



Research Paper

Determination of potato cultivars using image processing and an artificial neural network

Ali Hosseini Athar¹, Ali Nejat Lorestani^{1*}, Jafar Amiri Parian²

¹: Mechanical Engineering of Biosystems Department, Faculty of Agriculture, Razi University, Kermanshah, Iran.

²: Department of Biosystem Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran.

Article History	Abstract
Submitted: 2026/01/05	Variety detection of agricultural products, carried out to post-harvesting automation in some of the industries that this process using manual and visual inspection is very time-consuming and incorrect. Machine vision technology as a new method and non-destructive, can be used to extract morphological, color, and textural features. The purpose of this study was to identify varieties of potatoes using these features using image processing and artificial neural networks. To identify the variety of potatoes, ten varieties of potatoes were prepared consisting of: Agria, Marfona, Jali, Arenda, Ramoos, Bamba, Santa, Granola, Sparit, and Milva. Finally, 14 morphological features, 24 color features and 120 textural features were extracted from the images. Identification of varieties was carried out using a back-propagation neural network. The results showed that the average accuracy of classification for the morphological features was 88/09%, for color features 27.61% and for textural features (green gray level), 24.28% for a one layer network. As well, the average classification accuracy for a two layer network for morphological, color and texture (green gray level) features, were: 86.19%, 39.04%, 28.57% respectively. The results showed that the effective parameters for the classification of varieties of potatoes are morphological features.
Revised: 2026/02/03	
Accepted: 2026/02/23	
Published online: 2026/03/21	
Keywords: Potato, artificial neural network, image processing, morphology, color, texture.	
*Corresponding author email: lorestani@razi.ac.ir	
ORCID:  0000-0002-8221-404X	
	

How to cite this paper:

Hosseini Athar, A., Lorestani, A. N., and Amiri Parian, J. (2026). Determination of potato cultivars using image processing and an artificial neural network. *Journal of Research in Mechanics of Agricultural Machinery*. 38: 55-72. <https://dx.doi.org/10.22034/jrmam.2026.14862.753> (In Persian)



Authors retain the copyright and full publishing rights. Published by [Shahrood University](https://www.shahrood.ac.ir). This article is an open access article licensed under the [Creative Commons Attribution 4.0 International \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/)

<https://dx.doi.org/10.22034/jrmam.2026.14862.753>

EXTENDED ABSTRACT

Introduction

Potato (*Solanum tuberosum* L.) is a major tuber crop with significant global nutritional importance, providing higher energy and protein yield per unit area compared to wheat, rice, and maize (Akhavan *et al.*, 2005). Iran ranks 14th worldwide in potato production, with an annual output of approximately 5 million tons, of which about 200,000 tons are exported to neighboring countries. Approximately 180,000 hectares of Iranian farmland are dedicated to potato cultivation, predominantly under irrigated conditions. Hamadan Province leads national production, contributing 24%, followed by Ardabil, Isfahan, and other provinces.

Accurate identification of potato cultivars is critical in the food and processing industries for determining dry matter content and potential pesticide residues. Traditional methods are often destructive and time-consuming. Machine vision technology offers a non-destructive, rapid, and precise alternative by exploiting differences in shape, size, color, and texture among cultivars. Artificial neural networks (ANNs) are powerful computational tools capable of learning complex relationships between input features and desired outputs through training, making them suitable for pattern recognition and classification tasks (Hristev, 1998).

Previous studies have successfully applied image processing and ANNs for cultivar classification in crops such as rice (Golpour *et al.*, 2014; Shantaiya & Ansari, 2012). This study aimed to develop and evaluate algorithms for extracting morphological, color, and texture features from potato tuber images and to design optimal ANN architectures for classifying ten common Iranian potato cultivars using these features.

Material and Methods

Ten widely cultivated potato cultivars (Agria, Marfona, Granola, Arinda, Santa, Milva, Jelly, Ramos, Spirit, and one additional cultivar referred to as Bamba) were collected from Hesamabad village, Bahar County,

Hamadan Province, Iran. At least 30 healthy tubers per cultivar were selected after washing to remove soil.

Images were acquired using a Canon PC1742 digital camera (12.1 megapixels) at a fixed distance of 48 cm against a blue background, yielding 30 images per cultivar (4000×3000 pixels).

Pre-processing involved thresholding, binary conversion, noise removal based on small area elimination, and background subtraction.

Morphological features (e.g., area, major/minor axis length, perimeter, solidity), color features (mean, range, variance, and standard deviation in RGB and HSI spaces, totaling 24 features), and texture features (120 features derived from Gray-Level Co-occurrence Matrices in four directions) were extracted using custom algorithms in MATLAB R2012a.

Feed-forward ANNs with one or two hidden layers were trained using the Levenberg-Marquardt algorithm. Data were normalized to [0,1] and randomized; 70% were used for training and 30% for testing. Performance was evaluated using mean squared error (MSE) and coefficient of determination (R^2).

Results and Discussion

Image processing successfully segmented tubers, removing background and noise, enabling reliable feature extraction.

When using morphological features (16 inputs) with a single-hidden-layer ANN, the best performance was achieved with a 16-17-10 architecture (log-sigmoid hidden layer, linear output), yielding 88.09% classification accuracy, MSE of 0.1359, and R^2 of 0.9965 after 17 epochs. Two-hidden-layer networks performed slightly worse (86.19 %).

Color features (24 inputs) produced lower accuracy with single-hidden-layer networks (maximum 27.61%). However, a two-hidden-layer network (24-10-11-10 architecture, tan-sigmoid functions) improved accuracy to 39.04%, indicating that color alone is insufficient for robust discrimination due to

high intra-cultivar variability and overlap among cultivars.

Texture features (120 total) were analyzed separately for red, green, and blue channels (40 features each) and grayscale levels. Single-hidden-layer networks yielded low accuracies (20–24.28%). Two-hidden-layer networks performed better: green channel achieved the highest accuracy of 28.57% (40-16-17-10 architecture, linear-tan-sigmoid), followed closely by blue channel (28.09%). The green channel provided the most discriminative texture information.

Overall, morphological features provided the highest classification accuracy (88.09%), followed by color and texture. This aligns with prior research showing morphological traits (shape and size) are more stable and distinctive among potato cultivars than color or texture, which can be influenced by growing conditions and post-harvest handling.

Lower accuracies with color and texture may result from similarities among certain cultivars and environmental effects on surface properties. Combining feature sets was not explored but could potentially improve performance. The non-destructive nature of the approach and high accuracy with morphological features demonstrate its practical potential for industrial sorting and quality control.

Conclusions

This study demonstrated that image processing combined with artificial neural networks can effectively classify potato cultivars non-destructively. Among the tested

feature types, morphological features yielded the highest classification accuracy (88.09%) using a single-hidden-layer ANN, outperforming color and texture features. For color and texture, two-hidden-layer networks generally performed better than single-layer ones. The green channel provided the most useful texture information.

Morphological characteristics proved most reliable for discrimination, likely due to greater genetic stability. The developed system offers a rapid, accurate tool for cultivar identification in food processing and trade, with potential for further improvement through feature fusion or larger datasets.

Author Contributions

- First author: Master's graduate (primary researcher)
- Second author: Supervisor
- Third author: Co-supervisor

Data Availability Statement

All relevant data and results are reported within the manuscript in the form of tables and figure.

Ethical Considerations

The authors confirm that ethical principles have been observed in conducting and publishing this research.

Conflict of Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Funding Statement

The authors received no specific funding for this research.



تعیین ارقام سیب‌زمینی با استفاده از پردازش تصویر و شبکه عصبی مصنوعی

علی حسینی اطهر^۱، علی نجات لرستانی^{۱*} و جعفر امیری پریان^۲

۱. مهندسی مکانیک بیوسیستم، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ایران.

۲. استادیار گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران.

تاریخچه مقاله	چکیده
دریافت: ۱۴۰۴/۱۰/۱۵ بازنگری: ۱۴۰۴/۱۱/۱۴ پذیرش: ۱۴۰۵/۱۲/۰۴ انتشار: ۱۴۰۵/۰۱/۰۱	تشخیص ارقام محصولات کشاورزی، به منظور خودکار سازی فرآیندهای پس از برداشت در اغلب کارخانجات انجام می‌شود که این کار با استفاده از بازرسی دستی و دیداری بسیار وقت‌گیر و خطاپذیر است. فناوری ماشین‌بینایی به عنوان روشی غیر مخرب می‌تواند برای استخراج ویژگی‌های ریخت‌شناسی، رنگ و بافت به کار برده شود. هدف از انجام این پژوهش شناسایی ارقام سیب‌زمینی با استفاده از این ویژگی‌ها به کمک پردازش تصویر و شبکه‌های عصبی مصنوعی است. برای تشخیص ارقام سیب‌زمینی، ۱۰ رقم سیب‌زمینی به نام‌های آگریا، مارفونا، جلی، آرندا، راموس، بامبا، سانتا، گرانولا، اسپریت و میلوا تهیه شدند. در نهایت ۱۶ ویژگی ریخت‌شناسی، ۲۴ ویژگی رنگی و ۱۲۰ ویژگی بافتی از این تصاویر استخراج شد. شناسایی ارقام با استفاده از شبکه عصبی پس انتشار انجام گرفت. نتایج به دست آمده از این پژوهش نشان داد که میانگین دقت طبقه‌بندی برای ویژگی‌های ریخت‌شناسی ۸۸/۰۹٪، برای ویژگی‌های رنگی ۲۷/۶۱٪ و برای ویژگی‌های بافتی (سطح خاکستری سبز) ۲۴/۲۸٪، برای شبکه یک لایه به دست آمد. همچنین میانگین دقت طبقه‌بندی برای ویژگی‌های ریخت‌شناسی، رنگی و بافتی (سطح خاکستری سبز) برای شبکه دو لایه به ترتیب عبارت بودند از: ۸۶/۱۹٪، ۳۹/۰۴٪ و ۲۸/۵۷٪. نتایج نشان داد که عامل مؤثر برای طبقه‌بندی ارقام سیب‌زمینی، ویژگی‌های ریخت‌شناسی است.
واژه‌های کلیدی: سیب‌زمینی، شبکه عصبی مصنوعی، پردازش تصویر، ریخت- شناسی، رنگ، بافت. *پست الکترونیکی نویسنده مسئول: lorestani@razi.ac.ir ORCID:  ۴۰۴-۸۲۲۱-۰۰۰۲-۰۰۰۰X 	

