



## کارایی شبکه‌های عصبی مصنوعی در پیش‌بینی عملکرد یونجه

نفیسه یغمائیان مهابادی  
استادیار گروه علوم خاک دانشکده علوم کشاورزی دانشگاه گیلان

### چکیده

افزایش روزافزون تقاضای محصولات کشاورزی و افزایش فشار بر منابع آب و خاک از یک سو و مشکلات دستیابی به داده‌های میدانی از سوی دیگر، ضرورت استفاده از مدل‌های مناسب برای پیش‌بینی عملکرد محصولات زراعی را نمایان می‌سازد. در این پژوهش عملکرد محصول یونجه در منطقه ورامین استان تهران، توسط شبکه‌های عصبی مصنوعی پیش‌بینی شد. ورودی‌های شبکه‌های عصبی، خصوصیات اراضی شامل: درصد کربنات کلسیم معادل، درصد حجمی سنگریزه، درصد گچ، هدایت الکتریکی (EC)، نسبت جذب سدیم (SAR)، pH، درصد رس، سیلت و شن خاک و خروجی آنها میزان پتانسیل عملکرد محصول بر حسب کیلوگرم در هکتار می‌باشد. از شبکه عصبی پرسپترون چند لایه با الگوریتم آموزش پس انتشار برای پیش‌بینی پتانسیل عملکرد استفاده شد. معیارهای میانگین خطای مطلق (MAE)، ریشه میانگین مربعات خطا (RMSE) و ضریب تبیین ( $R^2$ )، جهت ارزیابی کارایی شبکه‌های استفاده شده به کارگرفته شدند. نتایج به دست آمده نشان داد که شبکه عصبی با ساختار ۱-۵-۲-۹ دارای کمترین مقدار RMSE برابر با ۲۶/۰ و بیشترین  $R^2$  برابر با ۹۷/۰ در میان ساختارهای مختلف شبکه عصبی به کارگرفته شده می‌باشد. این نتایج نشان دهنده توانایی بالای شبکه عصبی آموزش دیده در پیش‌بینی عملکرد محصول یونجه است.

واژه‌های کلیدی: شبکه عصبی پرسپترون چند لایه، خصوصیات اراضی، پتانسیل عملکرد

### مقدمه

پیش‌بینی عملکرد گیاهان زراعی از اهمیت خاصی برخوردار می‌باشد. برای پیش‌بینی موثر عملکرد این محصولات، ابتدا باید عوامل تعیین‌کننده یا محدودکننده عملکرد را شناخت. تولیدات کشاورزی همیشه با محدودیت شرایط اقلیمی، خاکی و تغییرات بازارهای بین‌المللی همراه بوده است. اگرچه این احتمال خطر، هرگز به طور کامل حذف نمی‌شود، اما می‌توان با شناخت پارامترهای مختلف مؤثر در رشد گیاه و تخمین میزان محصول قبل از فصل برداشت، آنها را به حداقل رساند. (Qian, et al., ۲۰۰۹)

عملکرد گیاه تابعی از عوامل مختلف گیاهی، اقلیمی و شرایط مدیریتی آب و خاک است. از اینرو محاسبه مقدار عملکرد گیاه و شاخص‌های وابسته به آن از روابط غیرخطی پیچیده‌ای تبعیت می‌کند که مدل‌سازی آن نیز دشواری خاصی دارد. با توجه به اهمیت مدل‌سازی عملکرد و تعیین عوامل مؤثر بر رشد، امروزه مدل‌های شبیه‌سازی گیاهی به عنوان ابزاری چندمنظوره در تحقیقات و مدیریت زراعی مطرح هستند. انواع مختلفی از مدل‌های پیش‌بینی عملکرد وجود دارد. یکی از روش‌های مدل‌سازی که در سال‌های اخیر مورد توجه بسیاری از محققین در علوم مختلف واقع شده است، مدل‌سازی به روش شبکه عصبی مصنوعی (Artificial Neural Network; ANN) می‌باشد.

