



تعیین الگوی توزیع جمعیت علف هرز خارشتر *Alhagi pseudalhagi* (M.B) Desv. با استفاده از شبکه عصبی مصنوعی چندی ساز بردار یادگیر (LVQ4)

عباس روحانی^{۱*} - حسن مکاریان^۲

تاریخ دریافت: ۱۳۹۱/۸/۲۰

تاریخ پذیرش: ۱۳۹۱/۱۲/۷

چکیده

تهیه نقشه‌های دقیق پراکنش علف‌های هرز به منظور کنترل متناسب با مکان آن‌ها مورد توجه بسیاری از محققین می‌باشد. این پژوهش نیز به منظور بررسی توزیع علف هرز خارشتر و ترسیم نقشه پراکنش آن با استفاده از شبکه عصبی چندی ساز بردار یادگیر (LVQ4) در سطح مزرعه انجام شد. داده‌های مربوط به جمعیت علف هرز خارشتر از طریق نمونه‌برداری از ۵۵۰ نقطه از سطح یک مزرعه در حال آیش واقع در مزرعه تحقیقاتی دانشکده کشاورزی پارامترهایی مانند میانگین، واریانس، توزیع آماری رگرسیونی بین مقادیر پیش‌بینی توزیع مکانی علف هرز با مقایسه آماری پارامترهایی مانند میانگین، واریانس، توزیع آماری رگرسیونی بین مقادیر واقعی آنها و نیز معیار دقت کلاس‌بندی انجام شد. نتایج نشان داد که در فاز آموزش، آزمایش و کل، به ترتیب مقادیر $0.7 \geq p \geq 0.2$ و $p = 1/1000$ بدست آمد که نشان دهنده عدم وجود تفاوت معنی داری در سطح ۵ درصد بین مقادیر ویژگی‌های آماری (میانگین، واریانس و توزیع آماری) مجموعه داده‌های پیش‌بینی شده مکانی علف هرز و مقادیر واقعی آنها بود. به عبارتی شبکه عصبی مصنوعی به خوبی توانست مدل داده‌های مکانی علف هرز را بیاموزد. نتایج نشان داد که شبکه عصبی آموزش دیده، دارای قابلیت بالایی در پیش‌بینی مکانی علف هرز در نقاط نمونه برداری نشده با خطای تشخیص کمتر از ۰.۹ درصد بود. شبکه عصبی توانست پس از کلاس‌بندی، نقشه توزیع مکانی علف هرز خارشتر را در تمام نقاط سطح مزرعه ترسیم نماید. نقشه حاصل از کلاس‌بندی نشان داد که علف هرز خارشتر دارای توزیع لکه‌ای است و لذا امکان کنترل متناسب با مکان آن در مزرعه مورد مطالعه وجود دارد.

واژه‌های کلیدی: توزیع لکه‌ای، کشاورزی دقیق، کلاس‌بندی، نقشه علف هرز

مقدمه

زیست محیطی خواهد شد (۱۹). ویلیامز و همکاران (۳۹) معتقدند که شناخت الگوهای پراکنش علف‌های هرز نقش مهمی در پیش‌بینی کاهش عملکرد، مدلسازی و مدیریت پایدار آنها داشته و می‌تواند سبب کاهش هزینه‌ها و نیز کاهش ورود مواد شیمیایی به محیط زیست شده و از طرفی سبب کنترل بهتر جمعیت علف‌های هرز در لکه‌ها شود. برای تصمیم‌گیری در رابطه با محل تیمار و نوع مدیریت لازم، تهیه نقشه علف‌های هرز ضروری است (۳۷). بدین ترتیب ورودی‌های مدیریتی با کارآیی بیشتری بکار رفته، هزینه‌های مورد نیاز کاهش می‌باید و سود بیشتری نیز عاید کشاورز خواهد شد (۱۷). گرهاردس و کریستنسن (۱۰)، بیان کردن که کاربرد علفکش‌ها براساس نقشه‌های تهیه شده از جمعیت علف‌های هرز مزارع غلات رستمانه سبب کاهش ۶۰ و درصدی استفاده از علفکش‌ها بترتیب در کنترل پهنه برگ‌ها و باریک برگ‌ها گردید. ویلیامز و همکاران (۳۸)، نیز توانستند با استفاده از سیستم کاربرد متناسب علفکش در

مدیریت متناسب با مکان^۳ در مزرعه بدلیل پتانسیل بالایی که در جلوگیری از آلودگی‌های زیست محیطی (از طریق عدم استفاده غیر ضروری علفکش‌ها) و کاهش هزینه‌های مدیریتی و نیز عدم کاهش در عملکرد دارد، توسط محققین مختلفی مورد توجه قرار گرفته است (۲۱). کاربرد متناسب با مکان علفکش‌ها بر اساس نقشه‌های صحیح و دقیق، عامل کلیدی در مدیریت دقیق علف‌های هرز است که در نهایت منجر به کاهش مقدار مواد شیمیایی مصرفی و نیز آلودگی‌های

۱- استادیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود
۲- نویسنده مسئول: (Email: abassrohani@yahoo.com)
۳- استادیار گروه زراعت و اصلاح نباتات، دانشکده کشاورزی، دانشگاه صنعتی شاهرود

استفاده از تصاویر تهیه شده از کانوپی برای چند گیاه زراعی تشریح نمایند، اما این تکنیک در پیشگویی متغیرهای پیوسته ای مانند رطوبت خاک (۵)، ارزیابی کیفیت آب (۴۴)، تخمین بیوماس (۱۶)، و تخمین عملکرد (۹) نیز پتانسیل بالایی نشان داده است. مدل‌های شبکه عصبی دارای مزایایی از قبیل افزایش ظرفیت اطلاعات و توانایی بیان اثرات متقابل قوی بین متغیرهای ورودی می‌باشند. آیکنهمد و همکاران (۱)، با استفاده از مدل شبکه عصبی پرسپترون چند لایه^۱ (MLP) برای تشخیص و تمایز بین گیاه زراعی هریج، علف هرز چشم و خاک مزرعه استفاده کردند. تمایز بین آفتابگردان، توچ^۲ و پس زمینه خاک نیز با استفاده از یک شبکه عصبی MLP توسط کودیر (۲۱) انجام شد. ارمک و همکاران (۱۵) 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. روحانی و مکاریان (۲۹) در پژوهشی نقشه‌های مدیریتی علف هرز تلخه را با هدف کاربرد در کشاورزی دقیق با استفاده از شبکه‌های عصبی مصنوعی تهیه کردند، آنها نشان دادند که شبکه‌های عصبی قابلیت درون یابی مطلوبی داشته و می‌تواند الگوهای توزیع علف‌های هرز را به خوبی تشخیص دهد. در حال حاضر، مطالعات متعددی به منظور پیش‌بینی 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. علف هرز خارشتر گونه‌ای چندساله و دارای ریشه‌های عمیق است که می‌تواند در نواحی خشک و نیمه خشک به خوبی رشد کند. این علف هرز در مراتع و در مزارع غلات و باغات ایران مشکلات زیادی ایجاد کرده است (۲۸). هدف از این پژوهش، پیش‌بینی و طبقه‌بندی توزیع مکانی علف هرز خارشتر. *Alhagi pseudalhagi* (M.B Desv.) به دلیل با استفاده از شبکه عصبی چندی ساز بردار یادگیر (LVQ4)^۲ به دلیل قابلیت آن در تفکیک مزرعه از نظر مقدار حد آستانه علف‌های هرز به منظور اتخاذ تصمیم‌های مدیریتی دقیق در مورد این علف هرز به سبب چند ساله بودن آن بود.