نحوه استناد به این مقاله:

حسینی اطهر، ع.، لرستانی، ع. ن.، و امیری پریان، ج. (۱۴۰۵). تعیین ارقام سیب‌زمینی با استفاده از پردازش تصویر و شبکه عصبی مصنوعی. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی، ۳۸: ۵۵-۷۲. <https://dx.doi.org/10.22034/jrmam.2026.14862.753>

مقدمه

سیب‌زمینی از محصولات غده‌ای است که نقش مهمی در تغذیه مردم جهان دارد و به دلیل عملکرد بسیار بالا در واحد سطح، انرژی و مقدار پروتئین تولیدی بیش‌تری نسبت به گندم، برنج و ذرت دارد (Akhavan et al., 2005). ایران با تولید سالانه پنج میلیون تن سیب‌زمینی رتبه چهاردهم تولید این محصول در جهان را دارد و هر ساله حدود ۲۰۰ هزار تن از این محصول را به کشورهای عراق، ترکمنستان، افغانستان و آذربایجان صادر می‌کند. در ایران حدود ۱۸۰ هزار هکتار از اراضی زراعی زیر کشت سیب‌زمینی قرار دارد که حدود ۹۸ درصد این سطح، به صورت آبی و تنها دو درصد به صورت دیم کشت می‌شود. استان همدان با تولید حدود ۲۴ درصد از سیب‌زمینی کشور مقام اول در تولید این محصول را به خود اختصاص داده و استان‌های اردبیل، اصفهان، آذربایجان شرقی، کردستان و زنجان به ترتیب رتبه‌های دوم تا ششم تولید را دارند که جمعاً ۶۳ درصد سیب‌زمینی کشور را تولید می‌کنند (Akhavan et al., 2005).

آمار تولید سیب زمینی در ایران در سال ۲۰۲۳ به ۲,۴۸۳,۱۹۹ تن بوده است. طبق آمار تولید سیب زمینی در ایران، بیشترین میزان تولید این محصول در این بازه آماری مربوط به سال ۲۰۰۵ بوده که طی این سال ۵,۱۴۰,۶۲۳ تن سیب زمینی در کشور تولید شده است. طبق آمار تولید سیب زمینی در جهان به ترتیب چین، هند و روسیه بیشترین تولید سیب زمینی در دنیا را دارند. چین در سال ۲۰۲۰ نزدیک به ۷۸.۱۸ میلیون تن سیب‌زمینی تولید کرده است (Anonymous, 2026).

شبکه‌ی عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرآیند یادگیری و با استفاده از پردازش-گره‌هایی به نام سلول عصبی تلاش می‌کند با شناخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. لایه یا لایه‌های مخفی، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهند. هر شبکه با دریافت مثال-هایی آموزش می‌بیند. آموزش فرایندی است که در نهایت منجر به یادگیری می‌شود. یادگیری شبکه، زمانی انجام می-شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف بین مقادیر پیش‌بینی شده و محاسبه شده در حد قابل قبولی باشد. با دست‌یابی به این شرایط فرایند یادگیری محقق شده است. این وزن‌ها حافظه و دانش شبکه را بیان می‌کنند.

شبکه عصبی آموزش دیده می‌تواند برای پیش‌بینی خروجی-های متناسب با مجموعه جدید داده‌ها به کار رود (Hristev, 1998).

گلپور و همکاران (Golpour et al., 2014) به بررسی تشخیص و طبقه‌بندی ارقام برنج در سه حالت شلتوک، قهوه‌ای و سفید با استخراج ویژگی‌های رنگی با استفاده از پردازش تصویر و شبکه عصبی مصنوعی پرداختند. نتایج حاصل از این تحقیق نشان داد که میانگین دقت طبقه‌بندی برای سه حالت شلتوک، قهوه‌ای و سفید به ترتیب ۹۸/۸٪، ۱۰۰٪ و ۱۰۰٪ می‌باشد.

شانتایا و انصاری (Shantaiya & Ansari, 2012) یک الگوریتم برای تشخیص شش واریته برنج با استفاده از ویژگی‌های ریخت‌شناسی، رنگ و بافت طراحی نمودند و از یک شبکه عصبی پس انتشار برای طبقه‌بندی این ارقام استفاده کردند.

تشخیص ارقام مختلف سیب‌زمینی از نظر تعیین ماده خشک و میزان درصد سم موجود در غده سیب‌زمینی در صنایع غذایی و تبدیلی از اهمیت بالایی برخوردار است. یکی از روش‌های کاربردی، غیر مخرب و دقیق تشخیص ارقام محصولات کشاورزی، فناوری بینایی ماشین است. فناوری بینایی ماشین از تفاوت غده‌های ارقام مختلف از نظر شکل، اندازه، رنگ و بافت برای تشخیص ارقام مختلف محصول بهره می‌گیرد. در این پژوهش برای تشخیص ارقام مختلف غده‌های سیب‌زمینی از پردازش تصویر و شبکه‌های عصبی مصنوعی استفاده شده است.

اهداف کلی این تحقیق به صورت زیر است:

- ۱- طراحی الگوریتم‌های متفاوت برای به دست آوردن ویژگی‌های ریخت‌شناسی، رنگ و بافت.
- ۲- استفاده از ویژگی‌های ریخت‌شناسی، رنگ و بافت برای تشخیص ارقام سیب‌زمینی
- ۳- طراحی نوع شبکه عصبی برای طبقه‌بندی ارقام سیب‌زمینی.

مواد و روش‌ها

جمع‌آوری نمونه‌ها

در این پژوهش ده رقم سیب‌زمینی متداول شامل رقم‌های آگریا، مارفونا، گرانولا، آرندا، سانتا، میلوا، جلی، راموس و اسپریت که به صورت وسیعی در منطقه غرب کشور کشت می‌شوند، مورد بررسی قرار گرفتند (شکل ۱). نمونه‌ها از

تبدیل شدند، در مرحله بعد حذف نویزهای موجود در تصاویر با استفاده از روش کوچک بودن مساحت نوفه‌های اطراف جسم، انجام گرفت. در نهایت با استفاده از حاصل ضرب تصویر دودویی در تصویر رنگی اولیه حذف پس زمینه انجام گرفت.

از آنجایی که برخی ویژگی‌ها از قبیل ریخت‌شناسی، رنگ و بافت، تفاوت میان اجسام را نمایش می‌دهند، بنابراین لازم است که این عامل‌ها استخراج شده و به وسیله بینایی ماشین برای تشخیص تفاوت‌های اجسام و در نهایت طبقه بندی به کار روند. الگوریتم‌ها در محیط ویندوز ۷ با استفاده از برنامه MATLAB R2012A به منظور استخراج ویژگی‌های ریخت‌شناسی، رنگی و بافتی طراحی شدند.

ویژگی‌های ریخت‌شناسی

یکی از راه‌های تشخیص ارقام استفاده از ویژگی مورفولوژی ارقام است، که این کار با استخراج ویژگی‌هایی از قبیل مساحت، نسبت ظاهری، کشیدگی، طول محور اصلی، طول محور فرعی، محیط، توپری، منحنی انرژی، میانگین فاصله، واریانس فاصله، فشردگی و برخی ویژگی‌های دیگر که از منابع متعدد استخراج شده، انجام گرفت.

مساحت (Area): عبارت است از تعداد تصاددهای درونی و مرز یک جسم (Amiri Parian, 2007).

طول محور اصلی: عبارت است از فاصله بین دو انتها در یک جسم در راستای بزرگترین قطر (Amiri Parian, 2007).
طول محور فرعی: عبارت است از فاصله بین دو انتها در یک جسم که عمود بر راستای اصلی است (Amiri Parian, 2007).

محیط: عبارت است از طول مرز جسم (Shouche et al., 2001).

توپری (Solidity): نسبت مساحت به مساحت پوسته‌ی محدب را بیان می‌نماید (Russ & Neal, 2016).

منحنی انرژی (Energy Curve): عبارت از میانگین مقدار انحنای در مرز جسم (Amiri Parian, 2007).


$$Energy Curve = \frac{1}{Pr} \sum_{i=1}^n C_i^2 \quad (1)$$

که در این معادله N، تعداد نقاط مرزی و Pr طول مرز جسم می‌باشد و Ci از معادله‌ی (۲) به دست می‌آید.

$$C_i = \sqrt{(2x_i - x_{i-1} - x_{i+1})^2 + (2y_i - y_{i-1} - y_{i+1})^2} \quad (2)$$

xi و yi مختصات تصادده i در محور مختصات است.


روستای حسام آباد از توابع شهرستان بهار استان همدان تهیه شدند. در ابتدا سیب زمینی‌های معیوب از سیب زمینی‌های سالم تفکیک و سپس برای استخراج بهتر ویژگی‌ها و کاهش خطا در تشخیص، سیب زمینی‌ها در آب شسته شدند، تا گل و لای از آن‌ها جدا شود. در نهایت از هر رقم حداقل ۳۰ نمونه انتخاب شد.