شبکه عصبی، شبیه‌سازی از دستگاه عصبی انسان است و در واقع تقلیدی از مغز و شبکه اعصاب انسان می‌باشد. در این شبکه سعی بر این است که ساختاری تهیه شود که همانند مغز، قدرت یادگیری، تعمیم‌دهی و تصمیم‌گیری داشته باشد (Rao and Rao, ۱۹۹۶). در این گونه ساختارها هدف این است که با معرفی عملکرد یک سیستم دینامیکی، مدل را آموزش داده، چگونگی عملکرد سیستم را در حافظه مدل ذخیره و از آن برای مواردی که قبلاً با آن مواجه نشده است، استفاده شود. به دلیل توانایی این شبکه‌ها در مدل‌سازی فرآیندهای بسیار پیچیده که تعداد عوامل تأثیرگذار در آنها زیاد است، امکان استفاده از آنها در علوم کشاورزی بسیار فراهم می‌باشد. شبکه‌های عصبی مصنوعی شامل مجموعه‌ای از نرون‌های به هم متصل می‌باشند که به هر مجموعه از این نرون‌ها یک لایه گفته می‌شود. در نهایت برای ایجاد این لایه‌ها، نرون‌ها به وسیله توابع فعال‌سازی (محرک) به یکدیگر متصل می‌شوند. یک شبکه عصبی به طور معمول، از سه لایه ورودی، پنهان و خروجی تشکیل شده است. لایه ورودی، فقط اطلاعات را دریافت می‌کند و تعداد نرون‌های آن بر اساس طبیعت مسئله تعیین می‌شود. لایه خروجی نیز همانند متغیر وابسته عمل کرده و تعداد نرون‌های آن به تعداد متغیر وابسته بستگی دارد؛ اما بر خلاف لایه ورودی و لایه خروجی، لایه پنهان هیچ مفهومی را نشان نمی‌دهد و صرفاً یک نتیجه میانی در روند محاسبه ارزش خروجی است (Gil et al., ۲۰۰۹). متداولترین شبکه در پیش‌بینی و حل مسائل غیرخطی، شبکه‌های چند لایه پرسپترون (Multi Layer Perceptron; MLP) می‌باشند که در این مطالعه از شبکه پرسپترون چند لایه با الگوریتم پس انتشار (Feed-Forward Backpropagation) و آموزش با ناظر استفاده گردید. آموزش نظارت‌شده به زوج‌هایی نیاز دارد که از بردار ورودی و بردار هدف (خروجی دلخواه) تشکیل شده باشند. یک بردار ورودی و خروجی دلخواه مربوط به آن، یک زوج آموزشی نامیده می‌شود. معمولاً یک شبکه با تعدادی از چنین زوج‌های آموزشی تربیت می‌گردد؛ به این صورت که با به کار بردن یک بردار ورودی، خروجی شبکه محاسبه و با بردار هدف خود مقایسه می‌شود و تفاوت بین خروجی محاسبه شده و خروجی دلخواه که خطا نامیده



می شود، به سمت عقب در سراسر شبکه منتشر می گردد و سپس وزن ها مطابق با الگوریتمی که تمایل به حداقل رساندن خطا را دارد، تغییر یافته و تنظیم می شوند (Haghan et al., ۱۹۹۵)

کول و همکاران (Kaul et al., ۲۰۰۵) از قابلیت شبکه های عصبی مصنوعی برای پیش بینی عملکرد ذرت و سویا در منطقه مریند استفاده نموده و بیان کردند که مدل شبکه عصبی مصنوعی در مقایسه با مدل های رگرسیونی دارای دقت بالاتری می باشد. آنها از پارامترهای میزان بارندگی و خصوصیات خاک به عنوان ورودی های مدل استفاده کردند و دریافتند که بارندگی در ماه های ژوئن تا اوت دارای اهمیت بیشتری می باشد و به همین دلیل بهتر است که آمار بارندگی در این ماه ها به صورت هفتگی به مدل معرفی گردد. دراموند و همکاران (Drummond et al., ۲۰۰۳) جهت تعیین روابط میان خصوصیات خاک، توپوگرافی و عملکرد غلات در منطقه میسوری آمریکا مطالعاتی را انجام دادند و مشاهده نمودند که روش شبکه های عصبی مصنوعی نسبت به روش های رگرسیونی دارای خطای کمتری می باشد. نوروزی و همکاران (Norouzi et al., ۲۰۱۰) از شبکه های عصبی مصنوعی به منظور پیش بینی عملکرد گندم در مناطق نیمه خشک و کوهستانی غرب ایران استفاده نمودند و بیان داشتند که شاخص انتقال رسوب، مهمترین عامل توپوگرافی بر میزان عملکرد این گیاه بوده است و میزان پروتئین موجود در دانه ها تحت تأثیر میزان نیتروژن کل خاک می باشد. باقری و همکاران (۱۳۹۱) به منظور پیش بینی عملکرد ذرت علوفه ای، از شبکه های عصبی مصنوعی بهره جستند و نشان دادند که زمانی که آب آبیاری، مقدار کود نیتروژنی و میزان درجه روز رشد به عنوان ورودی به مدل معرفی شوند، مدل می تواند عملکرد خشک گیاه را با دقت نسبتاً بالایی برآورد نماید.

