



## پیش بینی الگوی توزیع جمعیت علف هرز جوموشی (*Hordeum glaucum steud.*) با استفاده از شبکه عصبی مصنوعی

حسن مکاریان<sup>۱\*</sup> - عباس روحانی<sup>۲</sup>

تاریخ دریافت: ۱۶/۳/۸۹

تاریخ پذیرش: ۱۱/۱۲/۸۹

### چکیده

امروزه تشریح الگوهای توزیع مکانی جمعیت علف های هرز با استفاده از روش های درونیابی و تخمین تراکم به منظور بررسی امکان کنترل متناسب با مکان آنها مورد توجه بسیاری از محققین قرار گرفته است. این پژوهش به منظور ارزیابی قابلیت مدل شبکه عصبی پرسپترون چندلایه ای (MLPNN) در درونیابی و تخمین جمعیت گیاهچه علف هرز جوموشی در نقاط نمونه برداری نشده و نیز ترسیم نقشه پراکنش آن انجام شد. داده های مربوط به تراکم جمعیت علف هرز جوموشی از طریق نمونه برداری از سطح یک مزرعه زعفران در خراسان جنوبی بدست آمد. برای ارزیابی قابلیت شبکه عصبی MLP در درونیابی تراکم علف هرز از مقایسه آماری پارامترهای مانند میانگین، واریانس، توزیع آماری و نیز ضریب تبیین معادله خطی رگرسیونی بین مقادیر پیش بینی شده توسط شبکه عصبی و مقادیر واقعی آنها استفاده شد. نتایج نشان داد که در فاز آموزش، آزمایش و کل، به ترتیب مقادیر  $p \geq 0.49$  ،  $p \geq 0.27$  و  $p \geq 0.18$  بدست آمد که نشان دهنده عدم وجود تفاوت معنی داری در سطح ۵ درصد بین مقادیر ویژگی های آماری ( میانگین، واریانس و توزیع آماری ) مجموعه داده های پیش بینی شده تراکم علف هرز و مقادیر واقعی آنها بود. به عبارتی شبکه عصبی مصنوعی به خوبی توانست مدل داده های تراکم علف هرز را بیاموزد. نتایج نشان داد که شبکه عصبی آموزش دیده، دارای قابلیت بالای در پیش بینی تراکم علف هرز در نقاط نمونه برداری نشده بود. شبکه عصبی توانست پس از درونیابی، نقشه توزیع و تراکم گیاهچه های علف هرز جوموشی را ترسیم نماید. نقشه حاصل از درونیابی نشان داد که علف هرز جوموشی دارای توزیع لکه ای است و لذا امکان کنترل متناسب با مکان آن در مزرعه مورد مطالعه وجود دارد.

**واژه های کلیدی:** توزیع مکانی، درونیابی، جوموشی، شبکه عصبی، علف هرز

و دقیق، عامل کلیدی در کاربرد موفق کشاورزی دقیق است. شناخت الگوهای پراکنش علف های هرز و کنترل متناسب با مکان آنها می تواند سبب کاهش هزینه ها و نیز کاهش ورود مواد شیمیایی به محیط زیست شده و از طرفی سبب کنترل بهتر جمعیت علف های هرز در لکه ها شود (۳۳). به همین خاطر امروزه تحقیقات زیادی در مورد تهیه و استفاده از نقشه های توزیع علف های هرز با استفاده از مدل سازی پویایی جمعیت علف های هرز به منظور بکارگیری در مدیریت متناسب با مکان در حال انجام است (۹). اما آنچه رسیدن به این اهداف را محقق می سازد افزایش صحت و دقت روش های درون یابی و تهیه نقشه های کاربردی از جمعیت علف های هرز است. درونیابی مکانی شامل تخمین متغیرهایی مانند تراکم گیاهچه علف هرز، بیomas و عملکرد گیاه زراعی و غیره در نقاط نمونه برداری نشده با استفاده از داده های بدست آمده از نقاط نمونه برداری شده می باشد. به عبارتی یک روش درونیابی ایده ال قادر است تا با

### مقدمه

ظهور علف های هرز در جامعه گیاهی عمدتاً بصورت موضعی و لکه ای است (۷ و ۱۲) که این امر به دلیل اثرات متقابل بیولوژی علف هرز، شرایط موضعی ریزانقلیم<sup>۳</sup> و عملیات مدیریتی می باشد (۴). جهت بررسی اثر هر نوع عملیات کشاورزی بر مدیریت علف های هرز شناخت تغییرات در توزیع، تراکم و ترکیب علف های هرز در مکان و زمان ضروری است (۳۲). کاربرد متناسب با مکان نهاده های کشاورزی (مانند کودها، علفکش ها و...) بر اساس نقشه های صحیح

۱- استادیار گروه زراعت و اصلاح نباتات، دانشکده کشاورزی، دانشگاه صنعتی شاهرود

(\*)-نویسنده مسئول: Email:h.makarian@yahoo.com

۲- استادیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود

3-Microclimate

شبکه عصبی شامل آموزش و آزمایش می‌باشد. آموزش، فرآیند یادگیری مجموعه داده‌های ورودی به منظور تشخیص الگوهای آن توسط شبکه می‌باشد زیرا شبکه MLP از نوع بامعلم است. روش آموزش را قانون یادگیری گویند و اتصالات وزنی بین نرون‌ها از طریق قانون یادگیری در طول فاز آموزش اصلاح می‌شوند. الگوریتم پس انتشار<sup>۵</sup> معمولترین روش آموزش شبکه با معلم می‌باشد ولی در این مطالعه از الگوریتم اصلی پس انتشار (۲۷)، استفاده شد. اساس این اصلاح شده الگوریتم کمینه کردن محاسبه انحراف خروجی شبکه از خروجی دو الگوریتم می‌باشد. آزمایش، ارزیابی قابلیت تعمیم پذیری و شایستگی واقعی می‌باشد. آزمایش، ارزیابی قابلیت تعمیم پذیری و شایستگی شبکه آموزش دیده در شرایط کاملاً جدید توسط مجموعه داده‌های غیر از داده‌های آموزش گویند (۱۴ و ۳۰). تاکنون شبکه‌های عصبی مصنوعی در تفکیک پوشش‌های گیاهی و نیز علف‌های هرز در روش‌های سنجش از دور مورد استفاده قرار گرفته است (۱۱، ۱۹ و ۲۵). گرچه با استفاده از این مدل‌ها توانسته اند روابط غیر خطی پیچیده و مرکب را با استفاده از تصاویر تهیه شده از کانوپی برای چند گیاه زراعی تشریح نمایند، اما این تکنیک در پیشگویی متغیرهای پیوسته ای مانند رطوبت خاک (۶)، ارزیابی کیفیت آب (۳۶)، تخمین بیوماس (۱۸) و تخمین عملکرد (۱۰) نیز پتانسیل بالای نشان داده است. مدل‌های شبکه عصبی دارای مزایایی از قبیل افزایش ظرفیت اطلاعات و توانایی بیان اثرات متقابل قوی بین متغیرهای ورودی می‌باشند. آیتکنهد و همکاران (۱)، با استفاده از مدل شبکه عصبی پرسپترون چند لایه برای تشخیص و تمایز بین گیاه زراعی هویج، علف هرز چشم و خاک مزرعه استفاده کردند. تمایز بین آفت‌گردن، توق و پس زمینه خاک نیز با استفاده از یک شبکه MLP توسط کودیر (۲۱) انجام شد. ارمک و همکاران (۱۶)، با استفاده از شبکه عصبی مصنوعی الگوهای مکانی عملکرد سویا را در سطح مزرعه پیش‌بینی کرده و نقش عوامل ایجاد کننده تغییرات مکانی عملکرد از جمله پستی و بلندی و حاصلخیزی خاک را نیز مورد بررسی قرار دادند. در حال حاضر، مطالعات متعددی به منظور درونیابی و تهیه نقشه‌های دقیق پوشش‌های گیاهی، تغییرات بیوماس و عملکرد و غیره با روش‌های مختلف درونیابی در حال انجام است و هدف اصلی در همه آنها تهیه نقشه‌های قابل اطمینان جهت مدیریت دقیق مزارع می‌باشد. بنابراین هدف ما نیز در این مطالعه، ارزیابی قابلیت شبکه عصبی MLP در پیش‌بینی تراکم علف هرز جوموشی (*Hordeum glaucum* steud.) در نقاط نمونه برداری نشده بر اساس داده‌های حاصل از نقاط نمونه برداری شده در یک مزرعه زعفران می‌باشد.