مواد و روش‌ها

آزمایش در سال ۱۳۸۹ در اراضی زراعی دانشکده کشاورزی دانشگاه صنعتی شاهrood واقع در استان سمنان انجام شد. طول و عرض جغرافیایی محل به ترتیب ۵۴° و ۵۸° شمالی و ۳۶° و ۲۵° شرقی

2- Multi layer perceptron
3- Xanthium strumarium

مدیریت متناسب با مکان، میزان علفکش ورودی به مزرعه ذرت را ۱۲ تا ۱۵ درصد کاهش دهنده. تعیین نقشه آلدگی علف‌های هرز نه تنها برای کاربرد متناسب با مکان علف کشندها مورد استفاده قرار می‌گیرد بلکه برای ارزیابی راهبردهای مدیریتی در گذشته و یا حال (۲۵) و طراحی راهبردهای مدیریتی آینده علف‌های هرز کارا می‌باشد (۱۸). اما آنچه رسیدن به این اهداف را محقق می‌سازد افزایش صحت علف‌های هرز است. گوئل و همکاران (۱۲) تعیین نقشه‌های دقیق و آنالیز آن را از راه‌های کلیدی در کشاورزی دقیق می‌دانند. به هر حال یکی از نارسایی‌های روش‌های متدالو در آمار کلاسیک عدم توجه به سودمندی اطلاعات مربوط به موقعیت جغرافیایی 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 (۲۶). بنابراین به نظر می‌رسد در آنالیز مکانی جوامع یکی از راه‌ها جهت فایق آمدن به این نارسایی‌ها استفاده از روش‌های کلاس بندی و تهیه نقشه بوسیله مدل شبکه عصبی مصنوعی چندی ساز بردار یادگیر^۳ (LVQ4) می‌باشد. امروز شبکه‌های عصبی در بسیاری از زمینه‌ها از جمله طبقه‌بندی، تشخیص الگو، پیش‌بینی و مدلسازی فرآیند‌ها در علوم مختلف بکار گرفته می‌شوند. مزیت روش شبکه عصبی یادگیری مستقیم از روی داده‌ها، بدون نیاز به برآورد مشخصات آماری آنها است (۳۴). شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و همچنین دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن رابطه بین مجموعه‌ای از ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه می‌باشد (۲۰، ۳۲). ویژگی دیگر شبکه عصبی، تحمل پذیری در مقابل خطا می‌باشد (۳). شبکه‌های عصبی شامل تعدادی نرون‌های متصل بهم هستند. مراحل اصلی حل هر مسئله توسط شبکه عصبی شامل آموزش و آزمایش می‌باشد (۱۴، ۳۶). استفاده از مدل شبکه عصبی مصنوعی در تمایز الگوها در سال‌های اخیر مورد توجه قرار گرفته است. شبکه‌های عصبی طبقه‌بندی کننده در مقایسه با روش‌های آماری دارای مزایای بیشتری است (۲). بعضی از مشکلات طبقه‌بندی که از نظر کاربرد در کشاورزی خود را نشان داده اند بوسیله شبکه عصبی می‌توانند موفقیت بر طرف شده اند (۴۰). امروزه شبکه‌های عصبی می‌توانند آموزش بینند تا با دقت بالا جمعیت علف هرز را از گیاه زراعی در مزارع متمایز کنند (۴۱). علاوه بر این شبکه‌های عصبی مصنوعی در تفکیک پوشش‌های گیاهی و نیز علف‌های هرز در روش‌های سنجش از دور مورد استفاده قرار گرفته است (۱۲، ۱۹ و ۳۰). گرچه با استفاده از این مدل‌ها توانسته اند روابط غیر خطی پیچیده و مرکب را با

1- Learning Vector Quantization Neural Network

$$a(n) = \begin{cases} k_1 & \text{if } q \leq q_0 \\ k_2 \exp\left(-\frac{q-q_0}{\tau}\right) & \text{if } q > q_0 \end{cases}, \quad 0 < a(n) < 1 \quad (3)$$

اگر کلاس بندی صحیح باشد $d_c(n) = s(n)$ می‌باشد و در صورتیکه کلاس بندی صحیح نباشد $s(n) = -1$ خواهد شد. $d_c(n)$ عامل معادل کننده است و از رابطه زیر بدست می‌آید:

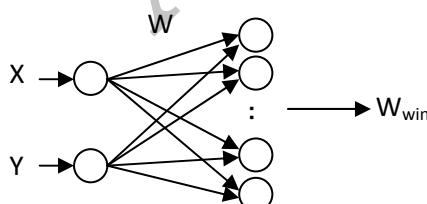
$$d_c(n) = \frac{E_c(n)}{P_c(n)} \quad (4)$$

در این رابطه، به ترتیب $P_c(n)$ تعداد بردارهایی است که به درستی و اشتباه توسط بردار کد c کلاس بندی می‌شود. تا پایان تکرار اول مقدار $d_c(n)$ مشخص نخواهد شد. بنابراین از روش زیر برای محاسبه آن استفاده شد:

$$d_c(n) = \begin{cases} \varepsilon & \text{if } q = 1 \\ d_c(n-1) & \text{if } q \geq 2, P_c(n-1) \neq 0 \\ \lambda & \text{if } q \geq 2, P_c(n-1) = 0 \end{cases} \quad (5)$$

