

## دسته بندی گوجه فرنگی با استفاده از SVM، MLP و LVQ

شبنم شادرو<sup>۱</sup>، صدیقه ایلدرآبادی<sup>۲</sup>، مینا فخلعی<sup>۳</sup>، حمید رضا پوررضا<sup>۴</sup>

موسسه آموزش عالی سپاهان<sup>۱</sup>، دانشکده مهندسی دانشگاه فردوسی مشهد<sup>۲</sup>، دانشگاه آزاد اسلامی مشهد- گروه ارشد هوش مصنوعی<sup>۳</sup>

[shabnam\\_shadroo@yahoo.com](mailto:shabnam_shadroo@yahoo.com)<sup>۱</sup> ، [sedigheh\\_ildarabadi@yahoo.com](mailto:sedigheh_ildarabadi@yahoo.com)<sup>۲</sup>

[mina\\_fakhlai@yahoo.com](mailto:mina_fakhlai@yahoo.com)<sup>۳</sup> ، [hpourreza@um.ac.ir](mailto:hpourreza@um.ac.ir)<sup>۴</sup>

**چکیده** - در این مقاله کنترل خودکار کیفیت گوجه فرنگی بر اساس بکارگیری روشهای مختلف *LVQ*، *MLP* و *SVM* مورد بررسی قرار گرفته است. ابتدا تصاویر توسط دوربین دیجیتالی گرفته شد و سپس عملیات حذف نویز و بهبود کنتراست بر روی تصاویر صورت پذیرفت. سپس مهمترین مرحله که استخراج ویژگی از تصاویر گوجه فرنگی است، انجام گرفت. ویژگیهای استخراج شده عبارتند از: میزان قرمزی و زردی که به صورت فازی به دست آمده، میزان سبز بودن، ممان مرتبه اول، ممان مرتبه دوم، ممان مرتبه سوم، میانگین این سه ممان، میزان گرد بودن و مساحت. ویژگیهای بدست آمده به دسته بندی کننده های متفاوت داده شد و نتایج بدست آمده مورد مقایسه و ارزیابی قرار گرفت. نتایج نشان می دهند که *SVM* نسبت به روش های دیگر بهتر عمل می کند.

**کلید واژه** - بینایی ماشین، کنترل کیفیت، *LVQ*، *SVM*


### ۱- مقدمه

متعددی بر روی استفاده از تکنیکهای بینایی ماشین برای بررسی کیفیت محصولات کشاورزی انجام پذیرفته است. ولف و همکارش مطالعه ای بر اساس شکل فلفل سبز انجام دادند [۲]. مورف و همکارانش جهت کنترل کیفیت سیب زمینی تکنیکی را بر اساس سایز، رنگ و شکل آن ارائه نمودند [۳]. استفنسون و چامبرلین معیارهای رنگ در دسته بندی گوجه فرنگی بر اساس انعکاس نور توسعه دادند [۴]. تاوو و همکارانش به تحلیل تصاویر رنگی برای کلاس بندی سیب زمینی پرداختند و آنها را به شش دسته، طبقه بندی کردند [۵]. کاستیل و همکارانش از شبکه های عصبی و منطق فازی، برای دسته بندی گوجه فرنگی استفاده نمودند [۶]. شبکه های عصبی و منطق فازی، از جمله تکنیکهای می باشند که برای مسائل شناسایی الگو و تصمیم گیری استفاده می شوند و نتایج خوبی را بدنبال دارند، به همین دلیل نیز این تکنیکها در کاربردهای صنعتی به عنوان یک راه حل خوب مورد استفاده قرار گرفته اند.