#### 5 - Back propagation

6- Back propagation with declining learning-rate factor (BDLRF)

استفاده از اطلاعات مربوط به تراکم علف‌های هرز در تعداد نقاط محدود نمونه برداری شده (دارای مشاهده)، تراکم علف‌های هرز را در نقاط نمونه برداری نشده به درستی تخمین بزند. دزیانت و کازانل (۸) از روش آنالیز روند سطحی<sup>۱</sup> که یک روش درونیابی است جهت توصیف پراکنش جوامع علف‌های هرز در یک مزرعه ذرت استفاده کردند. آنها با برآش یکتابع چندجمله ای، توزیع مکانی علف‌های هرز را نشان دادند. از دیگر روش‌های درونیابی مورد استفاده در مطالعات علم علف‌های هرز روش‌های مثلث بندی خطی<sup>۲</sup> و کریجینگ<sup>۳</sup> را می‌توان نام برد. در روش مثلث بندی خطی برای درونیابی، به مقادیر نزدیکترین سه نقطه نمونه برداری شده وزن یکسانی داده می‌شود (۱۷). کریجینگ نیز با استفاده از سمی واریوگرام‌ها با ترکیب وزن های داده شده به داده‌های نقاط مجاور، خطای مربوط به مقادیر پیش‌بینی شده را محاسبه می‌کند (۱۳). به هر حال یکی از نارسایی‌های روش‌های متدالول در آمار کلاسیک عدم توجه به سودمندی اطلاعات مربوط به موقعیت جغرافیابی مشاهدات بوده و متعاقب آن در تجزیه و تحلیل چنین داده‌هایی هیچگونه ارتباط ریاضی بین تغییرات مکانی نمونه‌ها بعنوان تابعی از فاصله بین آنها برقرار نمی‌شود (۲۲). بنابراین به نظر می‌رسد در آنالیز مکانی جوامع جهت فایق آمدن به این نارسایی‌ها می‌توان از روش‌های درونیابی با استفاده از مدل‌های شبکه عصبی پرسپترون چندلایه<sup>۴</sup> (MLPNN) بهره جست.

ساختر شبکه عصبی مصنوعی مشابه سیستم عصبی بیولوژی مغز انسان است (۲۶). امروز شبکه‌های عصبی در بسیاری از زمینه‌ها از جمله طبقه بندی، تشخیص الگو، پیش‌بینی و مدل‌سازی فرآیند‌ها بکار گرفته می‌شود. مزیت روش شبکه عصبی یادگیری مستقیم از روی داده‌ها، بدون نیاز به برآورد مشخصات آماری آنها است (۲۸). شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و همچنین داشت قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن رابطه بین مجموعه ای از ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه می‌باشد (۲۰ و ۲۶). شبکه عصبی قادر به تخمین هر تابع غیر خطی پیوسته می‌باشد (۱۵). ویژگی دیگر شبکه عصبی، تحمل پذیری در مقابل خطا می‌باشد (۳). این مزایا دلایل بکارگیری شبکه عصبی در پیش‌بینی تراکم علف‌های هرز را برای ما روشن می‌سازد. شبکه‌های عصبی شامل تعدادی نرون‌های متصل بهم هستند. در شبکه عصبی مصنوعی چندلایه پرسپترون، جریان داده‌ها بطور پیوسته از لایه ورودی به خروجی و بدون هیچگونه بازخوری جریان دارد. مراحل اصلی حل هر مسئله توسط

1- Trend surface

2- Linear triangulation

3- Kriging

4 - Multi layer perceptron neural network

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \times (r_{\max} - r_{\min}) + r_{\min} \quad (1)$$

در اینجا  $x$  داده خام اولیه،  $x_n$  داده نرمالیزه شده،  $x_{\max}$  به ترتیب مقادیر بیشینه و کمینه داده های اولیه و  $r_{\max}$  به ترتیب حد بالای و پایینی دامنه تغییرات داده های تبدیل شده است.

### شبکه عصبی پرسپترون چندلایه

بر اساس قضیه تقریب عمومی، شبکه عصبی با یک لایه مخفی و با تعداد کافی نرون در آن لایه قادر به تقریب هرتابع پیوسته دلخواه است (۲۰ و ۱۵)، بنابراین یک لایه مخفی برای شبکه عصبی انتخاب شد. ساختار شبکه MLP با یک لایه مخفی در شکل ۱ نشان داده شده است. شبکه MLP با دریافت بردار ورودی  $X^q$ ، بردار خروجی  $Z^q$  برای هر  $q = 1, \dots, Q$  تولید خواهد کرد. هدف اتخاذ پارامترهای صحیح شبکه، به منظور دستیابی به خروجی واقعی  $Z^q$  که تا حد ممکن نزدیک به خروجی مطلوب  $d^q$  متناظر با خود باشد. برای آموزش شبکه از الگوریتم پس انتشار با نرخ یادگیری کاهشی (BDLRF) استفاده شد. مزیت این الگوریتم در مقابل با الگوریتم پس انتشار اصلی (BB<sup>۳</sup>) (عنوان یک الگوریتم رایج در آموزش شبکه MLP دارای مزایایی از قبیل سهولت در تنظیم پارامترهای یادگیری شبکه به سبب پایین آوردن حساسیت شبکه به مقادیر آهنگ یادگیری و عامل ممتومن، کاهش زمان یادگیری از طریق پایین آوردن تعداد تکرارهای مورد نیاز برای یادگیری و بهبود رفتار شبکه در طول آموزش می باشد. کد کامپیوترا این الگوریتم در محیط برنامه نویسی نرم افزار MATLAB نسخه ۷ تهیه شد (۲).