$\varepsilon < 0$ و $\lambda \geq 1$ می‌باشد. مقادیر توصیه شده $\varepsilon = 0/2$ و $\lambda = 10$ است. (۳۵)

هدف استفاده از شبکه LVQ4، کلاس بندی سطح مزرعه به دو کلاس متفاوت بر حسب حد آستانه‌های مختلف (صفر، ۲ و ۴ بوته در هر متر مربع) به منظور از بین بردن علفهای هرز بالاتر از حد آستانه به کمک روش‌های مدیریتی معمول است. کلاس اول نقاطی از مزرعه که دارای علف هرز هستند و نقاطی دیگری که فاقد علف هرز می‌باشند. به طور کاملاً تصادفی، ۸۰ درصد از کل داده‌ها به طور تصادفی برای آموزش شبکه و ۲۰ درصد باقی مانده برای آزمایش شبکه بمنظور کلاس بندی انتخاب شد. ساختار شبکه عصبی LVQ4 استفاده شده بمنظور کلاس بندی سطح مزرعه به دو منطقه دارای علف هرز و فاقد علف هرز یا کلاس بندی بر مبنی تراکم‌های مختلف در شکل ۱ نشان داده شده است. ورودی‌های شبکه مختصات مکانی علف‌های هرز می‌باشند و خروجی شبکه بردار کدی است که نزدیکترین فاصله اقلیدسی را با ورودی دارد. برچسب بردار کد تعیین کننده کلاس بردار ورودی است. برنامه نویسی این مدل در محیط نرم افزار Matlab نسخه ۷ انجام شد.



شکل ۱- ساختار شبکه LVQ4 استفاده شده برای پیش‌بینی مکانی وجود علف هرز.

(X,Y) مختصات نقاط نمونه برداری شده، W ماتریس بردارهای کد و W_{win} برچسب بردار کد برندۀ شده.

و ارتفاع محل از سطح دریا ۱۳۴۹/۱ متر می‌باشد. میانگین برندگی سالیانه منطقه ۱۵۰ میلی متر، میانگین سالانه دما ۱۴/۴ درجه سانتی گراد می‌باشد. داده‌های مورد استفاده از مزرعه ای به ابعاد ۲۰×۱۰۰ متر (۲۰۰۰ متر مربع) و در حال آیش در مرداد ماه جم جوری شد. علف هرز خارشتر یکی از گونه‌های با تراکم بالا در این مزرعه بود. بنابراین در این پژوهش توزیع جمعیت علف هرز خارشتر بر روی یک شبکه عالمت گذاری شده مربعی^۱ به ابعاد ۲×۲ متر انجام و در مجموع از ۵۵ نقطه در مزرعه نمونه برداری انجام شد. نمونه برداری از جمعیت علف هرز با استفاده از کوادراتی به ابعاد ۵۰×۵۰ سانتی متر (مساحت ۲۵۰ متر مربع) در محل تقاطع خطوط شبکه مربعی و بصورت غیرتصادفی انجام شد. بطوریکه در هر کوادرات جمعیت علف هرز خارشتر شناسایی و شمارش شد. سپس داده‌ها در مدل مورد استفاده قرار گرفت.

شبکه عصبی چندی ساز بردار یادگیر (LVQ4)

شبکه عصبی LVQ4 یکی از روش‌های طبقه بندی و خوشبندی است. نحوی کار آن بر اساس تقسیم فضای ورودی R^n به تعدادی منطقه‌های متمایز از هم با نام ناحیه‌های تصمیم‌گیری^۲ و اختصاص یک بردار کد^۳ به هر یک از آنها است. کلاس بندی بر حسب نزدیکی بردار ورودی x^q به بردارهای کد انجام می‌شود. بردار ورودی متعلق به کلاس نزدیکترین بردار کد خواهد شد. الگوریتم تا وقتیکه ناحیه‌های تصمیم‌گیری و مرکزهای آنها ثابت نشود ادامه خواهد یافت. از بین شش گونه الگوریتم آموزش با نام‌های LVQ1، LVQ2.1، LVQ2.2، LVQ3، LVQ4 (۳۵، ۳۶) از الگوریتم آموزش LVQ4 به جهت بالا بودن کارآمدی آن استفاده شد.

الگوریتم آموزش شبکه عصبی LVQ4

فرض شود x^q بردار ورودی از مجموعه آموزش باشد:

$$Q, \dots, q=1, \quad x^q \in R^n$$

و $w_m \in R^n$ ، $m=1, \dots, M$ بردار کد باشد

پیدا کردن نزدیکترین بردار کد به x^q :

$$w_c = \arg \min_m (\|x^q - w_m\|) \quad (1)$$

$$w_c(t+1) = w_c(t) + \alpha(n)s(n)[x^q - w_c(t)] \quad (2)$$

$\alpha(n)$ آهنگ یادگیری در طول زمان آموزش از رابطه زیر بدست آمد.

1- Grid

2- Decision regions (Voronoi cells)

3- Codebook (Voronoi) vector

نتایج و بحث

شبکه عصبی آموزش دیده اطمینان داشت. برای اثبات ادعای ما درمورد قابل اطمینان بودن شبکه های عصبی آموزش دیده برای پیش بینی الگوی پراکنش علف هرز خارشتر، داده های واقعی و داده های پیش بینی شده توسط شبکه از نظر آماری با هم مقایسه شدند. 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 آزمون شد. بنابراین اگر p محاسبه شده برای هر مقایسه بیشتر از 0.05 باشد، فرضیه صفر را نمی توان رد کرد. به ترتیب برای مقایسه میانگین، واریانس و توزیع آماری از آزمون t ، F و کولموگروف-اسمیرنو استفاده شد. مقادیر p محاسبه شده برای هر مورد کلاس بندی در جدول ۲ نشان داده شده است. این نتایج نشان می دهند که میانگین، واریانس و توزیع آماری مقادیر واقعی و پیش بینی شده در هر مورد طبقه بندی، اختلاف معنی داری با هم ندارند (در تمام موارد $p > 0.02$). بنابراین شبکه عصبی مصنوعی LVQ4 دارای قابلیت بالایی برای پیش بینی توزیع آماری بین مقادیر پیش بینی شده و مقادیر واقعی تراکم علف هرز در سطح مزرعه بوده که نشان از دقت بالا و نیز قابلیت خوب شبکه عصبی مصنوعی LVQ4 بمنظور کلاس بندی سطح مزرعه از نظر تراکم علف هرز با هر مقدار تراکم آستانه می باشد.