شکل ۱- ارقام سیب زمینی از چپ به راست آرندا (a)، اسپریت (b)، آگریا (c)، بامبا (d)، جلی (e)، راموس (f)، سانتا (g)، گرانولا (h)، مارفونا (i) و میلوا (j).

مراحل شناسایی ارقام سیب زمینی

این مراحل شامل گرفتن تصویر، پیش پردازش تصویر، استخراج ویژگی و طبقه بندی است (شکل ۲).



شکل ۲- مراحل شناسایی ارقام سیب زمینی

تهیه تصاویر

برای تصویربرداری از نمونه‌ها از دوربین دیجیتال CANON، ساخت ژاپن، مدل PC1742 با کیفیت تصویر ۱۲/۱ مگاتصدا نه استفاده شد. برای ایجاد شرایط یکسان و کاهش نوفه و اثرات نور محیط یک پارچه آبی به عنوان تصویر زمینه انتخاب و عکسبرداری نمونه‌ها بر روی آن انجام شد. فاصله‌ی لنز دوربین از تصویر زمینه ۴۸ سانتی متر برای تمام تصاویر در نظر گرفته شد. از نمونه‌های هر رقم ۳۰ تصویر با ۱۰ تکرار به اندازه ۳۰۰۰×۴۰۰۰ تصادده تهیه شد.

معمولاً به خاطر بعضی عوامل مانند نوفه، تغییرات روشنایی، شرایط آب و هوایی، کیفیت کم تصاویر و پیش زمینه نامطلوب ممکن است تصاویر به صورت مستقیم برای اهداف تشخیص و طبقه بندی مناسب نباشند. در مرحله پیش پردازش ابتدا با استفاده از روش آستانه‌گیری، آستانه مناسب برای تصاویر انتخاب شد. سپس تصاویر رنگی به تصاویر دودویی

ویژگی‌های رنگی

راه دیگر تشخیص ارقام استفاده از ویژگی رنگی تصاویر است. از دو فضای رنگی RGB و HSI برای استخراج ویژگی‌های رنگی استفاده شد. در فضای رنگی RGB برای سه مؤلفه رنگی قرمز (R)، سبز (G) و آبی (B)، میانگین، محدوده تغییرات، واریانس و انحراف معیار با استفاده از معادلات (۱۱) تا (۱۴) به دست آمد (Golpour et al., 2012).

$$mean = \frac{1}{n} \sum_{i=1}^n x_i \quad (11)$$

$$range = \max(x_i) - \min(x_i) \quad (12)$$

$$variance = \frac{1}{n-1} \sum_{i=1}^n (x_i - mean)^2 \quad (13)$$

$$stdev = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - mean)^2} \quad (14)$$

در فضای رنگی HSI برای سه مؤلفه رنگی شدت (I)، اشباع (S) و اصل رنگ (H)، میانگین، محدوده تغییرات، واریانس و انحراف معیار با استفاده از معادلات (۱۵) تا (۱۸) به دست آمد (Gonzalez & Woods, 2018).

$$I = \frac{1}{3} (R + G + B) \quad (15)$$

$$S = 1 - \frac{3}{R+G+B} [Min(R, G, B)] \quad (16)$$

$$H = \cos^{-1} \left\{ \frac{1/2[(R-G)+(R-B)]}{[(R-G)^2+(R-B)(G-B)]^2} \right\} \quad (17)$$

$$H = 2\pi - \cos^{-1} \left\{ \frac{1/2[(R-G)+(R-B)]}{[(R-G)^2+(R-B)(G-B)]^2} \right\} \quad (18)$$

الگوریتم استفاده شده برای استخراج ویژگی‌های رنگی به صورت زیر است:
مرحله یک: جداسازی لایه‌های رنگی از تصویر تمام رنگی ورودی.

مرحله دو: به دست آوردن ترکیب HSI از ترکیب رنگی RGB با استفاده از معادلات (۱۵) تا (۱۸).

مرحله سه: محاسبه میانگین، محدوده تغییرات، واریانس و انحراف معیار برای دو ترکیب رنگی RGB و HSI با استفاده از معادلات (۱۱) تا (۱۴).

مرحله چهار: توقف.

در نهایت ۲۴ ویژگی رنگی در فضای رنگی RGB و HSI به دست آمد که در جدول ۱ نمایش داده شده است.

ویژگی‌های بافتی

به دلیل این که ممکن است ویژگی رنگی و ریخت‌شناسی برخی ارقام مشابه باشد از ویژگی بافتی برای استخراج مشخصات بافت استفاده شد. ابتدا سطوح خاکستری تصاویر رنگی استخراج شد. سپس با استفاده از ماتریس هم‌وقوعی^۱، ده ویژگی برای هر مؤلفه رنگی در چهار زاویه استخراج گردید. در نهایت ۱۲۰ ویژگی بافتی برای هر رقم استخراج شد.

فاصله‌ی میانگین (mendis): میانگین فاصله اقلیدسی هر تصادنه از گرانیگاه را فاصله میانگین گویند (Shouche et al., 2001). گرانیگاه به مختصات $(Y_{centroid}, X_{centroid})$ عبارت از مختصات مکانی تصادنه‌ای است که در مرکز تصویر قرار دارد.

(۳)

$$mendis = \frac{1}{N} \sum_{i=1}^N \sqrt{(x_i - x_{centroid})^2 + (y_i - y_{centroid})^2}$$

واریانس فاصله (vardis):

میانگین تفاضل فاصله اقلیدسی هر تصادنه از گرانیگاه تصویر و فاصله‌ی میانگین (Amiri Parian, 2007).

(۴)

$$vardis = \frac{1}{N-1} \sum_{i=1}^N (\sqrt{(x_i - x_{centroid})^2 + (y_i - y_{centroid})^2} - mendis)^2$$

فشرده‌گی (Compression): نسبت مجذور محیط به مساحت جسم (Shouche et al., 2001).

$$Compression = \frac{perimeter^2}{Area} \quad (5)$$

ویژگی‌هایی که در ذیل ارائه می‌گردد به دلیل عدم وجود نام مناسب طبق تعریف منبع مستخرج بیان می‌شوند (Amiri Parian, 2007).

$$factor1 = \frac{4\pi \times Area}{perimeter^2} \quad (6)$$

$$Shape\ factor2 = \frac{Major\ Axis\ Length}{Area} \quad (7)$$

$$Shape\ factor3 = \frac{Area}{Major\ Axis\ Length^3} \quad (8)$$

$$Shape\ factor4 = \frac{Area}{\pi (Major\ Axis\ \frac{Length}{2})^2} \quad (9)$$

(۱۰)

$$Shape\ factor5 = \frac{Area}{\pi \left(Major\ Axis\ \frac{Length}{2} \right) \left(Minor\ Axis\ \frac{Length}{2} \right)}$$

الگوریتم استفاده شده برای استخراج ویژگی‌های ریخت‌شناسی سیب‌زمینی به صورت زیر است:

مرحله یک: تبدیل تصاویر RGB به تصاویر دودویی
مرحله دو: حذف نوفه‌های تصویر با استفاده از روش کوچک بودن مساحت تصاویر اطراف جسم با مساحت بیش‌تر.
مرحله سه: کاهش دادن ابعاد تصاویر بزرگ به منظور بالا بردن سرعت پردازش

مرحله چهار: استخراج ویژگی‌ها با استفاده از روابط تعریف شده در MATLAB و روابط تعریف شده در معادلات (۱) تا (۱۰).
مرحله پنج: توقف

^۱ Gray Level Co-occurrence Matrix (GLCM)

جدول ۱- ویژگی‌های رنگی براساس مدل‌های رنگی RGB و HSI

شماره ویژگی	ویژگی	شماره ویژگی	ویژگی
۱	میانگین رنگ قرمز	۱۳	میانگین اصل رنگ
۲	محدوده تغییرات رنگ قرمز	۱۴	محدوده تغییرات اصل رنگ
۳	واریانس رنگ قرمز	۱۵	واریانس اصل رنگ
۴	انحراف معیار رنگ قرمز	۱۶	انحراف معیار اصل رنگ
۵	میانگین رنگ سبز	۱۷	میانگین اشباع
۶	محدوده تغییرات رنگ سبز	۱۸	محدوده تغییرات اشباع
۷	واریانس رنگ سبز	۱۹	واریانس اشباع
۸	انحراف معیار رنگ سبز	۲۰	انحراف معیار اشباع
۹	میانگین رنگ آبی	۲۱	میانگین شدت
۱۰	محدوده تغییرات رنگ آبی	۲۲	محدوده تغییرات شدت
۱۱	واریانس رنگ آبی	۲۳	واریانس شدت
۱۲	انحراف معیار رنگ آبی	۲۴	انحراف معیار شدت

ویژگی‌های ماتریس هم‌وقوعی

فرض کنیم هر تصویر، یک ماتریس با ابعاد N_x ستون و N_y سطر بوده و درایه‌های آن N_g سطح خاکستری متفاوت، داشته باشند. با این فرض، اطلاعات بافتی تصویر را می‌توان به وسیله یک ماتریس فراوانی نسبی $P(i,j)$ نشان داد. در این ماتریس مقدار درایه (i,j) بیانگر تعداد همسایگی‌های اتفاق افتاده در تصویر بین سطوح خاکستری i و j است. براین اساس می‌توان ماتریس هم‌وقوعی را در همسایگی‌های متفاوت به دست آورد (Solomon & Breckon, 2011). برای نرمال کردن ماتریس هم‌وقوعی باید درایه‌های آن را مطابق رابطه (۱۹) بریک عدد ثابت تقسیم نمود.

$$P(i,j) = \frac{P(i,j)}{C} \quad (19)$$

مقدار C برای یک تصویر با ابعاد مستطیلی N_y و N_x از رابطه (۲۰) به دست می‌آید (Majumdar & Jayas, 1999).

$$(20)$$

$C = 2N_x(N_y - 1) + 2N_y(N_x - 1) + 4(N_x - 1)(N_y - 1)$
از ماتریس هم‌وقوعی تصویر، ۱۰ ویژگی شامل میانگین، واریانس، وضوح، همگنی، حداکثر احتمال، همبستگی، انرژی و آنتروپی، سایه خوشه و برجستگی خوشه استخراج گردید که معادلات مربوط به این ویژگی‌ها در جدول ۲ آمده است (Majumdar & Jayas, 1999).