### الگوریتم BDLRF

این الگوریتم نسخه اصلاح شده الگوریتم پس انتشار اصلی می باشد (۲۷). این الگوریتم آموزش با آهنگ یادگیری (۱) و عامل ممتومن (۰) ثابت و نسبتاً بزرگ شروع می کند و قبل از آنکه شبکه ناپایدار و یا همگرایی آن کند شود، هر  $T$  تکرار ( $3 \leq T \leq 5$ ) آهنگ یادگیری و فاکتور ممتومن را از طریق تصاعد حسابی بصورت یکنواخت کاهش داده تا زمانیکه این پارامترها به  $x$  درصد (۰/۵٪) مقادیر اولیه خودشان برسند.

- 2- Back-propagation with declining learning-rate factor  
3- Basic back-propagation

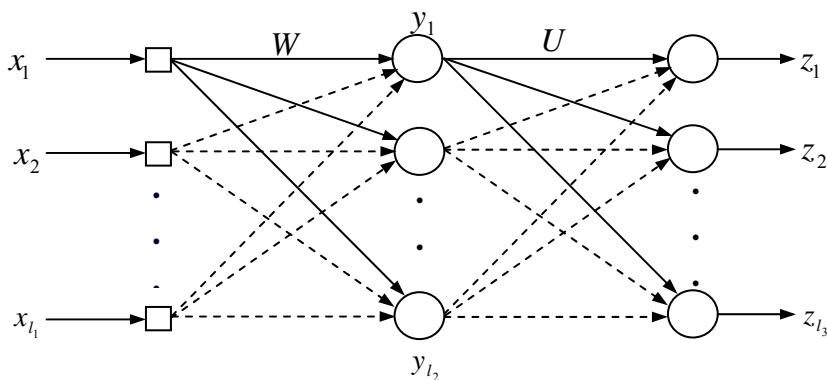
### مواد و روش ها

داده های مورد استفاده در این آزمایش در سال زراعی ۱۳۸۹ از یک مزرعه تجاری زعفران هشت ساله در منطقه بشرویه واقع در استان خراسان جنوبی جمع آوری گردید. طول و عرض جغرافیایی محل به ترتیب  $57^{\circ} 58' \text{ شمالی}$  و  $۵۸^{\circ} ۱۰' \text{ شرقی}$  و ارتفاع محل از سطح دریا  $۸۳۰$  متر می باشد. میانگین بارندگی سالیانه منطقه  $+48$  میلی متر، حداکثر و حداقل دمای مطلق سالانه به ترتیب  $-13$  و  $13$  درجه سانتیگراد می باشد. طبق آزمایش خاک انجام شده مزرعه دارای بافت خاک سنی لومی بوده و بنا بر توصیه کودی آزمایشگاه مقدار  $200$  کیلوگرم فسفات آمونیم در هکتار قبل از کاشت مورد استفاده قرار گرفته است. مزرعه انتخابی به ابعاد  $200 \times 200$  متر مربع بود. علف هرز جوموشی (باریک برگ یکساله زمستانه) یکی از مهمترین علف های هرز مزارع زعفران در استان های خراسان رضوی و جنوبی بشمار می رود (۲۶). نمونه برداری از جمعیت گیاهچه علف هرز زعفران در سطحی به ابعاد  $32 \times 32$  متر بر روی یک شبکه علامت گذاری شده مربعی <sup>۱</sup> به ابعاد  $4 \times 4$  متر انجام و در مجموع از  $144$  نقطه در مزرعه نمونه برداری انجام شد. نمونه برداری از جمعیت گیاهچه علف های هرز در اوایل دی ماه با استفاده از کوادراتی به ابعاد  $0/15 \times 0/15$  متر مربع ( $30 \times 30$  سانتی متر) در محل تقاطع خطوط شبکه مربعی انجام شد. بطوریکه در هر کوادرات جمعیت علف هرز جوموشی شناسایی و شمارش شد.

### پیش‌پردازش داده ها

در ابتدا بطور تصادفی داده های موجود به دو دسته مجموعه آموزش با  $10/8$  عضو (۷۵ درصد کل داده ها) و مجموعه آزمایش با  $36$  عضو (۲۵ درصد کل داده ها) تقسیم بندی شد. البته اگر این تقسیم بندی منجر به نتایج مطلوب نشود، می توان این مرحله را مجدد تکرار کرد (۳۵). قبیل از بکارگیری داده های خام اولیه در آموزش شبکه، باید داده ها در دامنه مناسبی نرمالیزه شود زیرا الگوریتم یادگیری همراه با داده های خام نمی تواند عملکرد مناسبی داشته باشد و همچنین بدلیل دامنه تغییرات خروجی تابع فعالیت سیگموئیدی (۱) بکارگرفته شده در لایه میانی، این امر ضروری به نظر می رسد. در غیر این صورت شبکه در طول فاز آموزش همگرا نخواهد شد و لذا نتایج مطلوب حاصل نخواهد شد (۳). زمانیکه از تابع فعالیت سیگموئیدی استفاده می شود، بهترین دامنه تبدیل داده ها خطی معادله (۱) استفاده شد:

- 1- Grid



شکل ۱- ساختار شبکه MLP با یک لایه مخفی

علف هرز<sup>۲</sup> و مختصات مکانی ( $X, Y$ ) در ابتدا نیاز به تعیین پارامترهای بهینه شبکه عصبی می باشد. در رابطه  $(X, Y) = f(Wd)$ ، تابع  $f$  شبکه عصبی MLP است.