در ایران شبکه های عصبی مصنوعی در موارد گوناگون از جمله برآورد خصوصیات فیزیکی و هیدرولیکی خاک مورد استفاده قرار گرفته است. اما مطالعات انجام گرفته در مورد برآورد پتانسیل محصول، بسیار اندک می باشد. از آنجایی که اعمال مدیریت صحیح بر مبنای داشتن اطلاعات دقیق از توان تولید اراضی منطقه می باشد؛ لذا یافتن روش های مناسب جهت شناخت و بررسی توان تولید اراضی با نگرش بازده بر حسب توانایی و استعداد کیفی و کمی اراضی از جایگاه و اهمیت ویژه ای برخوردار است. این پژوهش با هدف ارزیابی توانایی شبکه های عصبی مصنوعی به عنوان ابزاری جهت برآورد میزان پتانسیل عملکرد محصول یونجه صورت گرفت.

## مواد و روش ها

منطقه مورد مطالعه در شهرستان ورامین در محدوده عرض های جغرافیایی ۲۰ ۳۵ تا ۲۷ ۳۵ شمالی و طول های جغرافیایی ۳۸ ۵۴ تا ۴۱ ۵۴ شرقی واقع شده است. منطقه در ارتفاع ۹۷۲ متر از سطح دریا قرار گرفته است. متوسط درجه حرارت منطقه ۴/۱۷ درجه سانتی گراد و متوسط بارندگی منطقه ۱۷۰ میلی متر می باشد که اکثراً در فصول پاییز و زمستان رخ می دهد. سطح آب زیرزمینی، در عمق بیشتر از ۱۰ متری سطح خاک قرار دارد. رژیم حرارتی و رطوبتی منطقه به ترتیب گرم و اریدیک می باشد. اطلاعات هواشناسی از ایستگاه هواشناسی ورامین و اطلاعات خاک از ۵۰ پروفیل خاک حفر شده در منطقه بدست آمد. برای محاسبه پتانسیل تولید از مدل فائو استفاده گردید. در این مدل با استفاده از پتانسیل ژنتیکی محصول و ویژگی های گیاهی آن، با استفاده از داده های اقلیمی مانند تابش خورشید و درجه حرارت، مقدار کل تولید خالص زیست توده برآورد شد. در نهایت میزان پتانسیل تولید محصولات، با استفاده از شاخص اراضی محاسبه شده (روش ریشه دوم) و مقدار زیست توده محصول برداشت شده بدست آمد (Sys et al., ۱۹۹۱).