بدلیل آنکه در کاربردهای صنعتی همیشه نیاز به کاهش زمان و هزینه وجود دارد، خودکار کردن کنترل کیفیت از اهمیت زیادی برخوردار می باشد. به گفته افراد خبره، مشکلات زیر در کنترل کیفیت توسط افراد، وجود دارد: [۱]

- دقت پایین به دلیل وجود عواملی نظیر شدت روشنایی محیط، خستگی افراد و ...
- نبود همگنی ناشی از فاکتورهای قبلی.
- فقدان درستی بعنوان نتایج مشکلات قبلی.

استفاده از بینایی مصنوعی در فرایند دسته بندی تنها به کاهش زمان شناسایی کمک نمی کند، بلکه به هماهنگی دسته بندی نیز کمک می کند و این باعث یکنوایی بیشتر در ارزیابی کیفیت می شود. در سالهای اخیر تحقیقات



شکل ۱: بلوک دیاگرام سیستم

- حذف نویز با استفاده از عملیات مورفولوژیک (استفاده از فرسایش و گسترش)

- حذف زمینه با استفاده از الگوریتم سیداحمد

- کاهش انعکاس نور با استفاده از الگوریتم وفقی

برای حذف انعکاس نور بر روی گوجه فرنگی ابتدا تصویر به فضای *HSI* رفته و مقدار *S* برای پیکسل ها به میزان یکسانی برده می شود و سپس تصویر به فضای *RGB* می رود تا بر روی آن پردازش انجام شود.

در شکل (۲) الف. تصاویر اولیه گوجه فرنگی قبل از عملیات پیش پردازش نشان داده شده و تصاویر بدست آمده بعد از اعمال عملیات مورفولوژیک بر روی تصاویر اولیه، جهت حذف نویز، در شکل (۲) ب. آمده است. در شکل (۲) ج. تصاویری که با استفاده از الگوریتم سید احمد زمینه آنها حذف گردیده است، نشان داده شده و در شکل (۲) د. تصاویری که انعکاس نور آنها کاهش یافته نمایش داده شده است.

## ۲-۲- ویژگیهای استخراج شده

### ۲-۲-۱- ویژگیهای قرمزی و زردی

درویش آقای چنگوانگ با استفاده از تکنیک های فازی به بررسی میزان قرمزی و زردی و بنفشی و... در یک عکس *RGB* پرداخته شده است [۷]. در اینجا از میزان قرمزی و زردی به عنوان دو ویژگی برای گوجه فرنگی استفاده می شود.

میزان قرمز بودن، زرد بودن و ... گوجه فرنگی از روابط

در روش پیشنهادی در این مقاله از *SVM* و شبکه های عصبی *LVQ* و *MLP* برای کلاس بندی تصاویر استفاده شده است. خروجی دسته بندی کننده، مقادیر گسسته ای است. در این مورد تصاویر تهیه شده از اشیاء توسط یک دوربین ویدئویی دیجیتالی برای دسته بندی کردن استفاده می شود. تصاویر برای محاسبه فاکتور شکل، سایز، رنگ و بافت مورد پردازش قرار می گیرند تا ویژگیهای مورد استفاده به دست آید و آنها توسط *SVM* و شبکه های عصبی *LVQ* و *MLP* دسته بندی شوند.


در ادامه بخش ۲ اجزای ماشین را توضیح می دهد و بخش ۳ نیز نتایج حاصل از طبقه بندی کننده های مورد بررسی در این مطالعه را ارائه می کند.

## ۲- اجزای ماشین

بلوک دیاگرام سیستم طراحی شده در شکل ۱ نشان داده شده است. در این سیستم ابتدا توسط دوربین دیجیتالی تصاویری در ابعاد  $480 * 640$  گرفته می شود، بدین ترتیب که گوجه فرنگی ها بر روی صفحه سیاهی قرار می گیرند تا انعکاس نور به حداقل برسد. سپس تصاویر گرفته شده پیش پردازش می شوند تا نویز کاهش و زمینه و انعکاس روی گوجه فرنگی حذف گردد. سپس به منظور استخراج ویژگی تصاویر پردازش می شوند و ویژگیهای به دست آمده توسط فرد خبره ای به سه کلاس خوب، متوسط و بد برچسب گذاری شده و در اختیار شبکه عصبی قرار داده می شوند تا برای آموزش و تست سیستم مورد استفاده قرار گیرد. در بخش های بعدی کلیه این قسمت ها به تفصیل مورد بحث قرار خواهد گرفت.