## تنظیم‌ها، امتی‌های شدکه

لایه ورودی شامل ۳ نرون می باشد زیرا ورودی های شبکه شامل عامل بایاس و مختصات مکانی ( $X, Y$ ) علف هرز می باشند. لایه خروجی در شبکه تنها شامل یک نرون است که آن نشان دهنده تراکم علف هرز می باشد. تعیین توبولوژی بهینه، تعداد نرون ها در لایه مخفی شبکه از طریق آزمون سعی و خطای بدست آمد. اگر تعداد نرون ها در لایه مخفی کافی نباشد، شبکه قادر به یادگیری خوب نخواهد شد. ولی در تعداد بسیار زیاد آن مسئله بیش برآذشی وجود خواهد آمد که این منجر به تضعیف ویژگی تعمیم پذیری شبکه می شود (۳۱). در طول آزمون آهنگ یادگیری، عامل ممتد و تعداد تکرارها ( $Q = 10000$ ،  $\eta = 0.4$ ،  $a = 0.8$ ) ثابت نگه داشته شد. این فرآیند برای تعداد نرون های لایه مخفی ۷ تا ۲۰ انجام شد. نهایتاً بهترین نتیجه در ۱۷ نرون در لایه مخفی بدست آمد. بعد از این مرحله، باید مقادیر بهینه پارامتر یادگیری ( $\eta$ ) و عامل ممتد ( $a$ ) بدست آورد. برای دستیابی به عملکرد بهتر و تسريع در همگرایی شبکه از عامل ممتد استفاده شد (۱۴ و ۲۸). بدليل اثرات متقابل این دو پارامتر در عملکرد شبکه، پیدا کردن مقادیر بهینه آنها مشکل می باشد (۲۷). از آنجا که این دو پارامتر تنها در آموزش شبکه بکار می روند، از معیارهای عملکردی در طول فاز آموزش برای بهینه کردن آنها استفاده شد. مقادیر بهینه پارامترهای  $\eta$  و  $a$  نیز از طریق

تابع هزینه بکار رفته در این الگوریتم مجموع کل مربعات خطای (TSSE) می باشد و با استفاده از معادله ۳ محاسبه می شود:

$$TSSE = \sum_q \sum_k (d_k^q - z_k^q)^2 \quad , q=1,...,Q \quad (4)$$

مطلوب واقعی از  $q$  امين ورودی است. یادگیری شبکه در دو فاز پیش انتشار و پس انتشار اتفاق می‌افتد. وزن‌های هر لایه از شبکه از طریق معادله زیر (۴) محاسبه می‌شوند.

$$, \quad k=1,\dots,l_3, \quad j=1,\dots,l_2, \quad i=1,\dots,l_1$$

$$u_{jk}(n+1) = u_{jk}(n) - \eta \times \frac{\partial E}{\partial u_{jk}} + \alpha(u_{jk}(n) - u_{jk}(n-1)) \quad (3)$$

$$w_{ij}(n+1) = w_{ij}(n) - \eta \times \frac{\partial E}{\partial w_{ij}} + \alpha(w_{ij}(n) - w_{ij}(n-1)) \quad (\text{Eq. 4})$$

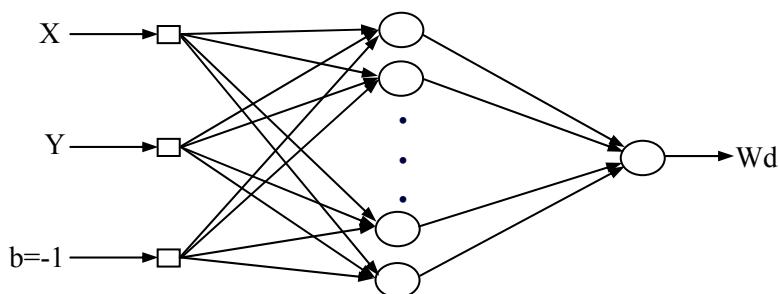
در اینجا  $w_{ij}$  اتصال وزنی بین گره های  $i$  و  $j$ ،  $u_{jk}$  اتصال وزنی بین گره های  $j$  و  $k$ ، مقادیر اولیه این وزن ها بطور تصادفی از دامنه مقادیر  $(0/25\text{--}25/0)$  انتخاب می شود.  $I_1$  و  $I_3$  به ترتیب تعداد نرون ها در لایه مخفی و لایه خروجی می باشند.  $\eta$  و  $a$  به ترتیب آهنگ یادگیری و فاکتور ممتومن هستند و مقادیر آنها در فاصله  $(1\text{--}10)$  قرار دارند و  $n$  شماره تکرار الگوریتم ( $N=1,\dots,n$ ) می باشد. زمانی الگوریتم متوقف می شود که TSSE کوچکتر از مقدار آستانه  $(1/000\text{--}0/000)$  مقدار آستانه در نظر گرفته شده برای مطالعه حاضر) باشد. جزئیات بیشتر این الگوریتم را می توان در مطالعات وکیل-آنونس (2002) بازدید کرد.

برای طراحی شبکه عصبی MLP جهت تعیین رابطه بین تراکم میسسه و پاوسیت (۱۱) مساهده نرد.

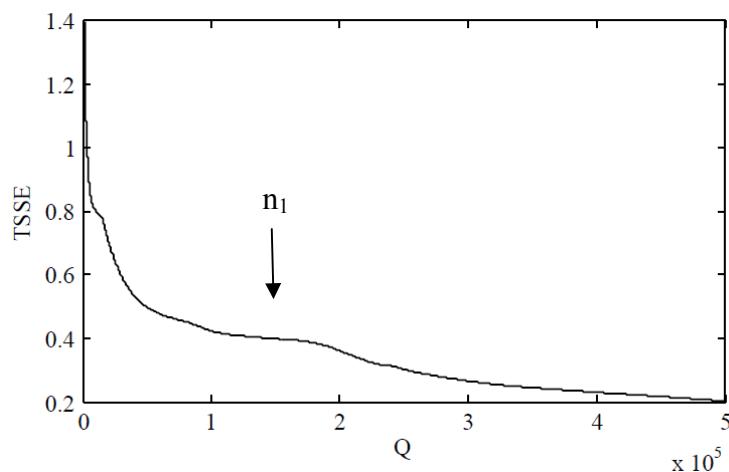
## نتایج و بحث

برخی ویژگی‌های آماری داده‌های استفاده شده در سه مرحله آموزش، آزمایش و کل، همراه با مقادیر پیش‌بینی شده آنها توسط شبکه عصبی با ساختار ۳-۱۷-۱ در جدول ۱ نشان داده شده است. تفاوت زیادی بین ویژگی‌های آماری مقادیر پیش‌بینی شده تراکم علف هرز جوموشی و مقادیر واقعی آنها ملاحظه نمی‌شود. تفاوت بین ویژگی آماری بین مقادیر واقعی و پیش‌بینی شده در فاز آزمایش به دلیل تازگی این داده‌ها برای شبکه عصبی بیشتر از فاز آموزش است. بر اساس این نتایج می‌توان ادعا کرد که شبکه عصبی با موفقیت آموزش دیده است. همچنان بدلیل نزدیک بودن مقادیر میانگین، مجموع و کشیدگی می‌توان نتیجه گرفت که داده‌های واقعی و پیش‌بینی شده مشابه هم هستند.