در این مطالعه ویژگی های خاک شامل: درصد کربنات کلسیم معادل، درصد حجمی سنگریزه، درصد گچ، درصد رس، سیلت و شن، EC، نسبت جذب سدیم (SAR) و pH به عنوان ورودی های شبکه در نظر گرفته شدند و خروجی شبکه، میزان پتانسیل عملکرد محصول را تعیین می کند. برای تعیین تعداد نرون های لایه میانی و همچنین تعداد لایه های میانی از روش آزمون و خطا استفاده شد. برای هر مرحله، رگرسیون خطی میان مقادیر اندازه گیری شده و برآورد شده اعمال گردید و ضریب تبیین ( $R^2$ ) هر مرحله نیز محاسبه شد که مقدار  $R^2$  بالا به معنای دست یافتن به آرائشی مناسبتر، جهت برآورد پارامتر خروجی می باشد. علاوه بر تعیین مقدار  $R^2$  از معیار ارزیابی ریشه میانگین مربعات خطا (RMSE) نیز استفاده شد. به این ترتیب پس از انجام آزمون و خطا بهترین ساختار شبکه جهت پیش بینی مقدار عملکرد محصول بدست آمد. شبکه مزبور در محیط نرم افزار ۱۰.۱ MATLAB اجرا شد. تابع غیر خطی سیگموئید (Sigmoid) به عنوان تابع محرک شبکه مورد استفاده قرار گرفت. در شبکه پیشنهادی، ۸۰ درصد داده ها در آموزش شبکه و ۲۰ درصد داده ها جهت آزمون در نظر گرفته شدند. از آنجاییکه خروجی این تابع اعدادی بین صفر و یک است و شکل داده های ورودی به آن نقش مهمی در یادگیری شبکه ایفا می کند. با لحاظ کردن این موضوع، نرمال سازی داده ها برای استفاده در شبکه با تابع فعالیت سیگموئیدی با استفاده از رابطه (۱) صورت گرفت.

$$x_n = 0.5 \left( \frac{x_0 - x_{ave}}{x_{max} - x_{min}} \right) + 0.5 \quad (1)$$

که در آن  $x_n$  داده نرمال شده،  $x_0$  داده ورودی،  $x_{ave}$  میانگین داده ها،  $x_{min}$  و  $x_{max}$  به ترتیب مقدار کمینه و بیشینه داده ها می باشد.



## چهاردهمین کنگره علوم خاک ایران - فیزیک خاک و رابطه آب، خاک و گیاه

برای تعیین صحت و اعتبار مدل‌ها از آماره‌های میانگین خطای مطلق (MAE)، ریشه میانگین مربعات خطا (RMSE) و ضریب تبیین ( $R^2$ ) بین مقادیر اندازه‌گیری شده و پیش‌بینی شده استفاده شد (روابط ۲، ۳ و ۴).

$$MAE = \frac{1}{N} \sum_{i=1}^N |O_i - t_i| \quad (2)$$

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

$$R^2 = 1 - \frac{\sum_{i=1}^N (O_i - t_i)^2}{\sum_{i=1}^N (O_i - \bar{O}_i)^2} \quad (4)$$

که در آن  $O_i$  مقدار اندازه‌گیری شده و  $t_i$  مقدار پیش‌بینی شده برای  $i$ امین خروجی می‌باشد.  $N$  تعداد کل رویدادهای مورد بررسی است.

### نتایج و بحث

در این پژوهش برای بدست آوردن بهترین ساختار شبکه، از دو ساختار تک لایه‌ای و دو لایه‌ای جهت انجام روند آموزش و آزمون شبکه استفاده گردید. در جدول ۱، تعداد لایه پنهان و تعداد نرون برای مدل‌های شبکه عصبی طراحی شده در این پژوهش آورده شده‌اند.