### ۲-۱- پیش پردازش

به منظور حذف نویزهای احتمالی تصویر، پیش از مرحله استخراج ویژگی، پیش پردازشهای زیر بر روی تصاویر انجام می شود.



شکل ۲: (الف) تصاویر اولیه؛ (ب) حذف نویز با استفاده از عملیات موزفولوژیک؛ (ج) حذف زمینه با استفاده از الگوریتم سیداحمد؛ (د) کاهش انعکاس نور با استفاده از الگوریتم وقتی.

The "log energy" entropy.

$$E(f) = \sum_i \log(f_i^2) \quad (9)$$

and  $\log(0) = 0$ .

در اینجا  $f_i$  سطح خاکستری عکس  $f$  می باشد.

### ۲-۲-۳ ممانها

از جمله ویژگیهای دیگری که جهت درجه بندی گوجه فرنگی ها در این تحقیق مورد استفاده قرار می گیرد گشتاور (ممان) مرتبه اول، دوم، سوم و میانگین این سه ممان می باشد. که با استفاده از روابط (۱۰)، (۱۱) و (۱۲) حاصل می گردند.

$$m_{pq} = \sum_i \sum_j i_p j_q f(i, j) \quad (10)$$

$$\eta_{pq} = \frac{\mu_{pq}}{(\mu_{00})^{\wp}} \quad (11)$$

$$\wp = \frac{p+q}{2} + 1$$

(۵) تا (۸) تعیین می شود :

$$M = \max(\min(B, G), \min(B, R), \min(G, R)) \quad (5)$$

$$M_{BY} = \begin{cases} +[\overline{BGR}] = +blueness, B > M \\ -[\overline{BGR}] = -yellowness, B \leq M \end{cases} \quad (6)$$

$$M_{GM} = \begin{cases} +[\overline{BGR}] = +greenness, G > M \\ -[\overline{BGR}] = -magenta, G \leq M \end{cases} \quad (7)$$

$$M_{RC} = \begin{cases} +[\overline{BGR}] = +redness, R > M \\ -[\overline{BGR}] = -cyaness, R \leq M \end{cases} \quad (8)$$

در این تحقیق از معیار  $Yellowness$  و  $Redness$  به عنوان ویژگی قرمزی و زردی استفاده می شود.


### ۲-۲-۲ ویژگی سبزی

برای تشخیص گوجه فرنگی سبز، ویولت آنتروپی در فضای  $R$  مورد استفاده قرار می گیرد (رابطه (۹)):

نرونیهای لایه مخفی و نوع تابع تبدیل نرونها به یادگیری می پردازند. می توان از توابع *logsig* یا *tansig* به عنوان توابع تبدیل نرونیهای لایه مخفی و لایه خروجی استفاده کرد. در این مقاله شبکه *MLP* دارای سه لایه ورودی، لایه میانی و لایه خروجی است؛ که به ترتیب هر یک شامل ۷، ۵۰ و ۳ نرون می باشند. از تابع *tansig* به عنوان تابع تبدیل نرونیهای لایه مخفی و لایه خروجی، از *MSE* به عنوان معیار خطا استفاده شده است. حداکثر دفعات تکرار ۱۰۰۰۰ برای آموزش و مقدار خطا ۰/۰۱ برای توقف آموزش در نظر گرفته شده است.