آزمون و خطای انتخاب شدند. عملکرد شبکه برای تمام ترکیبات مقادیر آهنگ یادگیری و عامل ممتد در بازه تغییراتی ( $0/0\text{--}0/90$ ) برای  $\eta$  و  $\alpha$  (۰/۰-۰/۹) برای  $\alpha$  با هم مقایسه شدند. نتایج نشان داد که بهترین عملکرد در سطح ثابت  $\alpha=0/30$  بدست می‌آید. بنابراین در طی آموزش شبکه، تنها پارامتر یادگیری از آهنگ کاهشی برخوردار شد. مقدار بهینه اولیه  $\eta=0/8$  برای شبکه بدست آمد. تعداد بهینه تکرارهای مورد نیاز شبکه برای یادگیری مجموعه داده‌های علف هرز جوموشی ۵۰۰۰۰ بدست آمد، همچنین نقطه بهینه شروع الگوریتم BDLRF در ۵۰۰۰ حاصل شد. مقدار نهایی  $\eta$  به  $0/04$  رسید. ساختار شبکه مورد استفاده برای پیش‌بینی علف هرز (Wd) بر اساس مختصات مکانی (X, Y) در شکل ۲ نشان داده شده است. نمودار همگرایی شبکه عصبی در طول مرحله آموزش در شکل ۳ نشان داده شده است. در شکل ۳ تا نقطه  $n_1$  شبکه بر اساس الگوریتم BB آموزش داده می‌شود و بعد از آن آموزش شبکه از طریق الگوریتم BDLRF انجام می‌شود.



شکل ۲- ساختار شبکه MLP استفاده شده برای پیش‌بینی تراکم علف هرز (Wd)



شکل ۳- نمودار همگرایی شبکه عصبی MLP در طی مدت مرحله آموزش  
توضیحات: Q تعداد تکرارهای الگوریتم، TSSE مجموع مربعات خطأ،  $n_1$  نقطه شروع الگوریتم BDLRF

جدول ۱- ویژگی های آماری مقادیر واقعی و پیش بینی شده تراکم گیاهچه علف هرز جوموشی

sum	ske	kur	max	min	std	var	av*	dv	pv	فاز آموزش
۱۱۶۷۹	۲/۹	۱۳/۵	۱۲۵۳	.	۱۹۷	۳۹۱۹۷	۱۰۸	dv		
۱۱۸۳۱	۲/۸	۱۳/۹	۱۲۰۵	.	۱۸۵	۳۴۳۳۲	۱۰۹	pv		
۵۲۰۱	۲/۶	۹/۸	۱۲۰۰	.	۲۷۱	۷۳۸۶۴	۱۴۴	dv		فاز آزمایش
۴۹۲۳	۲/۳	۸/۶	۱۰۶۸	.	۲۳۷	۵۶۵۹۸	۱۳۶	pv		
۱۶۸۸۰	۲/۹	۱۲/۸	۱۲۵۳	.	۲۱۸	۴۷۶۵۸	۱۱۷	dv		کل
۱۶۷۵۵	۲/۷	۱۲/۲	۱۲۰۵	.	۱۹۹	۳۹۶۸۲	۱۱۶	pv		

- توضیحات: av: میانگین، var: واریانس، std: انحراف معیار، min: کمینه، max: بیشینه، ske: چولگی، sum: مجموع، dv: مقادیر واقعی داده ها، pv: مقادیر پیش بینی شده توسط مدل MLP شبکه عصبی

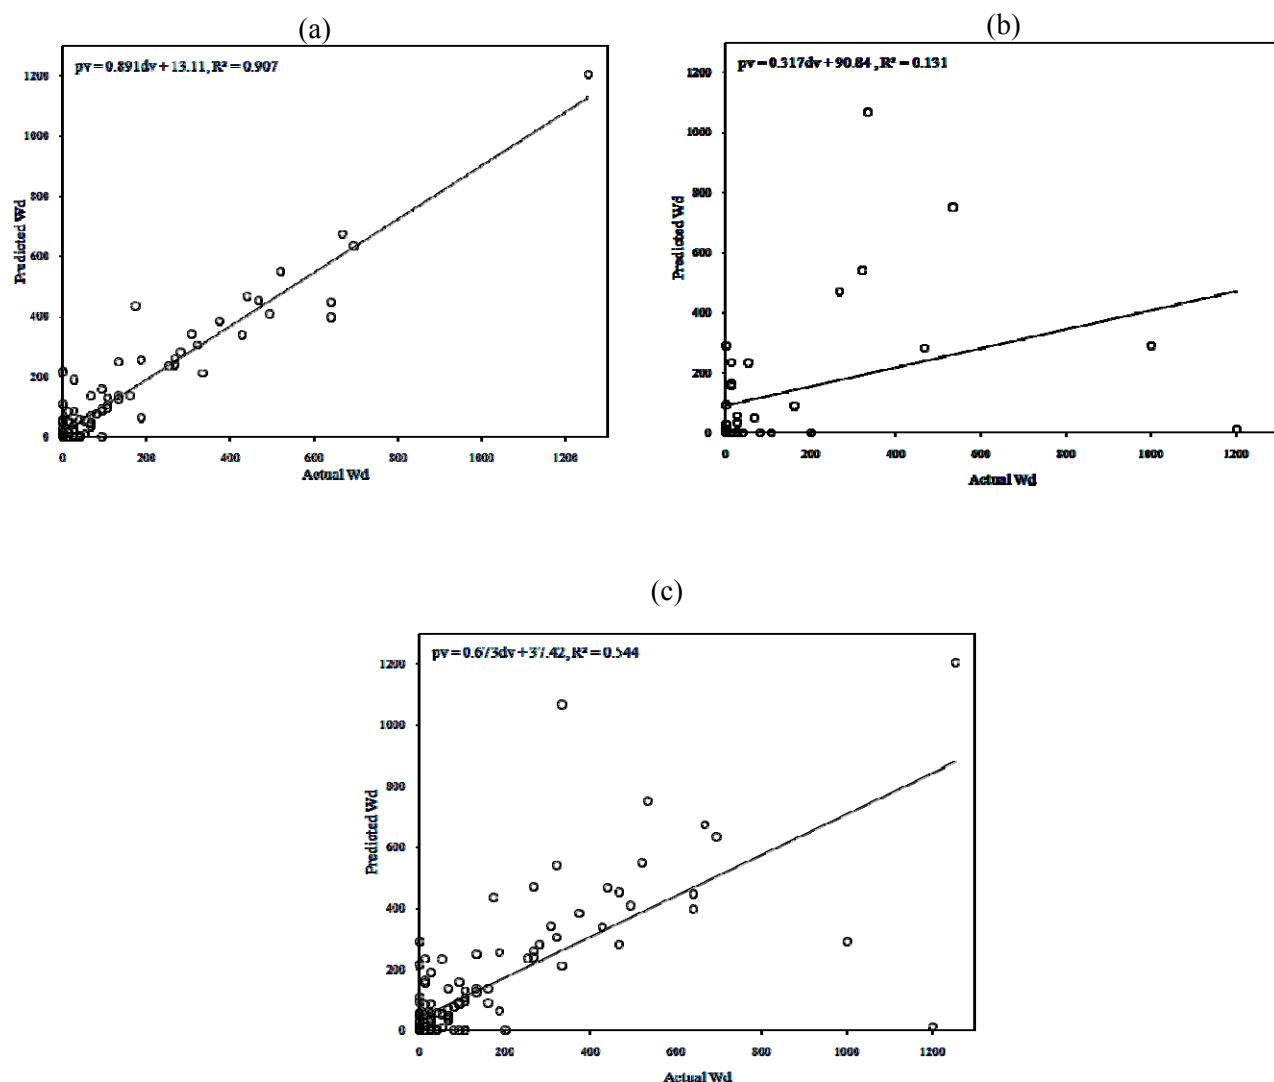
صنوعی رابطه بین فاکتورهای رقم، خاک و وضعیت زمین را با عملکرد مکانی ذرت و محتوای پروتئین دانه برسی کردند، با استفاده از این روش، آنها نشان دادند که رقم مهمترین فاکتور تاثیر گذار بر میزان پروتئین دانه بود.