روش محاسبه ویژگی‌های بافتی در الگوریتم زیر توضیح داده شده است:

مرحله یک: به دست آوردن ترکیبات رنگی RGB از تصاویر اصلی.

مرحله دو: برای همه ترکیبات رنگی RGB ماتریس GLCM برای چهارجهت (صفر، ۴۵، ۹۰ و ۱۳۵ درجه) محاسبه شد. مرحله سه: محاسبه ماتریس هم‌وقوعی و نرمال کردن آن. مرحله چهار: به دست آوردن ویژگی‌های بافتی از GLCM با استفاده از روابط جدول (۲).

مرحله پنج: توقف.

در زیر برخی از ویژگی‌های بافتی به اختصار بیان می‌شوند:

آنتروپی: یک اندازه از پیچیدگی تصویر را نشان می‌دهد. ساختار پیچیده دارای آنتروپی بالاتری است. وقتی که بسامد شدت‌ها حالت یکنواختی داشته باشد، بیشترین مقدار آنتروپی $\log_2 z$ است. کمینه مقدار آنتروپی برابر صفر است و وقتی اتفاق می‌افتد که همه تصادف‌ها شدت برابر داشته باشند.

وضوح: میزان تغییرات محلی رنگ در تصویر را ارائه می‌دهد. مقادیر بالای وضوح مربوط به تغییرات روشنی در ساختار تصویر است.

انرژی: بیان‌گر میزان نظم و هم‌جنسی در تصویر است. بنابراین این عامل، یک عامل مناسب جهت اندازه‌گیری بی-نظمی در ساختار تصویر می‌باشد. برای ساختارهای یکنواخت و هم‌جنس، مقدار انرژی نسبت به ساختارهای غیر هم‌جنس کم‌تر است.

بیشینه احتمال: بیشینه همسایگی سطوح خاکستری در جهت مشخص را ارائه می‌دهد.

یکنواختی: شباهت تصادف‌ها را اندازه می‌گیرد. سطوح خاکستری قطری ماتریس مجاورت دارای یکنواختی یک است.

دلتا، کوئیک پراپ، گرادیان مزدوج، مومنتوم و مرحله‌ای (Hoseinzadeh- Talaei, 2010).

در پژوهش حاضر روش شبکه عصبی مصنوعی به منظور تشخیص و طبقه‌بندی واریته‌های سیب‌زمینی استفاده گردید و نتایج با داده‌های حاصل از نرم افزار MATLAB با استفاده از برنامه ی SIGMAPLOT11 مقایسه گردید.

استاندارد سازی و تصادفی نمودن داده‌ها

یکی از مهم‌ترین دلایل نرمال‌سازی داده‌ها، یکسان سازی اهمیت متغیرها و اصلاح وزن‌های شبکه عصبی مصنوعی است (Unal *et al.*, 2010). همچنین بدون نرمال‌سازی، مقادیر بزرگ ورودی نیازمند وزن‌های بسیار کوچک در شبکه بوده که این امر باعث بروز خطا در شبکه می‌گردد (Dawson & Wilby, 1998). برای اجتناب از چنین شرایطی و همچنین به منظور یکسان نمودن ارزش داده‌ها، قبل از آموزش شبکه عصبی مصنوعی، داده‌های ورودی به آن بایستی استاندارد (نرمال) شوند. این کار مانع از کوچک شدن بیش از حد وزن‌ها می‌گردد (Sajikumar & Thandavewra, 1999). در عین حال این کار به این علت صورت می‌پذیرد که داده‌ها به اعدادی بین ۰ و ۱ تبدیل گردند، به این علت که خروجی اکثر توابع آستانه‌ای اعداد مابین ۰ و ۱ هستند و شکل داده‌های ورودی در آن نقش مهمی در یادگیری شبکه ایفا می‌کند (Hoseinzadeh- Talaei, 2010). همچنین با توجه به سامانه کار شبکه‌های عصبی مصنوعی، در صورتی که داده‌ها نرمال- سازی نشوند، سلول‌های عصبی سریع‌تر اشباع شده و ورودی خالص سلول‌های عصبی را نمی‌توان در محدوده‌ای مناسب قرار داد. به علت اینکه در ورودی‌های نزدیک ۰ و ۱ عناصر پردازش‌گر به دلیل شکل توابع، کند عمل می‌کنند و تغییرات وزن سلول‌های عصبی‌ها حداقل خواهد بود. بنابراین از رابطه ۲۱ برای نرمال‌سازی داده‌های ورودی به مدل استفاده شد.

$$X_{\text{norm}} = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (21)$$

که در آن، X_{norm} مقدار نرمال شده ورودی، X_i داده ورودی، $X_{\max}$ و $X_{\min}$ به ترتیب مقدار حداکثر و حداقل داده‌ها است.

تصادفی نمودن داده‌ها نیز به منظور خارج شدن ترتیب قرار گرفتن ردیف داده‌ها از حالت اولیه خود می‌باشد. تصادفی

جدول ۲- ویژگی‌های بافتی

خواص	رابطه
آنتروپی	$-\sum_{i=1}^{N_G} \sum_{j=1}^{N_G} p(i, j) \log\{p(i, j)\}$
انرژی	$\sum_{i=1}^{N_G} \sum_{j=1}^{N_G} \{p(i, j)\}^2$
وضوح	$\sum_{i=1}^{N_G} \sum_{j=1}^{N_G} (i - j)^2 p(i, j)$
همگنی	$\sum_{i=1}^{N_G} \sum_{j=1}^{N_G} \frac{p(i, j)}{1 + (i - j)^2}$
میانگین	$\sum_{i=1}^{N_G} \sum_{j=1}^{N_G} ip(i, j)$
واریانس	$\sum_{i=1}^{N_G} \sum_{j=1}^{N_G} (i - \mu)^2 p(i, j)$
همبستگی	$\sum_{i=1}^{N_G} \sum_{j=1}^{N_G} \frac{(i - \mu)(j - \mu)}{\sigma^2} p(i, j)$
بیشینه احتمال	$\max\{p(i, j)\}$
سایه خوشه	$\sum_{i=1}^{N_G} \sum_{j=1}^{N_G} (i + j - 2\mu)^3 p(i, j)$
برجستگی خوشه	$\sum_{i=1}^{N_G} \sum_{j=1}^{N_G} (i + j - 2\mu)^4 p(i, j)$

مراحل طراحی شبکه عصبی مصنوعی

۱- طراحی معماری شبکه


این مرحله شامل تعیین تعداد لایه‌های موجود در شبکه، تعداد سلول عصبی‌های هر لایه، تعیین برگشت‌پذیر بودن یا نبودن شبکه است که با توجه به نوع مسئله تعیین می‌گردد. (برای مثال شبکه‌های برگشتی در اغلب موارد برای مسائل پویا کاربرد دارند و یا اینکه شبکه‌های پرسپترون پیش‌خور، برای نگاشت‌های غیرخطی کاربرد دارند).

۲- تعیین نوع تابع انتقال (تعیین تابع انتقال از روش آزمون و خطا با تکرارهای زیاد انجام می‌شود).

۳- آموزش شبکه

الگوریتم یادگیری در واقع یک نوع الگوریتم ریاضی پیچیده است. الگوریتم‌های مختلفی در شبکه عصبی مصنوعی وجود دارد که چند مورد آن‌ها عبارتند از: لونیگ-مارکوارت، دلتا بار


در مرحله بعد تصاویر دودویی تصحیح شده در تصاویر رنگی ضرب می‌شود که این کار برای صفر کردن پس‌زمینه است (شکل ۳). پس از انجام همه‌ی این مراحل سرانجام تصویر نهایی برای استخراج ویژگی مورد استفاده قرار گرفت.



شکل ۳- الگوریتم تفکیک و کاهش نویز مراحل پیش پردازش

شناسایی ارقام سیب‌زمینی با استفاده از شبکه پس انتشار ویژگی‌هایی که در مرحله قبل استخراج شده بودند، به عنوان ورودی‌های شبکه و ارقام سیب‌زمینی به عنوان خروجی‌های شبکه‌ی عصبی مصنوعی محسوب شدند. در نهایت چندین شبکه با ساختارهای متفاوت، برای تشخیص و شناسایی ارقام سیب‌زمینی آموزش داده شد و دقت شبکه‌ها در شناسایی ارقام مورد ارزیابی قرار گرفت. ۳۰۰ الگو برای آموزش و ارزیابی شبکه مورد استفاده قرار گرفت (۷۰٪ جهت آموزش و ۳۰٪ جهت ارزیابی شبکه). در ابتدا شبکه با یک لایه پنهان و سپس با دو لایه پنهان آموزش داده شد و در نهایت با استفاده از خروجی‌های شبکه، میانگین طبقه‌بندی ارقام به دست آورده شد.