خطای تشخیص شبکه عصبی LVQ4 در دو مرحله آموزش و آزمایش در هر مورد طبقه بندی سطح مزرعه در جدول ۱ نشان داده شده است. خطای تشخیص، یعنی تعداد الگوهایی که به غلط توسط شبکه عصبی کلاس بندی شده به تعداد کل الگوهای های موجود در هر مرحله کاری شبکه در این جدول قابل ملاحظه است. برای سه حالت کلاس بندی سطح مزرعه بر اساس وجود و یا عدم وجود علف هرز ($WD_1 = 0$ ، $WD_1 > 0$ ، $WD_2 < 2$ ، $WD_1 \leq 2$) و $WD_2 > 2$ ، $WD_1 < 4$ ، $WD_2 < 4$ ، $WD_1 \leq 4$ ، $WD_2 > 4$) سطح مزرعه با تراکم کمتر یا مساوی ۴ بوته در هر متر مربع و بیشتر از آن ($WD_2 > 4$ ، $WD_1 < 4$) خطای تشخیص از صفر تا ۰/۹۱ متغیر است. به راحتی می توان با توجه به پایین بودن خطای تشخیص در فاز آموزش (۰/۶۸-۰/۲۳ درصد) به شبکه عصبی برای کلاس بندی سطح مزرعه اطمینان حاصل کرد و می توان بیان کرد که شبکه عصبی آموزش دیده به طور کامل الگوهای موجود را یاد گرفته است. بنابراین وزن های شبکه (بردارهای کد) مقدار بهینه دارند. در مرحله بعدی، ویژگی تعمیم پذیری و شایستگی شبکه عصبی آموزش دیده ارزیابی می شود. بنابراین شبکه با استفاده از مجموعه داده های غیر از مجموعه داده های آموزش (مجموعه داده های تست) ارزیابی شد. خطای تشخیص در فاز آزمایش بسیار کم (۰/۰۰ درصد) می باشد که این نشان از ویژگی تعمیم پذیر شبکه عصبی LVQ4 برای سایر نقاط مزرعه دارد. بنابراین می توان به

جدول ۱- خطای تشخیص شبکه عصبی LVQ4 در دو فاز آموزش و آزمایش

هدف شبکه برای طبقه بندی	تعداد عضوهای کلاس یک	تعداد عضوهای کلاس دو	خطای تشخیص در مرحله آموزش(%)	خطای تشخیص در مرحله آموزش(%)	خطای تشخیص در مرحله آزمایش(%)	خطای تشخیص در مرحله آزمایش(%)
	۴۵۳	۹۷	۰/۴۵	۰/۴۵	۰/۰۰	۰/۰۰
	۵۱۶	۳۴	۰/۶۸	۰/۶۸	۰/۹۱	۰/۹۱
	۵۳۹	۱۱	۰/۲۳	۰/۲۳	۰/۰۰	۰/۰۰

توضیحات: WD_1 و WD_2 به ترتیب تراکم علف هرز (Weed Density) در کلاس اول و کلاس دوم طبقه بندی.

جدول ۲- مقادیر P حاصل از مقایسات آماری مقادیر واقعی و پیش بینی شده جمعیت علف هرز خارشتر بوسیله شبکه عصبی

هدف شبکه برای طبقه بندی	مرحله بکارگیری شبکه	نوع تحلیل آماری	مقایسه میانگین	مقایسه واریانس	مقایسه توزیع
		فاز آموزش			
		فاز آزمایش			
		فاز آموزش			
		فاز آزمایش			
		فاز آموزش			
		فاز آزمایش			

توضیحات: WD_1 و WD_2 به ترتیب تراکم علف هرز (Weed Density) در کلاس اول و کلاس دوم طبقه بندی.

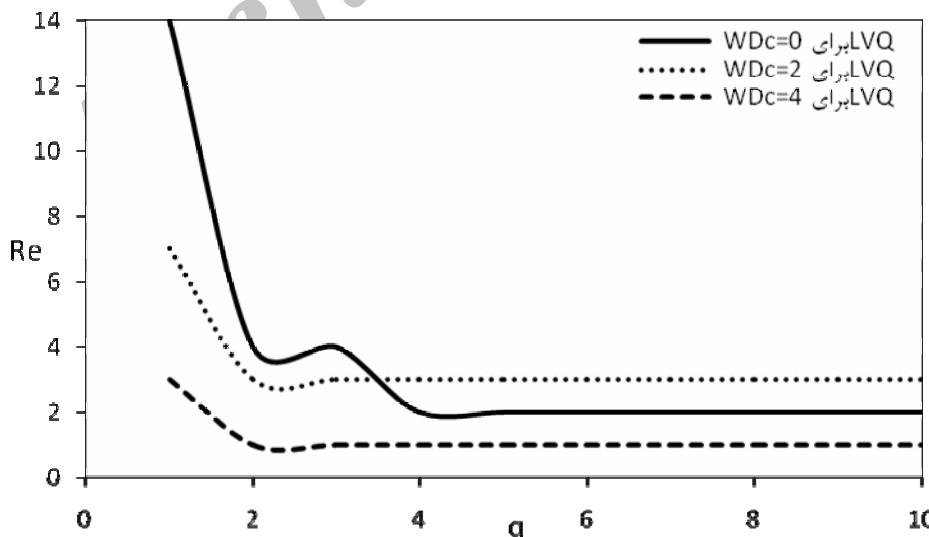
مبدا نزدیکتر به صفر برخوردار است. نمودار همگرایی شبکه عصبی LVQ4 در مدت زمان آموزش برای سه مورد کلاس بندی در شکل ۲ نشان داده شده است. خطای تشخیص یا کلاس بندی به ترتیب برای حد آستانه صفر، ۲ و ۴ از تعداد ۱۴ و ۷ و ۳ نقطه ($Re=3, 7, 14$) برای کل مجموعه آموزش، شروع و به تدریج کم تر می‌شود و بعد از ۴، ۲ و ۲ تکرار ($q=2, 4, 6$)، خطای ثابت باقی می‌ماند زیرا مرکزها و ناحیه‌های تشخیص هر بردار کد بدون تغییر می‌مانند. افزایش تعداد تکرارهای الگوریتم نیز موجب حرکت بردارهای کد به موقعیت دیگری نخواهد شد. لذا ادامه آموزش بی‌فاایده خواهد بود. بنابراین آموزش شبکه باید متوقف شود. معیار توقف الگوریتم بر اساس همین فرض بنا نهاده شد. نتایج این نمودار نشان می‌دهند که شبکه عصبی LVQ4 در حداقل زمان ممکن می‌تواند الگوی پراکنش علف هرز را یاد بگیرد و آنها را پیش بینی کند و همچنین بر اساس نتایج مندرج در جدول‌های ۱، ۲ و ۳ از قابلیت تعیین پذیر بالایی نیز برخوردار باشد.