ضرایب تبیین و رابطه خطی رگرسیونی و نیز نحوه پراکندگی بین تراکم های واقعی علف هرز در مقابل مقادیر پیش بینی شده آنها توسط شبکه عصبی در شکل ۴ نشان داده شده است. بهترین نتایج براساس معیار وقتی بدست می آید که معادله خطی مابین مقادیر واقعی و مقادیر پیش بینی شده توسط شبکه عصبی علاوه بر داشتن ضرایب تبیین بالا دارای کمترین عرض از مبدأ (نزدیک به صفر) و شبیه نزدیک به یک باشد. همانطور که ملاحظه می شود، بهترین نتیجه ( $R^2 = 90$ ) بر اساس نمودارهای پراکندگی برای فاز آموزش شبکه عصبی بدست آمده است (شکل ۴). دلیل پایین بودن ضرایب تبیین، بالا بودن عرض از مبدأ و نیز پایین بودن ضریب زاویه خط ماربر بین مقادیر واقعی و پیش بینی شده در فاز آزمایش به دلیل تازگی این داده ها برای شبکه عصبی است. اکسین و همکاران (۳۴) نیز نشان دادند که شبکه های عصبی مصنوعی نسبت به ضرایب همبستگی ساده یا ضرایب معادلات رگرسیون چند متغیره اطلاعات بسیار بیشتری را در مورد رابطه بین عوامل مربوط به خاک و وضعیت زمین با عملکرد و کیفیت دانه ذرت ارائه کردند.

برای اثبات ادعای ما درمورد قابل اطمینان بودن شبکه عصبی آموزش دیده در پیش بینی تراکم علف هرز، داده های واقعی و داده های پیش بینی شده توسط شبکه، از نظر آماری با هم مقایسه شد. در اینجا فرضیه صفر بر تساوی میانگین، واریانس و توزیع آماری هر دو سری داده دلالت دارد. هر فرضیه در سطح احتمال ۹۵ درصد به کمک پارامتر p آزمایش شد. اگر p محاسبه شده برای هر مقایسه بیشتر از  $0.05$  باشد، فرضیه صفر را نمی توان رد کرد. برای مقایسه میانگین، واریانس و توزیع آماری به ترتیب از آزمون های t و F کولموگرف- اسمیرنو استفاده شد. مقادیر p محاسبه شده برای هر سه مجموعه داده های آموزش، آزمایش و کل در جدول ۲ نشان داده شده است. بطوریکه در فاز آموزش، آزمایش و کل، به ترتیب مقادیر  $p \geq 0.049$ ،  $p \geq 0.022$  و  $p \geq 0.018$  بدست آمد. که نشان می دهد میانگین، واریانس و توزیع آماری مقادیر واقعی و پیش بینی شده سه مجموعه داده در سطح ۵ درصد اختلاف معنی داری با هم ندارند. بنابراین شبکه عصبی MLP آموزش دیده، دارای قابلیت بالایی برای پیش بینی تراکم علف هرز در نقاط نمونه برداری نشده است. دراموندا و همکاران (۱۰)، در ارزیابی روش های قابل اطمینان برای مطالعه ارتباط بین متغیر هایی مانند نوع خاک، پستی و بلندی زمین و عملکرد گیاه زراعی در طی چند سال و مکان مختلف، نشان دادند که مدل شبکه عصبی دارای حداقل خطای در پیش بینی مکانی متغیر های مذکور بود. اکسین و همکاران (۳۴)، با استفاده از شبکه عصبی

جدول ۲- مقادیر p حاصل از مقایسات آماری بین مقادیر واقعی و پیش بینی شده تراکم علف هرز جوموشی در فازهای آموزش، آزمایش و کل

نوع تحلیل آماری			مجموعه داده		
مقایسه میانگین	مقایسه واریانس	مقایسه توزیع	مقایسه داده	مقایسه میانگین	مقایسه واریانس
۰/۴۹۴	۰/۴۹۴	۰/۹۵۷	فاز آموزش		
۰/۱۸۰	۰/۴۳۵	۰/۸۹۹	فاز آزمایش		
۰/۳۱۸	۰/۲۷۵	۰/۹۷۲	کل		



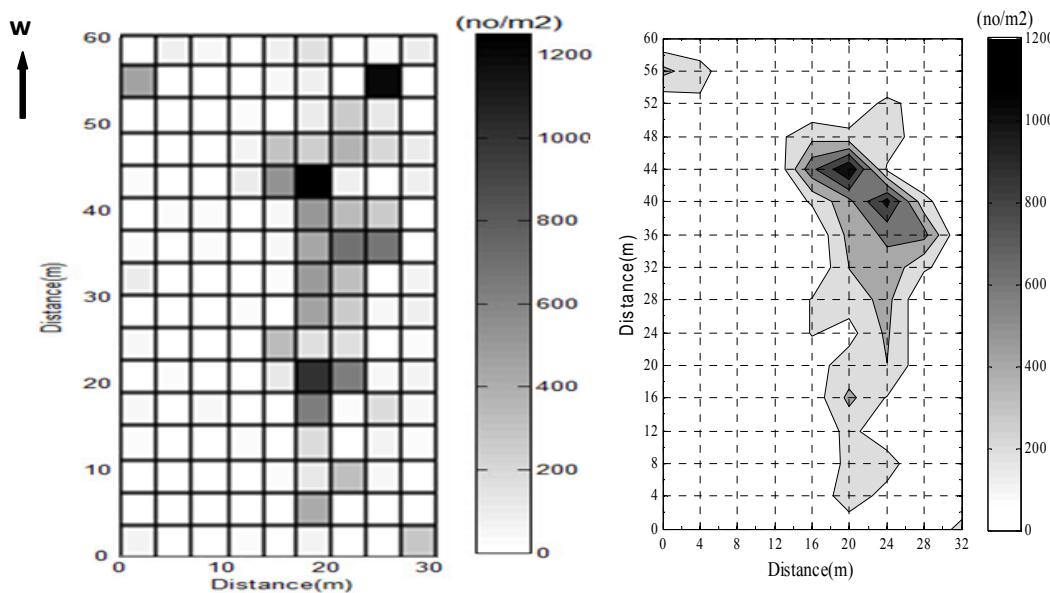
شکل ۴- نمودار پراکندگی مقادیر واقعی تراکم علف هرز (Predicted Weed density) در مقابل مقادیر پیش‌بینی شده (Actual Weed density)