### ۲-۳-۲- شبکه LVQ

شبکه های *LVQ*، بردارهای ورودی را به کلاسهای هدف با استفاده از لایه رقابتی دسته بندی می کنند، که ابتدا بردارهای ورودی به عنوان زیردسته ها دسته بندی می شوند و سپس این زیر دسته ها با یکدیگر ترکیب شده و در کلاسهای هدف قرار می گیرند. برخلاف شبکه های پرسپترون که تنها مجموعه بردارهای ورودی جداساز خطی را می توانند دسته بندی کنند، شبکه های *LVQ* این توانایی را دارند که هر مجموعه از بردارهای ورودی را دسته بندی نمایند. اما باید توجه داشت که لایه رقابتی حتما به اندازه کافی نرون داشته باشد و به هر کلاس به اندازه کافی نرون رقابتی نسبت داده شود. در این مقاله از شبکه *LVQ* با ۷ لایه ورودی و ۴ لایه مخفی استفاده شده است. در شکل (۳) ساختار کلی شبکه *LVQ* نشان داده شده است.



شکل ۳: ساختار کلی شبکه LVQ

$$\varphi_1 = \eta_{02} + \eta_{20}$$

$$\varphi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11} \quad (12)$$

$$\varphi_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2$$

### ۲-۲-۴- ویژگی گرد بودن و ویژگی مساحت

برای یک تصویر می توان یک ناحیه را چنین تعریف کرد:

$$R(i, j) = \begin{cases} 1 & \text{if } (i, j) \text{ in the region} \\ 0 & \text{otherwise} \end{cases} \quad (13)$$

بر این اساس، سطح ناحیه و مرکز ثقل به ترتیب از روابط (۱۴) و (۱۵) حاصل می شوند:

$$A = \sum_{i=1}^M \sum_{j=1}^N R(i, j) \quad (14)$$

$$\text{center of Gravity} : \begin{cases} x_0 = \frac{\sum_{i=1}^M \sum_{j=1}^N jR(i, j)}{A} \\ y_0 = \frac{\sum_{i=1}^M \sum_{j=1}^N iR(i, j)}{A} \end{cases} \quad (15)$$

حال با داشتن شعاع های حداقل *Rmin* و حداکثر *Rmax* میزان گردبودن از رابطه (۱۶) تعیین می گردد:

$$\text{Roundness} = R_{\min} / R_{\max} \quad (16)$$

### ۲-۳-۲- دسته بندی کننده

در این مقاله از *SVM* و شبکه های عصبی *LVQ* و *MLP* به منظور دسته بندی تصاویر استفاده شده است.

### ۲-۳-۱- شبکه عصبی MLP

شبکه های عصبی چند لایه پیشخور عموماً شبکه های چند لایه پرسپترون نامیده می شوند. در این نوع از شبکه های عصبی هر نرون دارای یک تابع محرک غیر خطی می باشد که دارای ویژگی هموار یا مشتق پذیر می باشد، بنابراین ارتباط بین پارامترهای شبکه و سیگنال خطا کاملاً پیچیده و غیر خطی است. در شبکه عصبی *MLP* تعداد نرونیهای لایه ورودی بر اساس تعداد ویژگیهای داده مورد نظر و تعداد نرونیهای لایه خروجی بر اساس تعداد کلاسها تعیین می شود. این شبکه ها بر اساس دو پارامتر تعداد

## ۲-۳-۳- دسته بندی کننده SVM

SVM از یک ابرصفحه خطی تفکیک گر بهینه، برای دسته بندی داده ها استفاده می کند که این ابرصفحه بهینه از حداکثر کردن "حاشیه" بدست می آید. به این منظور باید یک مساله بهینه سازی غیر خطی مقید، حل شود. نظریه SVM، با این فرضیه که تابع تفکیک گر در فضای ورودی می تواند غیر خطی هم باشد، تکمیل شد. نظریه عملکرد شبکه های بردار تکیه گاه یا همان ماشینهای بردار تکیه گاه، به این ترتیب کامل شد که: ابتدا بردارهای ورودی به شکل غیر خطی به یک فضای جدید، با ابعاد بزرگتر نگاشت داده می شوند. بعد در این فضای جدید سطوح خطی تصمیم گیر ساخته می شوند. خصوصیات این صفحات تصمیم گیر به نحوی است که قابلیت تصمیم را برای این روش فراگیری ماشین تضمین می کند. بنابراین به خاطر قابلیت نگاشت است که می توان گفت SVM یک حالت کلی از ماشینهای فراگیر است که شبکه های عصبی، شبکه های RBF و دسته بندی کننده های چند جمله ای، حالتی خاصی از آن می باشند.