ضرایب تبیین و همچنین رابطه خطی رگرسیونی بین مقادیر واقعی هر کلاس در مقابل مقادیر پیش بینی شده توسط شبکه عصبی LVQ4 در جدول ۳ نشان داده شده است. بهترین نتایج براساس این دو معیار وقتی بدست می‌آید که معادله خطی مابین تراکم علف هرز واقعی و تراکم علف هرز پیش بینی شده توسط شبکه عصبی علاوه بر داشتن ضرایب تبیین بالا دارای کمترین عرض از مبدا (نزدیک به صفر) و شبیب نزدیک به یک باشد ($PV=1/000dv+0/000$). کاملاً واضح است که ضرایب تبیین بین داده‌های واقعی و پیش بینی شده بسیار بالا می‌باشند ($R^2>0.8$). همچنین معادله خطی رگرسیونی مابین آنها دارای شبیه‌های نزدیک به واحد و عرض از مبداها کوچکی هستند، بنابراین می‌توان به چنین شبکه‌هایی اطمینان کرد. این نتایج نشان می‌دهند که قابلیت تعیین پذیری شبکه عصبی آموزش دیده بسیار بالا می‌باشد زیرا فاز آزمایش در مقایسه با فاز آموزش دارای ضریب تبیین بالاتر و نیز معادله خطی رگرسیونی مابین مقادیر واقعی و پیش بینی شده از شبیب نزدیکتر به واحد و عرض از

جدول ۳- رابطه خطی رگرسیونی و ضریب تبیین بین PV و dv

R^2	هدف شبکه برای طبقه بندی	مرحله بکارگیری شبکه	رابطه خطی رگرسیونی
.۹۶۹	$PV=0/۹۸۴ dv+0/۰۱۸$	فاز آموزش	
.۹۹۹	$PV=1/۰۰۰ dv+0/...$	فاز آزمایش	$WD_2>0, WD_1=0$
.۸۸۲	$PV=0/۸۸۸ dv+0/۱۱۱$	فاز آموزش	$WD_2>2, WD_1=2$
.۸۶۶	$PV=0/۹۹۰ dv+0/۰۱۹$	فاز آزمایش	
.۸۸۷	$PV=0/۸۸۹ dv+0/۱۱۱$	فاز آموزش	$WD_2>4, WD_1\leq 4$
.۹۹۹	$PV=1/۰۰۰ dv+0/...$	فاز آزمایش	

توضیحات: PV : مقادیر واقعی داده‌ها dv : مقادیر پیش بینی شده توسط مدل. WD_2 و WD_1 به ترتیب تراکم علف هرز ($Weed Density$) در کلاس اول و کلاس دوم طبقه بندی.



شکل ۲ - نمودار همگرایی شبکه عصبی LVQ4 در طول مدت آموزش q : تعداد تکرارهای آموزش شبکه و Re : خطای کلاس بندی در مرحله آموزش و WD_c : حد آستانه فرضی

مشهود است. به نظر می‌رسد با استفاده از روش‌های مدیریت مناسب با لکه‌ها از جمله استفاده از روش‌های کنترل پس رویشی و یا استفاده از روش‌های کنترل پیش رویشی از طریق تیمار کردن محل لکه‌ها با روش‌های مدیریتی مختلف قبل از شروع فصل رشد گیاه زراعی می‌توان به مقدار زیادی در مصرف سه صرفه جویی نمود، آلودگی‌های زیست محیطی را کاهش داده و نیز کنترل موثرتری را برای این علف هرز انجام داد. به اعتقاد کولر و لانینی^(۲۴) ترسیم نقشه‌های دقیق، اختصاصی و به موقع علف‌های هرز کلید دستیابی به تمام مزایای مدیریت مناسب با مکان علف‌های هرز به شمار می‌رود. در اراضی کشاورزی بذور و اندام‌های رویشی تکثیر شونده علف‌های هرز بوسیله عملیات مدیریتی مختلف از جمله شخم، آبیاری، برداشت، چراخ حیوانات، فعالیت‌های زارعین و عوامل محیطی در سطح مزرعه جابجا می‌شوند.^(۳۱)

علف هرز خارشتر گیاهی چندساله از خانواده بقولات^۱ است که قادر به تکثیر از طریق بذر می‌باشد، اما این گیاه عمدتاً از طریق پراکنش قطعات ریشه بوسیله عوامل گوناگون تکثیر می‌شود.^(۲۸) بذور علف هرز خارشتر مکانیسم پراکنش خاصی ندارد و از طرفی چون اغلب عواملی مانند شخم با گاوآهن، دیسک و سایر عملیات مدیریتی سبب قطعه قطعه شدن ریشه‌های این گیاه و جابجایی آن در فاصله اندک از گیاه مادری می‌شوند لذا پراکنش جمعیت این علف هرز بصورت لکه‌ای است. وجود توزیع لکه‌ای در علف‌های هرز چند ساله ای نظیر خارلته^۲، قیاق^۳ که بوسیله اندام‌های رویشی زیر زمینی تکثیر می‌شوند نیز گزارش شده است.^(۶) گرگهاردس و همکاران^(۱۰) بیشترین پایداری لکه‌ها را متعلق به چند ساله‌ها می‌دانند. گوسالی و همکاران^(۱۳) با استفاده از مدل‌های شبیه‌سازی، پراکنش علف هرز تلخه^۴ را در ایالت کلرادوی آمریکا مورد مطالعه قرار دادند. آنها نقشه‌های پراکنش این علف هرز را ترسیم کرده و نشان دادند که این علف هرز عمدتاً بصورت لکه‌ای ظاهر می‌شود، به گفته همین محققین برهمنکنیش بین میزان بارندگی، درجه حرارت و بافت خاک سبب توزیع ناهمگون این علف هرز در سطح ایالت شده است. در نهایت آنها بیان کردند که با توجه به توزیع لکه‌ای تلخه، امکان کنترل نقاط آلوده به این علف هرز و کاهش میزان سه صرفی و هزینه‌های کنترل وجود دارد. کوباخ و همکاران^(۸) نیز بیان کردند که پایداری لکه‌ها در بین گونه‌های مختلف علف هرز