(a) نمودار پراکندگی در فاز آزمایش شبکه عصبی، (b) نمودار پراکندگی در فاز آموزش شبکه عصبی، (c) نمودار پراکندگی برای تمام داده‌ها

شبکه عصبی MLP درونیابی و ترسیم شده در شکل ۵ نشان داده شده است. در این نقشه لکه‌هایی با اشکال و اندازه‌های مختلف به چشم می‌خورد. در این لکه‌ها با فاصله گرفتن از نقطه مرکزی لکه، تراکم علف هرز کاهش یافته و بتدریج به یک بخش حاشیه‌ای با تراکم کمتر و در مواردی به تراکم صفر می‌رسد. نقشه نشان می‌دهد که دامنه تغییرات تراکم در سطح مزرعه بالاست. توزیع ناهمگون و تجمعی علف هرز جوموشی در این شکل به خوبی مشهود است.

همین محققین بیان کردند که مدل شبکه عصبی مصنوعی ابزاری قوی در مطالعه اثر فاکتورهای تاثیرگذار بر الگوهای مکانی عملکرد گیاه زراعی می‌باشد. ارمک و همکاران (۱۶)، نشان دادند مدل شبکه عصبی با الگوریتم پس انتشار توانست تغییرات مکانی عملکرد سویا را با ریشه میانگین مربعات خطای پیش‌بینی شده ۱۴/۲ درصد پیش‌بینی کند.

**نقشه توزیع و تراکم علف هرز**  
نقشه توزیع و تراکم گیاهچه‌های علف هرز جوموشی که توسط



شکل ۵- نقشه توزیع و تراکم جمعیت گیاهچه علف هرز جوموشی در دو حالت بدون درونیابی (شکل سمت چپ) و درونیابی شده توسط مدل شبکه عصبی MLP (شکل سمت راست)

محیطی در سطح مزرعه جابجا می شوند (۲۴). بذور علف هرز دم جوموشی مکانیسم پراکنش مشخصی ندارد، بنابراین به نظر می رسد که عملیات آبیاری و سله شکنی که بلا فاصله قبل از شروع رشد زعفران در اوایل فصل رشد انجام می شود بذور را از اطراف گیاه مادری به فواصل دورتر منتقل کرده و لذا لکه های حاصل از جمعیت گیاهچه های این علف هرز دارای کشیدگی در راستای ردیف های گیاه زراعی و عملیات سله شکنی هستند (۲۲). بیولر (۵)، نیز بیان کرده است که دامنه طویل تر در جهت ردیف گیاه زراعی احتمالاً بدليل مدیریت گیاه زراعی، آب و باد می باشد. مکاریان (۲۳)، با استفاده از روش کریجینگ جمعیت علف های هرز را در نقاط نمونه برداری نشده درونیابی کرده و نشان داد که علف های هرز جو موشی و شاهی وحشی دارای آرایش لکه ای و علف هرز کاردوس دارای توزیع نسبتاً یکنواخت در سطح مزارع بودند. همین محقق بیان کرد که این الگوی جهت دار لکه های علف هرز در راستای حرکت ادوات کشاورزی و شیارهای آبیاری نشان دهنده این است که مدیریت مزرعه می تواند نقش قابل توجهی در توزیع علف های هرز داشته باشد. آرایش لکه ای علف هرز جوموشی در این مطالعه نشان داد که استراتژی های نمونه برداری مدل های اکلولوژیک که توزیع تصادفی علف های هرز را مبنای کار خود قرار داده اند قادر به توصیف صحیح این قبیل جوامع نمی باشند. این پژوهش نشان داد که شبکه عصبی مصنوعی توانست علاوه بر درونیابی، نقشه پراکنش جمعیت علف هرز جو موشی را به خوبی ترسیم نماید. نقشه حاصل از شبکه نیز نشان

وجود مرکز پر تراکم در لکه ها، بذوری را که منشاء گیاهچه ها در سال بعد می باشند را فراهم می کند و می تواند بیانگر نقاطی از مزرعه با تراکم بانک بذر بالا و یا شرایط مناسب برای جوانه زنی باشد. بنابراین استفاده از روش های مدیریت متناسب با لکه ها از جمله استفاده از روشن های کنترل پس رویشی و یا استفاده از روش های کنترل پیش رویشی از طریق تیمار کردن محل لکه ها با علفکش های بذر کش قبل از شروع فصل رشد گیاه زعفران می توان به مقدار زیادی در مصرف سه صرفه جویی نمود، آلدگی های زیست محیطی را کاهش داده و نیز کنترل موثرتری را برای این علف هرز انجام داد. مکاریان (۲۳) نشان داد که کنترل لکه ای بر اساس نقشه های درونیابی شده بوسیله کریجینگ سبب کاهش  $\frac{31}{5}$  و  $\frac{37}{5}$  درصدی علفکش مورد نیاز برای کنترل جوموشی،  $\frac{20}{3}$  و  $\frac{23}{3}$  درصدی علفکش مورد نیاز برای کنترل شاهی وحشی<sup>۱</sup>،  $\frac{43}{3}$  و  $\frac{36}{7}$  درصدی علفکش مورد نیاز برای کنترل کاردوس<sup>۲</sup> نسبت به کاربرد سراسری بترتیب در سال های اول و دوم آزمایش شد. نقشه نشان می دهد که لکه در راستای ردیف های گیاه زراعی کشیده تر می باشد. عموماً در نتیجه پراکنش اولیه، بذور بصورت مجتمع در اطراف گیاه مادری در داخل یا سطح خاک پراکنده می شوند. در اراضی کشاورزی بذور پس از ریزش بوسیله عملیات مدیریتی مختلف از جمله شخم، آبیاری، برداشت، چرای حیوانات، فعالیت های زارعین و عوامل

1 - *Cardaria draba* L.

2 - *Carduus pycnocephalus* L.

می شود که امکان استفاده از مدیریت متناسب با مکان و کاهش علفکش‌های مصرفی را در مزارع ممکن می‌سازد.