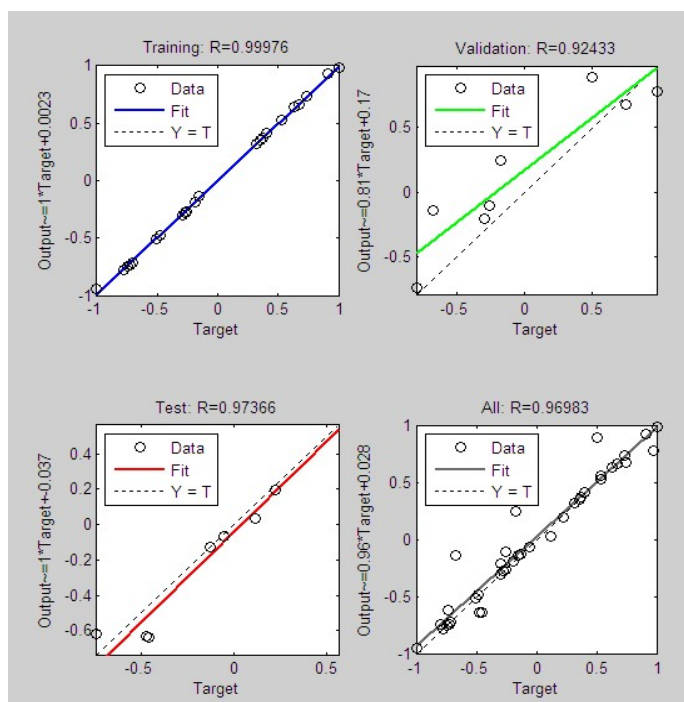
جدول ۱- مشخصات مدل‌های شبکه عصبی مصنوعی

ساختار شبکه عصبی	تعداد لایه پنهان، تعداد نرون	ساختار شبکه عصبی	تعداد لایه پنهان، تعداد نرون
۱	L1,N1	۱۱	L2,N1
۲	L1,N2	۱۲	L2,N2
۳	L1,N3	۱۳	L2,N3
۴	L1,N4	۱۴	L2,N4
۵	L1,N5	۱۵	L2,N5
۶	L1,N6	۱۶	L2,N6
۷	L1,N7	۱۷	L2,N7
۸	L1,N8	۱۸	L2,N8
۹	L1,N9	۱۹	L2,N9
۱۰	L1,N10	۲۰	L2,N10

L: تعداد لایه پنهان، N: تعداد نرون

نتایج ارزیابی شبکه‌های عصبی به کار رفته (جدول ۲) بر اساس سنج‌های آماری میانگین خطای مطلق (MAE)، ریشه میانگین مربعات خطا (RMSE) و ضریب تبیین ( $R^2$ ) بین مقادیر اندازه‌گیری شده و پیش‌بینی شده پتانسیل عملکرد محصول، نشان می‌دهد که با افزایش تعداد لایه‌های پنهان، میزان کارایی شبکه افزایش می‌یابد. نتایج تحقیقات آلوارز (Alvarez, ۲۰۰۹)، کول و همکاران (Kaul et al., ۲۰۰۵)، صفا و همکاران (Safa et al., ۲۰۰۳) و باقری و همکاران (۱۳۹۱) نیز تایید کننده این موضوع می‌باشد. اما با افزایش تعداد نرون روند مشخصی در میزان خطا مشاهده نمی‌شود. مدل ۱۵ با کمترین میزان خطا و بیشترین ضریب تبیین، به عنوان بهترین ساختار شبکه بدست آمد (جدول ۲). شکل ۳ مقدار همبستگی بین میزان واقعی پتانسیل تولید محصول یونجه و میزان محاسبه‌شده توسط شبکه عصبی مصنوعی برای مراحل آموزش و آزمون شبکه را نشان می‌دهد. نتایج پژوهش حاضر بیانگر کارایی بالای شبکه‌های عصبی مصنوعی جهت برآورد پتانسیل عملکرد محصول از طریق ویژگی‌های اراضی منطقه مورد مطالعه می‌باشد.

## چهاردهمین کنگره علوم خاک ایران - فیزیک خاک و رابطه آب، خاک و گیاه



شکل ۱- همبستگی بین میزان واقعی پتانسیل تولید محصول یونجه و میزان محاسبه شده توسط شبکه عصبی مصنوعی برای مراحل مختلف جدول ۲- ارزیابی مدل های شبکه عصبی مصنوعی

$R^2$	RMSE	MAE	ساختار شبکه عصبی	$R^2$	RMSE	MAE	ساختار شبکه عصبی
۹۲/۰	۳۲/۰	۲۲/۰	۱۱	۶۸/۰	۳۴/۰	۲۴/۰	۱
۷۹/۰	۳۳/۰	۲۴/۰	۱۲	۶۷/۰	۳۳/۰	۲۲/۰	۲
۹۳/۰	۳۱/۰	۲۳/۰	۱۳	۷۲/۰	۳۰/۰	۲۱/۰	۳
۹۶/۰	۳۰/۰	۲۳/۰	۱۴	۹۳/۰	۶۵/۰	۴۳/۰	۴
۹۷/۰	۲۶/۰	۱۹/۰	۱۵	۹۷/۰	۳۸/۰	۲۶/۰	۵
۸۹/۰	۳۰/۰	۲۱/۰	۱۶	۸۱/۰	۴۳/۰	۳۰/۰	۶
۹۱/۰	۳۳/۰	۲۴/۰	۱۷	۷۹/۰	۳۷/۰	۲۸/۰	۷
۹۵/۰	۲۸/۰	۲۰/۰	۱۸	۸۰/۰	۳۸/۰	۲۶/۰	۸
۹۰/۰	۳۰/۰	۲۰/۰	۱۹	۸۵/۰	۳۴/۰	۲۴/۰	۹
۹۶/۰	۳۱/۰	۲۲/۰	۲۰	۹۵/۰	۳۳/۰	۲۳/۰	۱۰