SVM جزء گروه دسته بندی کننده هایی است که بدون دانستن مدل توزیع داده ها، دسته بندی را انجام می دهد؛ حتی فراتر از آن، این مدل نیازی به دانستن یک ساختار کلی از مساله، ندارد. شبکه بردارهای تکیه گاه یک ماشین آموزشی جهت دسته بندی داده های ورودی به دو گروه می باشد اما با استفاده از تکنیکهایی برای مسائل چند دسته ای نیز استفاده می شود.

بطور کلی SVM بردارهای ورودی را با استفاده از یک کرنل به یک فضای بزرگتری می برد که تفکیک پذیری خطی در آن بهتر و قاطعانه تر انجام می شود. با استفاده از کرنلهای مختلف، می توان روشهای فراگیری مختلفی با انواع سطوح تصمیم گیری دلخواه، ساخت. به این ترتیب است که SVM به عنوان یک کلاس جدید از دسته بندی کننده ها و ماشینهای تشخیص الگو در می آید. چون فرآیند دسته بندی گوجه فرنگیها مسئله ای چند کلاسه است لذا این نوع دسته بندی کننده می تواند توسط ترکیب SVM های دو کلاسه ساخته شوند و این تکنیک بر خلاف سایر تکنیکها، دسته بندی را بین هر کلاس و سایر کلاسهای باقیمانده انجام می دهد. در این مقاله از SVM به همراه کرنل RBF استفاده شده است.

## ۲-۴- نتایج تجربی

در این مقاله، از ۱۴۲ عکس گوجه فرنگی در شرایط نوری متفاوت استفاده شده است. ۸۶ نمونه به عنوان داده آموزشی و ۵۶ نمونه به عنوان داده تست مورد بررسی قرار گرفته است. نتایج حاصل از اعمال سه نوع دسته بندی کننده SVM و شبکه های عصبی LVQ و MLP روی این مجموعه داده، در جدول (۱) ارائه شده است.

جدول ۱: نتایج اعمال روش های

SVM, LVQ, MLP

شبکه عصبی	MLP	LVQ	SVM
داده آموزشی	٪۸۰	٪۹۳/۴	٪۱۰۰
داده تست	٪۵۷/۸	٪۷۴/۶	٪۷۷

از آنجا که تصمیم گیری تنها بر اساس بردارهای مرزی انجام می گیرد، SVM با تعداد الگوهای آموزشی کم نیز پاسخی نزدیک به پاسخ واقعی و بهینه خواهد داشت. همچنین به همین خاطر نیز دچار بایاس شدن بیش از حد به سمت داده های آموزشی، نمی شود؛ چراکه خود را بر اساس بردارهای آموزشی مرزی که در تفکیک دو دسته مهم می باشند، تنظیم می کند. SVM همانند شبکه های عصبی نیازی به یک مدل از پیش تعیین شده، ندارد و به دلیل آنکه SVM بردارهای ورودی غیر خطی را به یک فضای جدید خطی با ابعاد بزرگتر نگاشت می دهد و بعد در این فضای جدید سطوح خطی تصمیم گیر ساخته می شوند، نسبت به روش های دیگر بهتر پاسخ می دهد.

