion toppler. *Journal of Agricultural Engineering Research*, 13(4): 89-96. (In Persian).
- Iraji, M. S., & Tosinia, A. (2011). Classification of tomatoes on machine vision with fuzzy the mamdani inference, adaptive neuro fuzzy inference system based (Anfis-Sugeno). *Australian Journal of Basic and Applied Sciences*, 5(11): 846-853.
- Jadhav, S., Udupi, V. & Patil, S. (2019). Recognition of plant leaf diseases using learning vector quantization neural network classifier. *IOSR Journal of Computer Engineering*, 21(3): 41-49.
- Jafarlou, M., & Farrokhi Teimourlou, R. (2014). Estimation of apple volume and its shape indentation using image processing technique and neural network. *Journal of Agricultural Machinery*, 4(1): 57-64. (In Persian).
- Jahanbakhshi, A. & Kheiralipour, K. (2019). Carrot sorting based on shape using image processing, artificial neural network, and support vector machine. *Journal of Agricultural Machinery*, 9(2), 295-307. (In Persian).
- Jamdar, A. V. & Patil, A. P. (2017). Detection and classification of apple fruit diseases using k-means clustering and learning vector quantization neural network. *International Journal of Scientific Development and Research*, 2(6): 423-429.
- Kheiralipour, K., & Pormah, A. (2017). Introducing new shape features for classification of cucumber fruit based on image processing technique and artificial neural networks. *Journal of Food Process Engineering*, 40: 1-4.
- Kohonen, T. (1972). Correlation matrix memories. *IEEE Transactions on Computers*, 21: 353-359.
- Mesri Gundoshmian, T., Mahmoudi, A., Hoseinpour, A. & Komarizadeh, M. H. (2011). Dedection of potato and clod using an acoustic based LVQ intelligent algorithm. *Journal of Agricultural Machinery Science*, 7(3): 293-297.
- Mohebbi, M., Akbarzadeh Totonchi, M. R., Shahidi, F. & Pourshahabi, M. R. (2007). Investigate the possibility of machine vision ارتفاع برش برگ استفاده نمود. این اطلاعات در راه اندازی مکانیزم‌هایی برای تنظیم خودکار تیغه‌های برش سرزن قابل استفاده است.
- منابع
- Abry, P., Roux, S. G., Wendt, H., Messier, P., Klein, A. G., Tremblay, M., Borgnat, P., Jaffard, S., Vedel, B., J., Coddington, & Daffner, L. A. (2015). Multiscale anisotropic texture analysis and classification of photographic. Prints: *Art Scholarship Meets Image Processing Algorithms. Signal Processing Magazine, IEEE*, 32(4): 18-27.
- Bodkhe, K., Thakur, N., Deshmukh, S. & Jaipurkar, P. (2015). Analysis of fungus in plant using processing techniques. *International Journal of Recent Research in Mathematics Computer Science and Information Technology*, 2(1): 12-18.
- Boniecki, P., Piekarska-Boniecka, H., Tran Dinh, D., Zaborowicz, M., Dach, J., Smurzyńska, A. & Koszela, K. (2017). Neural identification of chosen apple pests using algorithm LVQ. 8<sup>th</sup> *International Conference on Communication Technologies in Agriculture, Food and Environment (HAICTA2017)*, Chaina, Greece, 21-24 sep.
- Capizzi, G., Sciuto, G. L., Napoli, C., Tramontana, E. & Woźniak, M. (2015). Automatic classification of fruit defects based on co-occurrence matrix and neural networks. *Proceedings of the Federated Conference on Computer Science and Information Systems* 861-867.
- Chang, D. H., & Islam, S. (2000). Estimation of soil physical properties using remote sensing and artificial neural network. *Remote Sensing of Environment*, 74: 534-544.
- Daneshmand Vaziri, M., Rajabipour, A. & Omid, M. (2018). Investigating the possibility of using the wireless sensor network (WSN) and image processing in an early detection and diagnosis of the pest of greenhouse whitefly. *Iranian Journal of Biosystem Engineering*, 49(3), 395-408. (In Persian).
- Dousti, A., Ghazavi, M. A. & Maleki, A. (2013). Grading of empty walnut using signal processing and artificial neural network techniques. *International Journal of Agriculture and Crop Sciences*, 6(15): 1072-1078.