طبقه‌بندی ارقام سیب‌زمینی با استفاده از ویژگی‌های ریخت‌شناسی و شبکه عصبی مصنوعی با یک لایه پنهان در ابتدا ۱۶ ویژگی رنگی به عنوان ورودی‌های شبکه و ۱۰ رقم به عنوان خروجی شبکه در نظر گرفته شد، سپس آموزش شبکه و ارزیابی آن و در نهایت میانگین دقت طبقه‌بندی ارقام سیب‌زمینی به دست آمد. همان طور که در جدول (۳) مشاهده می‌شود در حالات مختلف توابع انتقال، با استفاده از تابع خطی در خروجی و تابع لگاریتم سیگموئید در لایه پنهان با آرایش شبکه ۱۰-۱۷-۱۶ بهترین ساختار در الگوریتم آموزشی LM با بیش‌ترین میانگین دقت طبقه‌بندی ۸۸/۰۹ و میانگین خطای مربعات ۰/۱۳۵۹ و ضریب تعیین ۰/۹۹۶۵ و تعداد چرخه آموزش ۱۷ به دست آمد (شکل ۴).



شکل ۴- نمای شبکه یک لایه برای شناسایی ارقام سیب-زمینی با استفاده از ویژگی‌های ریخت‌شناسی

نمودن موقعی به صورت صحیح انجام می‌گیرد که بیش‌ترین کم‌ترین مقدار خروجی مشاهده‌ای در قسمت داده‌های آموزشی قرار بگیرد و آن هم به این دلیل است که شبکه بتواند بحرانی‌ترین حالت‌ها را تجربه نماید (Shabani, 2011).

در تحقیق حاضر، جهت طراحی شبکه عصبی مصنوعی از جعبه ابزار شبکه عصبی مصنوعی در نرم افزار MATLAB استفاده گردیده است. در این تحقیق از ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد داده‌ها برای آزمون استفاده شد.

ارزیابی کارایی مدل

در این قسمت با استفاده از داده‌های آزمون، ارزیابی دقت پیش بینی مدل مورد سنجش قرار گرفت. برای مقایسه کمی عملکرد مدل‌های پیشنهادی می‌توان از تجزیه و تحلیل خطاهای باقیمانده و اختلاف بین مقادیر اندازه‌گیری شده و برآورده شده بهره گرفت. آماره‌های زیادی برای ارزیابی عملکرد مدل‌ها وجود دارد (Homaei et al., 2002). در این پژوهش از میانگین مربع خطا (MSE) و ضریب تعیین (R^2) برای ارزیابی عملکرد مدل استفاده شد. بیان ریاضی این آماره‌ها بصورت زیر است:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_{\text{estimated}} - Y_{\text{target}})^2 \quad (22)$$

که در آن MSE، میانگین مربع خطا، n تعداد داده‌ها، $Y_{\text{estimated}}$ خروجی شبکه و Y_{target} خروجی‌های واقعی است.

$$R^2 = 1 - \left(\frac{\sum_{i=1}^n (Y_{\text{estimated}} - Y_{\text{target}})^2}{\sum_{i=1}^n (Y_{\text{target}})^2} \right) \quad (23)$$

مقدار MSE نشان می‌دهد که پیش‌بینی‌ها تا چه حد، اندازه‌گیری‌ها را بیش‌تر یا کم‌تر تخمین زده‌اند. در شرایطی که مقادیر پیش‌بینی شده و اندازه‌گیری شده با هم برابر باشند (حالت ایده‌آل) مقدار آماره‌ها به ترتیب $MSE=0$ ، $R^2=1$ خواهد بود (Shabani, 2011).

نتایج و بحث

پردازش تصویر

پس از عملیات تهیه تصاویر رنگی، به دلیل بالا بردن دقت پردازش، برش تصاویر انجام شد. پس از برش تصویر، تصاویر رنگی با روش آستانه‌گیری به تصاویر دودویی تبدیل شدند. سپس با استفاده از روش حذف مساحت‌های کوچک، مساحت‌های کوچک اطراف تصویر سیب‌زمینی حذف شدند و

جدول (۴) استفاده از آرایش شبکه ۱۰-۱۷-۲۴ بهترین ساختار در الگوریتم آموزشی LM با بیش‌ترین میانگین دقت طبقه‌بندی ۲۷/۶۱ و میانگین خطای مربعات ۳/۸۶۲۹ و ضریب تعیین ۰/۹۰۰۸ با تعداد چرخه آموزش ۱۳ به دست آمد. همچنین با توجه به جدول (۴) تابع خروجی لگاریتم سیگموئید و لایه پنهان خطی، دقت شبکه در شناسایی ارقام به شدت سیر نزولی پیدا می‌نمود.

همچنین با توجه به جدول (۳)، با تابع خروجی لگاریتم سیگموئید دقت شبکه در شناسایی ارقام به شدت سیر نزولی پیدا نمود.

طبقه بندی ارقام با استفاده از ویژگی های رنگی و شبکه‌های عصبی مصنوعی با یک لایه پنهان
در این بخش ۲۴ ویژگی رنگی به عنوان ورودی شبکه و ۱۰ رقم به عنوان خروجی شبکه در نظر گرفته شد. با توجه به

جدول ۳- تأثیر توابع انتقال در تشخیص ارقام سیب‌زمینی با استفاده از ویژگی های ریخت‌شناسی

توابع انتقال (لایه خروجی - لایه پنهان)	آرایش شبکه	تعداد چرخه آموزش	میانگین دقت طبقه بندی (%)	میانگین خطای مربعات	ضریب تعیین
خطی - لگاریتم سیگموئید	۱۶-۱۷-۱۰	۱۷	۸۸/۰۹	۰/۱۳۵۹	۰/۹۹۶۵
خطی - تانژانت سیگموئید	۱۶-۸-۱۰	۱۴	۸۶/۱۹	۰/۳۶۷۸	۰/۹۹۰۶
تانژانت سیگموئید - تانژانت سیگموئید	۱۶-۲۳-۱۰	۱۴	۸۲/۳۸	۰/۱۵۳۴	۰/۹۹۶۱
تانژانت سیگموئید - لگاریتم سیگموئید	۱۶-۱۳-۱۰	۱۵	۷۹/۰۴	۰/۲۰۲۹	۰/۹۹۴۸
خطی - خطی	۱۶-۱۷-۱۰	۴	۵۹/۰۴	۰/۵۸۰۲	۰/۹۸۵۱
تانژانت سیگموئید - خطی	۱۶-۲۰-۱۰	۹	۵۹/۰۴	۰/۴۹۸۳	۰/۹۸۷۲
لگاریتم سیگموئید - لگاریتم سیگموئید	۱۶-۱۴-۱۰	۳۳	۴۵/۲۳	۴/۲۶۱۵	۰/۸۹۰۹
لگاریتم سیگموئید - خطی	۱۶-۲۶-۱۰	۱۰	۴۴/۲۸	۴/۳۷۶۷	۰/۸۸۷۹
لگاریتم سیگموئید - تانژانت سیگموئید	۱۶-۸-۱۰	۱۴	۴۰/۹۵	۴/۳۲۴۹	۰/۸۸۹۳

گرفته شد. سپس آموزش شبکه و ارزیابی به وسیله جعبه ابزار شبکه عصبی MATLAB برای شناسایی ارقام سیب‌زمینی انجام و بهترین نتایج در جدول (۵) گزارش شد. با توجه به نتایج به دست آمده از جدول (۵) بهترین میانگین دقت طبقه بندی مربوط به تابع انتقال با لایه پنهان تانژانت سیگموئید و با لایه خروجی تانژانت سیگموئید با آرایش شبکه ۱۰-۲۳-۴۰ و میانگین دقت طبقه بندی ۲۰ درصد با میانگین مربعات خطا ۶/۹۱۲۱ و ضریب تعیین ۰/۸۱۵۰ و با ۱۱ چرخه آموزش به دست آمد.

طبقه‌بندی ارقام با استفاده از ویژگی‌های بافتی و شبکه‌های عصبی مصنوعی با یک لایه پنهان برای سطح خاکستری سبز
به منظور طبقه‌بندی ارقام سیب‌زمینی براساس مؤلفه‌ی بافتی، ۴۰ ویژگی بافتی که در بخش قبل با استفاده از پردازش تصویر استخراج شده بود، را برای سطح خاکستری رنگ سبز به عنوان ورودی‌های شبکه و ۱۰ رقم سیب‌زمینی به عنوان خروجی‌های شبکه در نظر گرفته شد. سپس آموزش شبکه و ارزیابی به وسیله جعبه ابزار شبکه عصبی MATLAB برای شناسایی

طبقه بندی ارقام با استفاده از ویژگی های بافتی و شبکه‌های عصبی مصنوعی با یک لایه پنهان
در این بخش در مجموع، ۱۲۰ ویژگی بافتی استخراج شده را در سه دسته رنگی، قرمز، سبز و آبی تقسیم بندی و در سه بخش جداگانه به شبکه عصبی مصنوعی آموزش داده شده و ارزیابی شد. سپس با استفاده از میانگین دقت طبقه‌بندی بالا، بهترین ساختار را انتخاب کرده و در مرحله بعد به منظور شناسایی ارقام با بالاترین میانگین دقت، از سطوح خاکستری تصویر، بهترین سطح خاکستری را برای شناسایی ارقام سیب-زمینی با استفاده از مقایسه میانگین دقت طبقه‌بندی از میان ساختارهای مختلف انتخاب نموده و در نهایت شبکه بهینه برای شبکه دولایه انتخاب می‌شود.