## ۲- نتیجه گیری

شبکه های بردارهای تکیه گاه (SVM)، یک کلاس عام از روشهای فراگیری ماشینها می باشند که تابع تصمیم گیر آنها به راحتی با تغییر تابع ضرب داخلی (کرنل)، می تواند عوض شود. این روش جهت تفکیک بردارهای آموزشی به دو دسته استفاده می شود. ولی باروشهایی خاص برای مسائل چند دسته ای هم استفاده می شود. در مقایسه با روشهای دیگر نتایج بسیار خوبی را می دهد. از آنجا که تصمیم گیری تنها بر اساس بردارهای مرزی انجام می گیرد، این روش با تعداد الگوهای آموزشی کم نیز پاسخی نزدیک به پاسخ واقعی و بهینه خواهد داشت. همچنین به همین خاطر نیز دچار بایاس شدن بیش از حد به سمت داده های آموزشی،

[10] Matheron, G., "The theory of regionalized variables and its applications", Les Cahiers du Centre de Morphologie Mathématique de Fontainebleau, n° 5, 1971.

[11] Laykin, S., Alchanatis, V. and Edan, Y., "Image processing algorithms for tomatoes classification", The XIV Memorial CIGR World Congress 2000, Tsukuba, Japan, 2000.

[12] Morrow, C.T., Heinemann, P.H., Sommer, H.J., Tao, Y. and Varghese, Z. "Automated inspection of potatoes, apples and mushrooms" In Proc. Of Int. Advanced Robotics Program, 179-188, 1990.

نمی شود؛ چراکه خود را بر اساس بردارهای آموزشی مرزی که در تفکیک دو دسته مهم می باشند، تنظیم می کند. با استفاده از کرنل می توان سیستم را در یک فضای بعد بالا، آموزش داد. همانند شبکه های عصبی نیازی به یک مدل از پیش تعیین شده، ندارد. در این مقاله کنترل خودکار کیفیت گوجه فرنگی براساس بکارگیری روشهای مختلف  $L_{VQ}$ ،  $MLP$  و  $SVM$  مورد بررسی قرار گرفته است. ویژگیهای بدست آمده به دسته بندی کننده های متفاوت داده شد و نتایج بدست آمده مورد مقایسه و ارزیابی قرار گرفت. نتایج نشان می دهند که  $SVM$  با کرنل RBF نسبت به روش های دیگر بهتر عمل می کند.

## مراجع

[1] Noordam, J.C., Otten, G.W., Timmermans, A.J.M., and Zwol, B. van, "High-speed potato grading and quality inspection based on a color vision system", presented at SPIE, Machine vision and its applications, San Jose, Californie, 2000.

[2] Wolfe R.R. and Swaminathan, M. "Determining orientation and shape of bell peppers by machine vision" Trans. of the ASAE 30(6):1853-1856, 1987.

[3] McClure, J.E and Morrow, C.T. "Computer vision sorting of potatoes" ASAE Paper No.87-6501. ASAE, St. Joseph MI-49085, 1987

[4] Stephenson, K.Q. "Color sorting tomatoes" Quality Detection of Foods: 199-201, 1976.

[5] Tao, Y., Morrow C.T., Heinemann P.H., Sommer H.J. III "A Fourier-based separation technique for shape-grading of potatoes using machine vision" Trans. of the ASAE 38:949-957, 1995.

[6] D.Unay, B. Gosselin, "Apple defect detection and quality classification with MLP -neural networks", 2002.

[7] Chenguang Lu "The Decoding Model: a Symmetrical Model of Color Vision", 2003.

[8] Castillo, O., Cardona, R., Melin, P., "A Hybrid Approach for Automated Quality control combining Learning Vector Quantization Neural Networks and Fuzzy Logic", IEEE conf, vol 3, p: 2081-2085, 2002.

[9] Y.Gejima, H.Zhang, M.Nagata, "Judgment on level of maturity for tomato quality  $L^*a^*b^*$  color image processing", IEEE conf. on Advanced Intelligent Mechatronics, 2003.