- Fayyazi, S., Abbaspour-Fard, M. H., Monadjemi, S. A., Sadrnia, H. & Rohani, A. (2014). Identification of three Iranian Rice Grain Varieties in Mixed Bulks Using Different Textural Features and LVQ Neural Network. *Journal of Agricultural Mechanization*, 1(1):

- parameters. *Journal of Physics: Conference Series*, 1196 (2019) 012040. doi:10.1088/1742-6596/1196/1/012040
- Yudong, Z. & Lenan, W. U. (2012). Classification of fruits using computer vision and a multiclass support vector machine. *Sensors*, 12: 12489-12505; doi: 10.3390/s120912489.
- Zhang, B. H., Huang, W. Q., Li, J. B., Zhao, C. J., Liu, C. L. & Huang, D. F. (2014). Detection of slight bruises on apples based on hyperspectral imaging and MNF transform. *Spectrosc. Spectral Anal*, 34(5): 1367-1372.
- Zhang, W. J., Zhong, X. Q. & Liu, G. H. (2008). Recognizing spatial distribution patterns of grassland insects: neural network approaches. *Stochastic Environmental. Research and Risk Assessment*, 22: 207-216.
- Zhang, Y. L., Wu, H. F. & Huang, J. F. (2010). Application of neural networks to discriminate fungal infection levels in rice panicles using hyperspectral reflectance and principal components analysis. *Computers and Electronics in Agriculture*, 72: 99-106.
- Zhang, Y., Pulliainen, J., Koponen, S. & Hallikainen, M. (2002). Application of an empirical neuralnetwork to surface water quality estimation in the Gulf of Finland using combined optical data and microwave data. *Remote Sensing of Environment*, 81: 327-336.
- and artificial neural networks in predicting moisture content of dried shrimp. 4<sup>th</sup> *Conference on Machine Vision and Image Processing, 13-14 Feb*, Ferdowsi University of Mashhad, Iran. (In Persian).
- Nozari, V. & Mazlomzadeh, M. (2013). Date grading based on some physical properties. *Journal of Agricultural Technology*, 9(7): 1703-1713.
- Qiaohua, W., Yihua, T. & Zhuang, X. (2017). Grape size detection and online gradation based on machine vision. *International Journal of Agricultural and Biological Engineering*, 10: 226.
- Razak, T. R. B., Othman, M. B., Bakar, M. N. B. A., Ahmad, K. A. B. & Mansor, A. B. (2012). Mango grading by using fuzzy image analysis. *International conference on agricultural. Environmental Biological Science*, 18-22.
- Rohani, A. & Makarian, H. (2011). Making weed management maps by artificial neural networks for using in precision agriculture. *Journal of Agricultural Machinery*, 1(2): 74-83. (In Persian).
- Rong, D., Rao, X. & Ying, Y. (2017). Computer vision detection of surface defect on oranges by means of a sliding comparison window local segmentation algorithm. *Computer Electronic Agriculture*, 59-68.
- Sahan, S., Polat, K., Kodaz, H. & Gunes, S. (2005). The medical applications of attribute weighted artificial immune system (AWAIS): *Diagnosis of Heart and Diabetes Diseases, ICARIS 2005, LNCS 3627*, 456-468
- Shadro, S. h., Eildarabadi, S., Fakhlaei, M. & Pourreza, H. R. (2007). Classification of tomatoes by SVM, MLP and LVQ. *First Joint Congress on Fuzzy and Intelligent Systems*, Ferdowsi University of Mashhad, Iran. 29-31 Aug. (In Persian).
- Shahbazi, S., Javaherian, A. & Khorasani, M. (2009). Geological facies classification and identification by seismic data and competitive neural networks. *Journal of the Collage of Engineering*, 43(3): 283-296. (In Persian).
- Shahin, M. A., Tollner, E. W. & McClendon, R. W. (2001) . Artificial intelligence classifiers for sorting apples based on watercore. *Journal of Agricultural Engineering Research*, 79(3): 265-274.
- Shahin, M. A., Tollner, E. W., Gitaitis, R. D., Sumner, D. R. & Maw, B. W. (2002). Classification of sweet onions based on internal defects using image processing and neural network techniques. *Transactions of the ASAE*, 45(5): 1613-1618.
- Sutarno, S. & Fauliah, P. (2019). Implementation of learning vector quantization (LVQ) algorithm for durian fruit classification using gray level co-occurrence matrix (GLCM)