طبقه‌بندی ارقام با استفاده از ویژگی‌های بافتی و شبکه‌های عصبی مصنوعی با یک لایه پنهان برای سطح خاکستری قرمز
برای طبقه‌بندی ارقام سیب‌زمینی براساس مؤلفه‌ی بافتی، ۴۰ ویژگی بافتی برای مؤلفه‌ی رنگ قرمز به عنوان ورودی‌های شبکه و ۱۰ رقم سیب‌زمینی به عنوان خروجی‌های آن در نظر

۱۷-۴۰ و میانگین دقت طبقه‌بندی ۲۴/۲۸ درصد با میانگین مربعات خطا ۴/۸۴۱۴ و ضریب تعیین ۰/۸۷۴۷ با تعداد چرخه آموزش ۱۳ به دست آمد.

ارقام سیبزمینی انجام و بهترین نتایج در جدول (۶) گزارش شد. با توجه به نتایج به دست آمده از جدول (۶) بهترین میانگین دقت طبقه‌بندی مربوط به تابع انتقال با لایه پنهان تانزانت سیگموئید و با لایه خروجی خطی با آرایش شبکه ۱۰-

جدول ۴- تأثیر توابع انتقال در تشخیص ارقام سیبزمینی با استفاده از ویژگی‌های رنگی

توابع انتقال (لایه خروجی- لایه پنهان)	آرایش شبکه	تعداد چرخه آموزش	میانگین دقت طبقه بندی (%)	میانگین خطای مربعات	ضریب تعیین
تانزانت سیگموئید- تانزانت سیگموئید	۱۰-۱۷-۲۴	۱۳	۲۷/۶۱	۳/۸۶۲۹	۰/۹۰۰۸
خطی- لگاریتم سیگموئید	۱۰-۲۶-۲۴	۱۱	۲۵/۲۳	۴/۹۱۱۴	۰/۸۷۳۹
لگاریتم سیگموئید- تانزانت سیگموئید	۱۰-۱۴-۲۴	۲۳	۲۳/۸۰	۶/۱۷۰۸	۰/۸۴۱۵
تانزانت سیگموئید- لگاریتم سیگموئید	۱۰-۸-۲۴	۱۲	۲۳/۳۳	۴/۰۰۱۸	۰/۸۹۷۲
خطی- تانزانت سیگموئید	۱۰-۲۶-۲۴	۹	۲۱/۴۲	۴/۳۹۴۶	۰/۸۸۷۲
لگاریتم سیگموئید- لگاریتم سیگموئید	۱۰-۱۱-۲۴	۱۶	۱۹/۵۲	۵/۵۶۵۸	۰/۸۵۷۱
خطی- خطی	۱۰-۱۱-۲۴	۴	۱۸/۰۹	۵/۶۸۸۶	۰/۸۵۳۹
تانزانت سیگموئید- خطی	۱۰-۲۳-۲۴	۱۱	۱۶/۶۶	۵/۷۰۸۶	۰/۸۵۳۴
لگاریتم سیگموئید- خطی	۱۰-۱۴-۲۴	۱۵	۱۳/۸۰	۶/۷۳۹۱	۰/۸۲۶۹

دوم، به ترتیب ۲ و ۱ انتخاب شدند و تعداد سلول عصبی در لایه های پنهان در هر مرحله یک عدد اضافه شد. در نهایت تعداد سلول عصبی در لایه پنهان اول ۱ تا ۲۰ و تعداد سلول عصبی در لایه های پنهان دوم ۲ تا ۲۱ بودند

ارزیابی شبکه با دو لایه پنهان در تعیین دقت طبقه‌بندی ارقام سیبزمینی با استفاده از ویژگی‌های ریخت‌شناسی با توجه به نتایج به دست آمده از جدول (۳) تابع انتقال لگاریتم سیگموئید در لایه پنهان و تابع انتقال خطی در لایه خروجی به عنوان بهترین ساختار برای ایجاد شبکه دو لایه در نظر گرفته شد (شکل ۵). پس از ارزیابی شبکه با تعداد سلول- های عصبی مختلف در دو لایه پنهان، بیشترین دقت طبقه بندی مربوط به شبکه‌ای با تعداد سلول عصبی به ترتیب ۵ و ۶ در این دو لایه مشاهده شد. میانگین دقت شناسایی ارقام سیبزمینی ۸۶/۱۹ درصد با ضریب تعیین ۰/۹۹۴۹ و میانگین خطای مربعات ۰/۱۹۷۳ با تعداد چرخه آموزش ۳۸ برای این شبکه بهینه آمد.

این روش نسبت به ارزیابی شبکه با یک لایه پنهان برای شناسایی ارقام، درصد دقت نسبتاً پایین تری ارائه داد. بنابراین شبکه با یک لایه پنهان برای ویژگی‌های ریخت‌شناسی به منظور تشخیص ارقام سیبزمینی، بهتر تشخیص داده شد.

طبقه‌بندی ارقام با استفاده از ویژگی‌های بافتی و شبکه عصبی مصنوعی با یک لایه پنهان برای سطح خاکستری آبی به منظور طبقه‌بندی ارقام سیبزمینی براساس مؤلفه‌ی بافتی، ۴۰ ویژگی بافتی که در فصل قبل با استفاده از پردازش تصویر استخراج شده بود، را برای سطح خاکستری آبی به عنوان ورودی‌های شبکه و ۱۰ رقم سیبزمینی به عنوان خروجی‌های شبکه در نظر گرفته شد. سپس آموزش شبکه و ارزیابی به وسیله جعبه ابزار شبکه عصبی MATLAB برای شناسایی ارقام سیبزمینی انجام و بهترین نتایج در جدول (۷) گزارش شد. با توجه به نتایج به دست آمده از جدول (۷) بهترین میانگین دقت طبقه‌بندی مربوط به تابع انتقال با لایه پنهان تانزانت سیگموئید و با لایه خروجی تانزانت سیگموئید با آرایش شبکه ۱۰-۲۳-۴۰ و میانگین دقت طبقه‌بندی ۲۳/۸۰ درصد با میانگین خطای مربعات ۴/۹۴۷۳ و ضریب تعیین ۰/۸۶۹۸ تعداد چرخه آموزش ۱۵ به دست آمد.

ارزیابی شبکه با دو لایه پنهان با استفاده از ویژگی‌ها جهت تعیین تعداد سلول عصبی بهینه در لایه پنهان، شبکه‌هایی با ساختار B-X-Y-A طراحی شدند. که در این ساختار A، تعداد ویژگی‌های ورودی، Y تعداد سلول عصبی در لایه پنهان اول، X تعداد سلول عصبی در لایه پنهان B و تعداد ارقام می باشد. تعداد سلول عصبی در لایه پنهان اول و

جدول ۵- تأثیر توابع انتقال در تشخیص ارقام سیب‌زمینی با استفاده از ویژگی‌های بافتی سطح خاکستری قرمز

توابع انتقال (لایه خروجی - لایه پنهان)	آرایش شبکه	تعداد چرخه آموزش	میانگین دقت طبقه بندی (%)	میانگین خطای مربعات	ضریب تعیین
تانزانت سیگموئید - تانزانت سیگموئید	۴۰-۲۳-۱۰	۱۱	۲۰	۶/۹۱۲۱	۰/۸۱۵۰
تانزانت سیگموئید - خطی	۴۰-۵-۴۰	۸۴	۱۹/۵۲	۵/۴۸۵۴	۰/۸۵۳۲
خطی - لگاریتم سیگموئید	۴۰-۲۰-۴۰	۹	۱۶/۱۹	۷/۳۲۴۵	۰/۸۰۴۰
تانزانت سیگموئید - لگاریتم سیگموئید	۴۰-۲۳-۴۰	۹	۱۵/۲۳	۶/۵۹۷۰	۰/۸۲۳۵
خطی - تانزانت سیگموئید	۴۰-۱۷-۴۰	۹	۱۴/۷۶	۶/۴۷۱۷	۰/۸۲۶۸
خطی - خطی	۴۰-۱۷-۴۰	۳۲	۱۴/۷۴	۶/۸۵۳۳	۰/۸۱۶۶
لگاریتم سیگموئید - تانزانت سیگموئید	۴۰-۲۰-۴۰	۱۲	۱۱/۴۲	۷/۸۹۴۳	۰/۷۸۸۸
لگاریتم سیگموئید - خطی	۴۰-۱۱-۴۰	۱۴	۱۰/۹۵	۷/۹۸۲۰	۰/۷۸۶۴
لگاریتم سیگموئید - لگاریتم سیگموئید	۴۰-۲۳-۴۰	۱۱	۸/۵۷	۷/۹۵۷۲	۰/۷۸۷۱


جدول ۶- تأثیر توابع انتقال در تشخیص ارقام سیب‌زمینی با استفاده از ویژگی‌های بافتی مؤلفه سبز