منابع

- باقری، س.، قیصری، م.، ایوبی، ش. و لوایی، ن. ۱۳۹۱. پیشبینی عملکرد ذرت علوفه‌ای با استفاده از شبکه‌های عصبی مصنوعی. مجله پژوهش‌های تولید گیاهی، جلد نوزدهم، شماره ۴، صفحه‌های ۷۷ تا ۹۶.
- Alvarez A. ۲۰۰۹. Predicting average regional yield and production of wheat in the Argentine Pampas by an artificial neural network approach. *European Journal of Agronomy*, ۳۰: ۷۰-۷۷.
- Drummond S. T., Sudduth K. A., Joshi A., Birrell S. J. and Kitchen N.R. ۲۰۰۳. Statistical and neural methods for site-specific yield prediction. *Transactions of the ASAE*, ۴۶: ۵-۱۴.
- Gil D., Johnsson M., Garcia Chamizo J. M., Paya A. S. and Fernandez D. R. ۲۰۰۹. Application of artificial neural networks in the diagnosis of urological dysfunctions. *Expert Systems with Applications*, ۳۶: ۵۷۵۴-۵۷۶۰.
- Hagan M. T., Demuth H. B. and Beale M. ۱۹۹۵. *Neural Network Design*. PWS Publishing Company. Boston.
- Kaul M., Hill R. L. and Walthall C. ۲۰۰۵. Artificial neural networks for corn and soybean yield prediction. *Agricultural Systems*, ۸۵: ۱-۱۸.
- Norouzi M., Ayoubi S., Jalalian A., Khademi H. and Dehghani A. A. ۲۰۱۰. Predicting rainfed wheat quality and quantity by artificial neural network using terrain and soil characteristics. *Acta Agriculturae Scandinavica*, ۶۰: ۳۴۱-۳۵۲.
- Qian B., Jong R.D., Warren R., Chipanshi A. and Hill H. ۲۰۰۹. Statistical spring wheat yield forecasting for the Canadian prairie provinces. *Agricultural and Forest Meteorology*, ۱۴۹: ۱۰۲۲-۱۰۳۱.
- Rao V. and Rao H. ۱۹۹۶. *C++ Neural networks and fuzzy logic* (۳<sup>rd</sup> ed.). MIS Press, New York.
- Safa B., Khalili A. Tashnehlab M. and Liaghat A. ۲۰۰۳. Predicting wheat yield using Artificial Neural Network. *Journal of Nivar*, ۱۲: ۴۷-۶۲.

**Abstract**

The increasing demands for agricultural products and pressure on the water and land resources also the problems to generate new data specify the necessity of using suitable models to predict the performance of agricultural products. In this research alfalfa yield was predicted using Artificial Neural Networks (ANN) in Varamin region of Tehran province. ANN inputs were land characteristics such as : percentage of calcium carbonate, gravel, gypsum, clay, silt and sand, Electrical Conductivity (EC), Sodium Absorption Ration (SAR) and pH. ANN output was potential production (kg/ha). Multi-Layer Perceptron networks (MLP) with backpropagation learning algorithm was used for crop yield prediction and Mean Absolute Error (MAE), Root Mean Square Error (RMSE) and Coefficient of Determination ( $R^2$ ) criterions were used to evaluate the performance of the ANN. The obtained results show that the ۹-۲-۵-۱ network has the lowest RMSE equal to ۰.۲۶ and maximum value of  $R^2$  equal to ۰.۹۷ and is suitable for predicting alfalfa yield.