الگوی توزیع مکانی علف هرز خارشتر

نقشه‌های پراکنش مکانی علف هرز خارشتر که با توجه به سطوح آستانه فرضی صفر، ۲ و ۴ بوته در هر متر مربع توسط شبکه عصبی LVQ4 پیش‌بینی و کلاس بندی شد در شکل ۳ نشان داده شده است. این کلاس بندی به مدیر مزرعه جهت کنترل علف هرز در نقاطی از مزرعه که دارای تراکم‌های بالاتر از حد آستانه هستند، کمک می‌کند. حد صفر، ۲ و ۴ بوته انتخاب شده می‌تواند یک حد آستانه فرضی برای علف هرز باشد تا به کمک آن قابلیت شبکه عصبی نشان داده شود. اگرچه پیش‌تر با مقایسه آماری، خطای تشخیص و معادله رگرسیونی مابین مقادیر واقعی و پیش‌بینی شده به عدم وجود تفاوت معنی دار بین آنها دست پیدا کردیم ولی با مقایسه بین نقشه حاصل از داده‌های واقعی و داده‌های پیش‌بینی شده توسط شبکه عصبی LVQ4 متوجه خواهیم شد که تفاوت چنانی بین آنها وجود ندارد و اگر بعضی نقاط در دو نقشه متناظر متفاوت از هم هستند ناشی از خطای مدل شبکه عصبی است. ولی در مورد صحت کارآیی یک مدل نمی‌توان تنها با مقایسه یک یا چند نقطهٔ قضاؤت کرد^(۴۳). واضح است که نقاط دارای تراکم بیشتر از حد آستانه مورد نظر در مدیریت مناسب با مکان مورد تیمار قرار می‌گیرد و سایر نقاط که زیر حد آستانه قرار دارند نیاز به مصرف علفکش یا هر عملیات کنترلی ندارند. آستانه اقتصادی به صورت تراکمی از علف هرز تعریف شده که در آن هزینه کنترل علف هرز معادل سود حاصل از کنترل است^(۲۷). آستانه خسارت اقتصادی به کشاورز در جهت تصمیم‌گیری صحیح در مورد کنترل علف‌های هرز کمک می‌کند. زان و همکاران^(۴۲) با استفاده از شبکه عصبی مصنوعی چندی ساز بردار یادگیر (LVQ4) میزان آلودگی پانیکول برنج به بیماری بلایت را به چند سطح سالم، با آلودگی کم، متوسط و شدید طبقه بندی کردند. سپس بر اساس آستانه آلودگی مورد نظر اقدام به کنترل بیماری کردند. کلی و همکاران^(۷)، با استفاده از روش درونیابی میزان کاهش عملکرد ذرت دانه‌ای را در اثر رقابت با علف‌های هرز باریک برگ یکساله بصورت موضوعی در سطح مزرعه تخمین زدند و نشان دادند که بعضی از نقاط بدلیل اینکه کاهش عملکرد آنها از حد آستانه مورد نظر کمتر بود، نیاز به کاربرد علفکش نداشت. بنابراین چنانچه آستانه خسارت برای علف هرزی بر اساس اطلاعات لازم تعریف شده با شبکه عصبی LVQ4 ابزارهای موثر و دقیقی خواهد بود که به مدیر مزرعه جهت کنترل مناسب با مکان (نقاط بالای حد آستانه) کمک خواهد کرد.

در نقشه‌های ترسیم شده (شکل‌های ۳ و ۴) لکه‌هایی از علف هرز با اشکال و اندازه‌های متفاوت به چشم می‌خورد. نقشه نشان می‌دهد که دامنه تغییرات لکه‌های آلوده در سطح مزرعه بالاست. توزیع ناهمگون و تجمعی علف هرز خارشتر در این شکل ها به خوبی

1 - Fabaceae

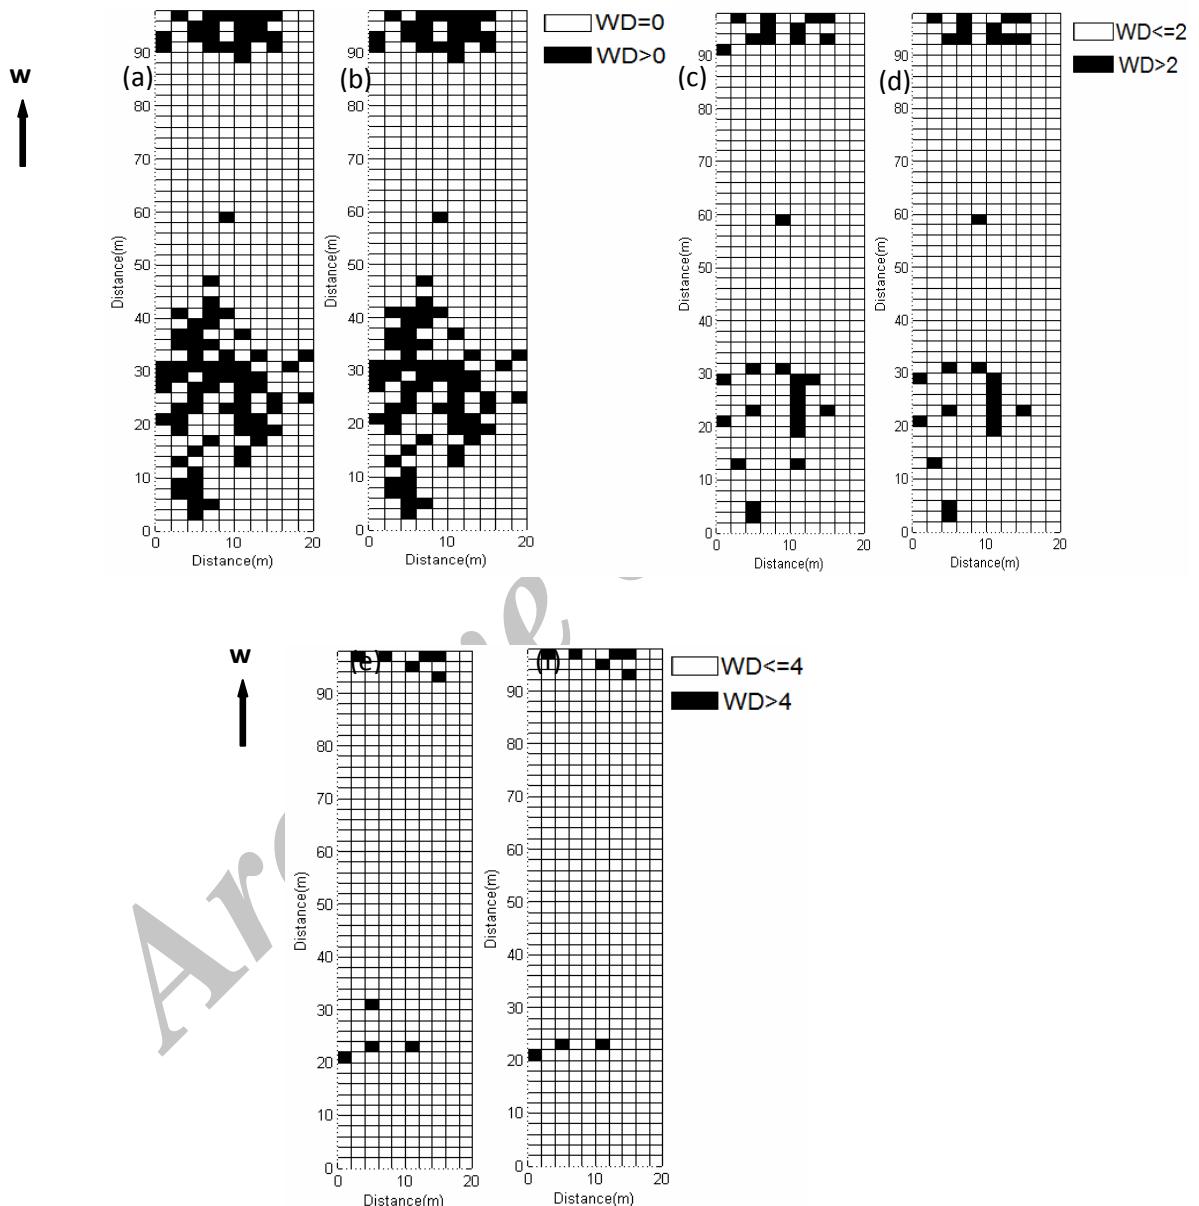
2 - *Cirsium arvense* L.