توابع انتقال (لایه خروجی - لایه پنهان)	آرایش شبکه	تعداد چرخه آموزش	میانگین دقت طبقه بندی (%)	میانگین خطای مربعات	ضریب تعیین
خطی - تانزانت سیگموئید	۴۰-۱۷-۴۰	۱۳	۲۴/۲۸	۴/۸۴۱۴	۰/۸۷۴۷
تانزانت سیگموئید - تانزانت سیگموئید	۴۰-۲۳-۴۰	۱۳	۱۹/۵۲	۵/۷۱۷۲	۰/۸۵۲۱
تانزانت سیگموئید - لگاریتم سیگموئید	۴۰-۲۰-۴۰	۱۱	۱۹/۰۴	۵/۶۶۶۲	۰/۸۵۳۴
خطی - لگاریتم سیگموئید	۴۰-۱۴-۴۰	۹	۱۵/۷۱	۶/۰۰۵۹	۰/۸۴۴۷
لگاریتم سیگموئید - خطی	۴۰-۱۷-۴۰	۱۰	۱۴/۷۶	۷/۵۳۱۸	۰/۸۰۵۲
لگاریتم سیگموئید - تانزانت سیگموئید	۴۰-۵-۴۰	۹	۱۳/۸۰	۷/۲۵۰۸	۰/۸۱۲۵
خطی - خطی	۴۰-۱۷-۴۰	۲۰	۱۳/۳۳	۶/۶۴۴۴	۰/۸۲۸۱
تانزانت سیگموئید - خطی	۴۰-۲۳-۴۰	۱۲	۱۲/۳۸	۶/۸۲۸۱	۰/۸۲۳۴
لگاریتم سیگموئید - لگاریتم سیگموئید	۴۰-۱۴-۴۰	۱۱	۱۲/۳۸	۷/۰۰۹۸	۰/۸۱۸۷

جدول ۷- تأثیر توابع انتقال در تشخیص ارقام سیب‌زمینی با استفاده از ویژگی‌های بافتی مؤلفه آبی

توابع انتقال (لایه خروجی - لایه پنهان)	آرایش شبکه	تعداد چرخه آموزش	میانگین دقت طبقه بندی (%)	میانگین خطای مربعات	ضریب تعیین
تانزانت سیگموئید - تانزانت سیگموئید	۴۰-۲۳-۱۰	۱۵	۲۳/۸۰	۴/۹۴۷۳	۰/۸۶۹۸
خطی - خطی	۴۰-۸-۱۰	۸۸	۲۱/۹۰	۳/۷۷۳۵	۰/۹۰۰۷
خطی - لگاریتم سیگموئید	۴۰-۱۴-۱۰	۹	۱۷/۱۴	۶/۰۹۴۱	۰/۸۳۹۷
لگاریتم سیگموئید - لگاریتم سیگموئید	۴۰-۱۴-۱۰	۱۶	۱۷/۱۴	۶/۲۸۸۲	۰/۸۳۴۶
خطی - تانزانت سیگموئید	۴۰-۱۷-۱۰	۱۲	۱۵/۲۳	۵/۵۱۰۸	۰/۸۵۵۰
تانزانت سیگموئید - لگاریتم سیگموئید	۴۰-۲۳-۱۰	۱۰	۱۴/۷۶	۵/۴۸۰۳	۰/۸۵۵۸
لگاریتم سیگموئید - تانزانت سیگموئید	۴۰-۲۳-۱۰	۱۱	۱۴/۷۶	۶/۹۰۵۵	۰/۸۱۸۳
لگاریتم سیگموئید - خطی	۴۰-۸-۱۰	۲۲	۱۴/۲۸	۶/۷۵۴۷	۰/۸۲۲۳
تانزانت سیگموئید - خطی	۴۰-۱۱-۱۰	۲۱	۱۳/۳۳	۵/۴۶۰۴	۰/۸۵۶۳

ارزیابی شبکه با دو لایه پنهان در تعیین دقت طبقه بندی ارقام سیب‌زمینی با استفاده از ویژگی‌های رنگی با توجه به نتایج جدول (۴) تابع انتقال با لایه خروجی سیگموئید و تابع انتقال با لایه پنهان سیگموئید به عنوان شبکه بهینه انتخاب شد. پس از ارزیابی شبکه با تعداد سلول‌های




شکل ۵- نمای شبکه دو لایه برای شناسایی ارقام با استفاده از ویژگی‌های ریخت‌شناسی


احتمالاً دلیل خطاهای زیاد را می‌توان به مشابه بودن ویژگی‌های استخراج شده بافتی اشاره نمود، که برای رفع این مشکل می‌توان از حذف ویژگی‌های مشابه و بالا بردن تعداد ویژگی‌های دیگر با استفاده از ماتریس‌های مختلف دیگر برای استخراج ویژگی‌های متفاوت استفاده کرد.

ارزیابی شبکه با دو لایه پنهان در تعیین دقت طبقه‌بندی ارقام سیب‌زمینی با استفاده از ویژگی‌های بافتی سطح خاکستری آبی

پس از ارزیابی شبکه با تعداد سلول‌های عصبی مختلف در دو لایه پنهان، بیش‌ترین دقت طبقه‌بندی مربوط به شبکه‌ای با تعداد سلول عصبی به ترتیب ۲۰ و ۲۱ در این دو لایه مشاهده شد. میانگین دقت شناسایی ارقام سیب‌زمینی ۲۸/۰۹ درصد با ضریب تعیین ۰/۸۷۰۴، خطای میانگین مربعات ۴/۹۲۶۰ با تعداد چرخه آموزش ۱۵ برای این شبکه بهینه به دست آمد. این روش نسبت به ارزیابی شبکه با یک لایه پنهان برای شناسایی ارقام، درصد دقت نسبتاً بالاتری ارائه داد. بنابراین شبکه با دو لایه پنهان برای ویژگی‌های بافتی نسبت به شبکه با یک لایه پنهان به منظور تشخیص ارقام سیب‌زمینی بهتر تشخیص داده شد.



شکل ۶- نمودار مقایسه داده‌های پیش‌بینی شبکه دو لایه و واقعی برای ویژگی‌های بافتی سطح خاکستری سبز



شکل ۷- نمودار مقایسه داده‌های پیش‌بینی شبکه دو لایه و واقعی برای ویژگی‌های بافتی سطح خاکستری آبی

عصبی مختلف در دو لایه پنهان، بیش‌ترین دقت طبقه‌بندی مربوط به شبکه‌ای با تعداد سلول عصبی به ترتیب ۱۰ و ۱۱ در این دو لایه مشاهده شد. میانگین دقت شناسایی ارقام سیب‌زمینی ۳۹/۰۴ درصد با ضریب تعیین ۰/۹۲۶۴ و میانگین خطای مربعات ۲/۸۶۵۶ با تعداد چرخه آموزش ۱۷ برای این شبکه بهینه به دست آمد.

این روش نسبت به ارزیابی شبکه با یک لایه پنهان برای شناسایی ارقام، درصد دقت نسبتاً بالاتری ارائه داد. بنابراین شبکه با دو لایه پنهان برای ویژگی‌های رنگی نسبت به شبکه یک لایه به منظور تشخیص ارقام سیب‌زمینی بهتر تشخیص داده شد.

ارزیابی شبکه با دو لایه پنهان در تعیین دقت طبقه‌بندی ارقام سیب‌زمینی با استفاده از ویژگی‌های بافتی

با توجه به نتایج به دست آمده از جدول‌های (۶) و (۷) به علت نزدیک بودن میانگین دقت طبقه‌بندی براساس مؤلفه‌های رنگی و همچنین متفاوت بودن نوع ساختار دو مؤلفه رنگی سبز و آبی به عنوان شبکه بهینه انتخاب شدند تا مشخص شود کدام مؤلفه رنگی بیش‌ترین میانگین دقت طبقه‌بندی را دارا است، که در ادامه به توضیحاتی در این مورد پرداخته می‌شود.

ارزیابی شبکه با دو لایه پنهان در تعیین دقت طبقه‌بندی ارقام سیب‌زمینی با استفاده از ویژگی‌های بافتی سطح خاکستری سبز

پس از ارزیابی شبکه با تعداد سلول‌های عصبی مختلف در دو لایه پنهان، بیش‌ترین دقت طبقه‌بندی مربوط به شبکه‌ای با تعداد سلول عصبی به ترتیب ۱۶ و ۱۷ در این دو لایه مشاهده شد. میانگین دقت شناسایی ارقام سیب‌زمینی ۲۸/۵۷ درصد با ضریب تعیین ۰/۸۸۳۱، میانگین خطای مربعات ۴/۵۲۱۳ با تعداد چرخه آموزش ۱۲ برای این شبکه بهینه به دست آمد. این روش نسبت به ارزیابی شبکه با یک لایه پنهان برای شناسایی ارقام، درصد دقت نسبتاً بالاتری ارائه داد. بنابراین شبکه با دو لایه پنهان برای ویژگی‌های بافتی به منظور تشخیص ارقام سیب‌زمینی بهتر تشخیص داده شد.

در شکل ۶ نمودار داده‌های خروجی واقعی و پیش‌بینی خروجی‌های شبکه عصبی براساس بهترین شبکه انتخاب شده‌ی خطی- تانژانت سیگموئید نمایش داده شده است. با توجه به این نمودار، خطای تشخیص شبکه در پیش‌بینی رقم‌ها، در رقم پنجم کمترین خطا نسبت به ارقام دیگر و بیش‌ترین خطا در رقم‌های اول، دوم و هشتم را نشان می‌دهد.

در مقایسه با شبکه تک لایه برای ویژگی بافتی در مؤلفه سبز، در تشخیص ارقام سیب‌زمینی بهترین عملکرد را داشت. با توجه به نتایج و محدودیت‌ها، پیشنهاد می‌شود در تحقیقات آتی موارد زیر پیگیری شود:

- بهره‌گیری از مدل‌های یادگیری عمیق (مانند شبکه‌های کانولوشنی CNN) برای استخراج خودکار و سلسله‌مراتبی ویژگی‌ها بدون نیاز به مهندسی دستی ویژگی؛
- بکارگیری الگوریتم‌های انتخاب و کاهش ابعاد ویژگی (مانند ReliefF، Genetic Algorithm یا Boruta) جهت حذف ویژگی‌های تکراری و غیرمؤثر؛
- افزایش تنوع ارقام (بیش از ۱۰ رقم) و حجم نمونه‌ها، و همچنین جمع‌آوری داده از مناطق و فصل‌های مختلف کشت برای بهبود تعمیم‌پذیری؛

به طور کلی، رویکرد پیشنهادی (پردازش تصویر + شبکه عصبی) به ویژه با تکیه بر ویژگی‌های ریخت‌شناسی، پتانسیل بالایی برای خودکارسازی تشخیص ارقام سیب‌زمینی در صنایع غذایی، کنترل کیفیت و تجارت دارد و می‌تواند به عنوان پایه‌ای برای سیستم‌های هوشمند کشاورزی دقیق (precision agriculture) مورد استفاده قرار گیرد.