داد که جوموشی دارای آرایش لکه‌ای است و بنابراین نقاط زیادی بصورت عاری از علف هرز یا با تراکم کم علف هرز در مزرعه دیده

## منابع

- 1- Aitkenhead M.J., Dalgetty I.A., Mullins C.E., McDonald A.J. S., and Strachan N.J.C. .2003. Weed and crop discrimination using image analysis and artificial intelligence methods. *Computers and Electronics in Agriculture*, 39: 157-171.
- 2- Anonymous .2007. Matlab. The Language of Technical Computing. Version 7.4 . The Mathworks of Natick, Massachusetts, USA.
- 3- Azadeh A., Ghaderi S.F., and Sohrabkhani S. 2006. Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. *Applied Mathematics and Computation*, 186: 1753-1761.
- 4- Bigwood D.B., and Inouye D.W. 1988. Spatial pattern analysis of seed banks: an improved method and optimized sampling. *Ecology*, 69: 497-507.
- 5- Buhler D.D. 1999. Expanding the Context of Weed Management. Food products press.
- 6- 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.
- 7- Clay S.A., Kreutner B., Clay D.E., Reese C., Kleinjan J., and Forcella F. 2006. Spatial distribution, temporal stability, and yield loss estimates for annual grasses and common ragweed (*Ambrosia artemisiifolia*) in a corn /soybean production field over nine years. *Weed Science*, 54: 380-390.
- 8- Dessaint F., and Caussanel J.P. 1994. Trend surface analysis: a simple tool for modeling spatial patterns of weeds. *Crop Protection*, 13: 433-438.
- 9- Dille J.A., Milner M., Groeteke J.J., Mortensen D.A., and Williams II, M.M. 2003. How good is your weed map? A comparison of spatial interpolators. *Weed Science*, 51: 44 – 55.
- 10-Drummond S.T., Sudduth K.A., Joshi A., Birrell S.J., Kitchen N.R. 2003. Statistical and neural methods for site -specific yield prediction. *Transactions of the American Society of Agricultural and Biological Engineers (ASABE)*, 46: 5–14.
- 11-Goel P.K., Prasher S.O., Patel R.M., Landry J.A., Bonnell R.B., and Viau A.A. 2003. Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn. *Computers and Electronics in Agriculture*, 39: 67–93.
- 12-Gonzales-Andujar J.L., and Saavedra M. 2003. Spatial distribution of annual grass weed populations in winter cereals. *Crop Protection*, 22: 629-633.
- 13-Gotway C.A., Ferguson R.B., Hergert G.W., and Peterson T.A. 1996. Comparison of kriging and inverse distance methods for mapping soil parameters. *Soil Science Society America Journal*, 60: 1237-1247.
- 14-Gupta M.M., Jin J., and Homma N. 2003. Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory. John Wiley & Sons, Inc., Hoboken, New Jersey.
- 15-Haykin S., 1994. Neural networks: A comprehensive foundation. McMillan College Publishing Company, New York.
- 16-Irmak A., Jones J.W., Batchelor W.D., Irmak S., Boote k.J., and Paz j.O. 2006. Artificial neural network model as a data analysis tool in precision farming. *Transactions of the American Society of Agricultural and Biological Engineers*, 49: 2027-2037.
- 17-Isaaks E.H., and Srivastava, R.M. 1989. An introduction to Applied Geostatistics. Oxford University Press, New York.
- 18-Jin Y.Q., Liu C. 1997. Biomass retrieval from high-dimensional active/pассив remote sensing data by using artificial neural networks. *International Journal of Remote Sensing*, 18: 971–979.
- 19-Karimi Y., Prasher S.O., McNairn H., Bonnell R.B., Dutilleul P., and Goel P.K. 2005. Classification accuracy of discriminate analysis, artificial neural networks, and decision trees for weed and nitrogen stress detection in corn. *Transactions of the American Society of Agricultural and Biological Engineers*, 48 :1261–1268.
- 20-Kaul M., Hill R.L., and Walhall C. 2005. Artificial neural networks for corn and soybean yield prediction. *Agriculture system*, 85: 1-18.
- 21-Kavdir S. 2004. Discrimination of sunflower, weed and soil by artificial neural networks. *Computers and*

**Electronics in Agriculture, 44: 153-160.**

- 22-Makarian H., Rashed Mohassel M.H., Bannayan M., and Nassiri M. 2007. Soil seed bank and seedling populations of *Hordeum murinum* and *Cardaria draba* in saffron fields. *Agriculture Ecosystems and Environment*, 120: 307- 312.
- 23-Makarian H. 2008. Investigation of spatial and temporal dynamic of weed seed bank and seedling populations and its effect on saffron (*Crocus sativus* L.) leaf dry weight under different weed management conditions. Ph.D. thesis in weed science. Ferdowsi University of Mashhad :193pp.
- 24-Rashed M.H. 1992. Weeds of South Khorasan saffron fields. *Agriculture Science and Technology*, 6:118-135.
- 25-Shanin M.A., Tollner E.W., McClendon R.W., and Arabnia H.R. 2002. Apple classification based on surface bruises using image processing and neural networks. *Trans. American Society of Agricultural and Biological Engineers*, 45:1619–1627.
- 26-Torrecilla J.S., Otero L., and Sanz P.D. 2004. A neural network approach for thermal/pressure food processing. *Food Engineer*, 62: 89-95.
- 27-Vakil-Baghmisheh M.T., and Pavešić N. 2001. Back-propagation with declining learning rate. Proceeding of the 10<sup>th</sup> Electrotechnical and Computer Science Conference, Portorož, Slovenia. Vol B: 297-300.
- 28-Vakil-Baghmisheh M.T. 2002. Farsi Character Recognition Using Artificial Neural Networks. PhD Thesis, Faculty of Electrical Engineering, University of Ljubljana.
- 29-Vakil-Baghmisheh M.T., Pavešić N. 2003. A Fast simplified fuzzy ARTMAP network. *Neural Processing Letters*. 17: 273-301.
- 30-Veelenturf L.P.J. 1995. Analysis applications of artificial neural networks. Simon & Schuster international group, United States of America.
- 31-Wang Y.M., Elhag T.M.S. 2007. A comparison of neural network, evidential reasoning and multiple regression analysis in modeling bridge risks. *Expert Systems with Applications*, 32: 336-348.
- 32-Wiles L. 2005. Sampling to make map for site specific weed management. *Weed Science*, 53: 228- 235.
- 33-Williams M.M., Gerhards R., and Mortensen D.A. 1999. Spatiotemporal outcomes of site-specific weed management in maize. Pages 897-906 in J. V. Stafford, ed. Precision Agriculture 99. Sheffield, Great Britain: Society of Chemical Industry.
- 34-Yuxin M., Mulla D.J., and Pierre C.R. 2006. Identifying important factors influencing corn yield and grain quality variability using artificial neural networks. *Precision Agriculture* 7: 117–135.
- 35-Zhang Y.54F., Fuh J.Y.H. 1998. A neural network approach for early cost estimation of packaging products. *Computer Ind Engineer*, 34: 433-50.
- 36-Zhang Y., Pulliainen J., Koponen S., and Hallikainen M. 2002. Application of an empirical neural network to surface water quality estimation in the Gulf of Finland using combined optical data and microwave data. *Remote Sensing of Environment*, 81: 327–336.