3 - *Sorghum halepense* L.

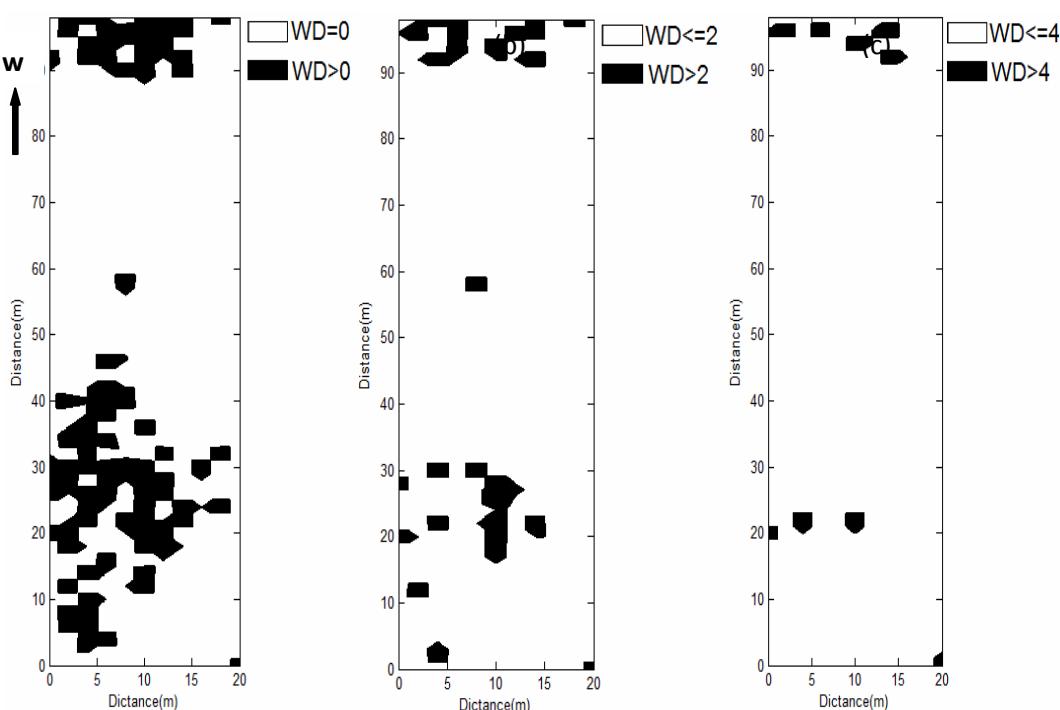
4 - *Acroptilon repens* L.

مطالعه آرایش ناهمگون علف هرز خارشتر نشان داد که راهبردهای رایج مدیریتی که توزیع تصادفی علفهای هرز را مبنای کار خود قرار داده اند قادر به توصیف صحیح این قبیل جوامع نمی باشند و در نهایت با محاسبات اشتیاه سبب مصرف بیش از حد نیاز علفکش و آلدگی‌های زیست محیطی خواهد شد.

متفاوت است. لفهای هرزی که حالت لکه‌ای بودن و پایداری بیشتری دارند برای مدیریت مناسب با مکان مناسب‌ترند. به هر حال، تراکمی داکار و همکاران (۳۳) دریافتند که علیرغم اینکه عملکرد ذرت در شرایط مصرف علف کش به صورت کاربرد مناسب با مکان و کاربرد سراسری، مشابه بوده است ولی از طریق مدیریت مناسب با مکان، مصرف آثارازین ۳۲ و دایکامبا ۴۵ درصد کاهش یافته. در این



شکل ۳- نقشه توزیع جمعیت علف هرز خارشتر در دو حالت واقعی (شکل‌های a و e) و تفکیک شده توسط مدل شبکه عصبی LVQ4 (شکل‌های b، d و f). WD: تراکم علف هرز (Weed Density). شکل‌های (a) نقاطی از مزرعه که فاقد علف هرز و یا دارای علف هرز هستند. شکل‌های (c) و (d) نقاطی از مزرعه که دارای مساوی و یا کمتر از دو بوته علف هرز و بیشتر از دو بوته علف هرز در متر مربع هستند. شکل‌های (e) و (f) نقاطی از مزرعه که دارای مساوی یا کمتر از چهار بوته و بیشتر از چهار بوته علف هرز در متر مربع هستند.



شکل ۴- نقشه توزیع جمعیت علف هرز خارشتر پیش بینی شده بوسیله مدل شبکه عصبی LVQ4 برای تمام سطح مزرعه. شکل های a، b و c بترتیب بر اساس حد آستانه های فرضی صفر، ۲ و ۴ بونه خارشتر در مترمربع ترسیم شده اند.