مشارکت نویسندگان

نحوه و میزان مشارکت نویسندگان در انجام این پژوهش به صورت زیر است:

- نویسنده اول: دانش‌آموخته کارشناسی ارشد
- نویسنده دوم: استاد راهنما
- نویسنده سوم: استاد راهنما

دسترسی به داده‌ها

همه اطلاعات و نتایج در متن مقاله گزارش شده است (به صورت جدول و شکل).

اصول اخلاقی

نویسندگان اصول اخلاقی را در انجام و انتشار این اثر علمی رعایت نموده‌اند و این موضوع مورد تأیید همه آن‌ها است.

تضاد منافع نویسندگان

نویسندگان اعلام می‌کنند که هیچ گونه منافع مالی رقابتی یا روابط شخصی شناخته‌شده‌ای که ممکن است بر کار گزارش‌شده در این مقاله تأثیر گذاشته باشد، ندارند.

در شکل ۷ نمودار داده‌های خروجی واقعی و پیش‌بینی خروجی‌های شبکه عصبی براساس بهترین شبکه انتخاب شده‌ی تانژانت سیگموئید-تانژانت سیگموئید نمایش داده شده است. با توجه به این نمودار خطای تشخیص شبکه در پیش‌بینی رقم‌ها، در رقم چهارم کم‌ترین خطا و بیش‌ترین خطا در رقم‌های دهم، اول، دوم، سوم و هشتم است. احتمالاً دلیل خطاهای زیاد را می‌توان به مشابه بودن ویژگی‌های استخراج شده بافتی اشاره نمود، که برای رفع این مشکل می‌توان از حذف ویژگی‌های مشابه و بالا بردن تعداد ویژگی‌های دیگر با استفاده از ماتریس‌های مختلف، برای استخراج ویژگی‌های متفاوت استفاده کرد.

نتیجه‌گیری

در این پژوهش، امکان‌سنجی طبقه‌بندی غیرمخرب ده رقم رایج سیب‌زمینی ایرانی (آگریا، مارفونا، گرانولا، آرندا، سانتا، میلوا، جلی، راموس، اسپریت و بامبا) با استفاده از پردازش تصویر و شبکه‌های عصبی مصنوعی (تک‌لایه و دولایه) بررسی شد. نتایج نشان داد که ویژگی‌های ریخت‌شناسی با فاصله قابل‌توجهی نسبت به دو دسته دیگر، بهترین عملکرد را ارائه دادند. در شبکه تک‌لایه، دقت میانگین طبقه‌بندی با ویژگی‌های ریخت‌شناسی به $88\%/0.9$ رسید (بهترین معماری: $10-16-17$ با توابع لگاریتم سیگموئید-خطی، $MSE=0.1359$ و $R^2=0.9965$)، در حالی که ویژگی‌های رنگی حداکثر دقت 27.61% و ویژگی‌های بافتی (بهترین کانال: سبز با $24\%/0.28$) عملکرد بسیار ضعیفی نشان دادند. حتی در شبکه دولایه که برای ویژگی‌های رنگی و بافتی بهبود نسبی ایجاد کرد (به ترتیب 39.04% و $28\%/0.57$ برای بهترین حالت‌ها)، همچنان ویژگی‌های ریخت‌شناسی برتر بودند ($86\%/0.19$).

این یافته تأیید می‌کند که ویژگی‌های شکل و اندازه (ریخت‌شناسی) به دلیل پایداری ژنتیکی بالاتر و تأثیرپذیری کمتر از شرایط محیطی و پس از برداشت، عامل‌های مؤثرتر و متمایزتری برای تشخیص ارقام سیب‌زمینی هستند. در مقابل، ویژگی‌های رنگی و بافتی به دلیل شباهت‌های درون‌رقمی بالا، تغییرات ناشی از عوامل محیطی، نور، خاک و ذخیره‌سازی، قدرت تمایز کافی نداشته و در این مطالعه عملکرد قابل قبولی ارائه نکردند. شبکه دو لایه در مقایسه با شبکه تک لایه برای ویژگی رنگی در تشخیص ارقام سیب‌زمینی بهترین عملکرد را داشت. بهترین سطح خاکستری ویژگی بافتی در تشخیص ارقام مختلف سطح خاکستری سبز تعیین شد. شبکه دو لایه

- University Raleigh, North Carolina, CRC Press. 1035 pp. ISBN: 978-1-4987-4028-9 (eBook).
- Sajikumar, N., Thandavewra, B.S. 1999. A non-linear rainfall-run off model using an artificial neural network. *Journal of Hydrology*. 216(1): 32-55. [https://doi.org/10.1016/S0022-1694\(98\)00273-X](https://doi.org/10.1016/S0022-1694(98)00273-X)
- Shabani, M., 2011. Modeling the monthly inflow to Minab Dam using artificial neural network, M.Sc. Thesis. Bu-Ali Sina University. (In Persian)
- Shantaiya, S. and Ansari, U. 2012. Identification of Food grains and its quality using pattern classification. *International Journal of Computer and Communication Technology*. 3(1): 14-19. <https://doi.org/10.47893/IJCCT.2012.1107>.
- Shouche, S.P., Rastogi, R., Bhagwat, S.G., Sainis, J.K., 2001. Shape analysis of grains of Indian wheat varieties. *Computers and Electronics in Agriculture*. 33(1): 55-76. [https://doi.org/10.1016/S0168-1699\(01\)00174-0](https://doi.org/10.1016/S0168-1699(01)00174-0)
- Solomon, C. and Breckon, T., 2011. Fundamentals of Digital Image Processing. WileyBlackwell, 328 pp., West Sussex, UK.
- Unal, B., Mamak, M., Seckin, G., Cobaner, M. 2010. Comparison of an ANN approach with 1-D and 2-D methods for estimating discharge capacity of straight compound channels. *Advances in Engineering Software*. 41(2): 120-129. <https://doi.org/10.1016/j.advengsoft.2009.10.002>
- حمایت مالی
- نویسنده(ها) هیچ حمایت مالی خاصی برای انجام این پژوهش دریافت نکرده‌اند.
- منابع
- Akhavan, S., Mostafazadeh fard, B., Mousavi, S. F., Ghadami Firoozabadi, A. and Bahrmi, B. 2005. The effect of amount and method of irrigation on yield, yield components and quality of Agria cultivar. *Journal of Agric. Biotechnol.* 5(2): 27-40. [magiran.com/p842603 -last Accessed: 2026/01/05]. (In Persian).
- Amiri Parian, J. 2007. Grading of agricultural products based on volume or density using machine vision. Ph.D. Thesis, Tarbiat Modares University, Tehran, Iran. (In Persian).
- Anonymous, 2026. [<https://amarfact.com/statistics/> - Last Accessed: 2026/05/25]. (In Persian).
- Dawson, C.W. and Wilby, R. 1998. An artificial neural network approach to rainfall-runoff modeling. *HYDROLOG. SCI. J.* 43(1): 47-66. <https://doi.org/10.1080/02626669809492102>
- Golpour, I., Amiri Parian, J., Amiri Chayjan, R. 2012. Recognition of Iranian cultivars based on the analysis of color components of digital images. *7th National Congress of Agricultural Machinery and Mechanization Engineering*, Shiraz University, Shiraz, Iran. (In Persian)
- Golpour, I., Amiri Parian, J., Amiri Chayjan, R. 2014. Identification and Classification of Bulk Paddy, Brown, and White Rice Cultivars with Colour Features Extraction using Image Analysis and Neural Network. *Czech J. Food Sci.* 32(3): 280-287. <https://doi.org/10.17221/238/2013-CJFS>
- Gonzalez, R.C., Woods, R.E. 2018. Digital Image Processing. 4th ed. Pearson, 1306 pp., New York, USA.
- Homaei, M., Dirksen, C. and Feddes, R.A. 2002. Simulation of root water uptake in non-uniform transient salinity using different macroscopic reduction function, *Agricultural Water Management*. 57(2): 89-109. [https://doi.org/10.1016/S0378-3774\(02\)00072-0](https://doi.org/10.1016/S0378-3774(02)00072-0)
- Hoseinzadeh- Talaei, P. 2010. Modeling of flow-scale curve of rock fragments using artificial neural network. M.Sc. Thesis. Bu-Ali Sina University. (In Persian)
- Hristev, R.M., 1998. The Ann Book. GNU Public License, 392 pp. Available on (http://www.pdg.cnb.uam.es/cursos/Complutense/Complutense2004/pages/12_NeuralNetworks/Hristev_The_ANN_Book.pdf).
- Majumdar, S., Jayas, D.S. 1999. Classification of Bulk Samples of Cereal Grains using Machine Vision, *Journal of Agricultural Engineering Research*. 73(1): 35-47. <https://doi.org/10.1006/jaer.1998.0388>
- Russ, J.C. and Neal, F. B. 2016. The Image Processing Handbook. (7th edition). North Carolina State