حاصل از شبکه نشان داد که خارشتر دارای آرایش لکه ای است. بنابراین به نظر می رسد از طریق تیمار کردن لکه های دارای علف هرز می توان به اهداف مدیریت متناسب با مکان و کاهش علفکش های مصرفی دست یافت.

این پژوهش نشان داد که شبکه عصبی LVQ4 توانست علاوه بر پیش بینی، نقشه پراکنش جمعیت علف هرز خارشتر را به خوبی ترسیم نماید. براساس نتایج این آزمایش و یافته های زان و همکاران (۴۲) شبکه عصبی می تواند بر اساس هر آستانه تعیین شده نقشه های مدیریتی برای اعمال تیمار نقاط بالای حد آستانه تهیه کند. نقشه

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. *Comput. Electron. Agr.* 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. *Appl. Math. Comput.* 186: 1753-1761.
- 4- Buhler D.D. 1999. Expanding the Context of Weed Management. Food products press. Canada, March 3, 1999, pp. 60 /65. Conseil des production végétales du Québec, Inc.
- 5- Chang D.H., and Islam S. 2000. Estimation of soil physical properties using remote sensing and artificial neural network. *Remote Sens. Environ.* 74: 534-544.
- 6- Christensen S., Heisel T., and Paice M. 1998. Simulation of long term *Alopecurus myosuroides* population using three patch spraying strategies. Proceedings of the 15th Danish Plant Prot. Con. Weeds. DJF-RC. Prot No. 2, pp. 141-150.
- 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 Sci.* 54: 380-390.

- 8- Colbach N., Forcella F., and Johnson G.A. 2000. Spatial and temporal stability of weed populations over five years. *Weed Sci.* 48:366-377.
- 9- Drummond S.T., Sudduth K.A., Joshi A., Birrell S.J., and Kitchen N.R. 2003. Statistical and neural methods for site-specific yield prediction. *Trans. of the Americ. Soc. of Agri. and Biol. Engin. (ASABE)*. 46: 5–14.
- 10- Gerhards R., and Christensen S. 2003. Real- time weed detection, decision making and patch spraying in maize, sugarbeet, winter wheat and winter barley. *Weed Res.* 43: 385- 392.
- 11- Gerhards R., Wyse-pester D.Y., and Johnson G.A. 1997. Characterizing spatial stability of weed populations using interpolated maps. *Weed Sci.* 45: 108-119.
- 12- 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. *Comput. Electron. Agr.* 39: 67–93.
- 13- Goslee C.S., Peters D.P.C., and George-Beck K. 2006. Spatial prediction of invasion success across heterogeneous landscapes using an individual-based model. *Biol. Invas.* 8: 193- 200.
- 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- 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. *Trans. of the Americ. Soc. of Agri. and Biol. Engin. (ASABE)*. 49: 2027-2037.
- 16- Jin Y.Q., and Liu C. 1997. Biomass retrieval from high-dimensional active/passive remote sensing data by using artificial neural networks. *Int. J. Remot. Sens.* 18: 971–979.
- 17- Johnson G.A., Mortensen D.A., and Martin A.R. 1995. A simulation of herbicide use based on weed spatial distribution. *Weed Res.* 35: 197-205.
- 18- Joshi C.H., Leeuw J.D., and Duren I.C.V. 2008. Remote sensing and GIS application for mapping and spatial modeling of invasive species. www.Isprs.org.
- 19- Karimi Y., Prasher S.O., McNairn H., Bonnell R.B., Dutilleul P., and Goel P.K. 2005. Classification accuracy of discriminant analysis, artificial neural networks, and decision trees for weed and nitrogen stress detection in corn. *Trans. of the Americ. Soc. of Agri. and Biol. Engin. (ASABE)*. 48 :1261–1268.
- 20- Kaul M., Hill R.L., and Walther C. 2005. Artificial neural networks for corn and soybean yield prediction. *Agr. syst.* 85: 1-18.
- 21- Kavdir S. 2004. Discrimination of sunflower, weed and soil by artificial neural networks. *Comput. Electron. Agr.* 44: 153-160.
- 22- Kohonen T. 1990. The Self-Organizing Map, Proceedings of IEEE. Vol. 78, No. 9.
- 23- Kohonen T. 1995. Self-Organizing Map, Springer-Verlag, Berlin, Heidelberg.
- 24- Koller M., and Lanini W.T. 2005. Site- specific herbicide applications based on weed maps provide effective control . *Calif. Agr.* 59: 182-187.
- 25- Lamb D.W., and Brown R.B. 2001. Remote-sensing and mapping weeds in crops. *J. Agr. Engin. Res.* 87: 117-125.
- 26- 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. *Agr. Ecosys. Environ.*120: 307- 312.
- 27- O'Donovan J.T. 1991. Quackgrass (*Elytrigia repens*) interference in canola (*Brassica campestris*). *Weed Sci.* 39: 397-401.
- 28- Rashed Mohassel M.H., Najafi H., and Akbarzadeh M.D. 2001. Weed Biology and Control. Ferdowsi University Press, 404p.(In Persian)
- 29- Rohani A., and Makarian H. 2011. Making weed management maps by artificial neural networks for using in precision agriculture. *J. Agr. Machin. Engin.* 2: 74- 83.
- 30- 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. of the Americ. Soc. of Agri. and Biol. Engin.* 45:1619–1627.
- 31- Shaukat S.S., and Siddiqui I.A. 2004. Spatial pattern analysis of seed bank and its relationship with

- above-ground vegetation in an arid region. *J. Arid Environ.* 57: 311-327.
- 32- Torrecilla J.S., Otero L., and Sanz P.D. 2004. A neural network approach for thermal/pressure food processing. *Food Engin.* 62: 89-95.
- 33- Tredaway-Ducar J., Morgan G.D., Wilkeson J.B., Hart W.E., Hayes R.M., and Mueller T.C. 2003. Site-specific weed managemnet in corn (*Zea mays*). *Weed Tech.* 17: 711-717.
- 34- Vakil-Baghmisheh M.T. 2002. Farsi Character Recognition Using Artificial Neural Networks. PhD Thesis, Faculty of Electrical Engineering, University of Ljubljana.
- 35- Vakil-Baghmisheh M.T., and Pavešić N. 2003. Premature clustering phenomenon and new training algorithms for LVQ4. *Pattern recogn.* 36:1901-1921.
- 36- Veelenturf L.P.J. 1995. Analysis applications of artificial neural networks. Simon & Schuster international group, United States of America.
- 37- Wiles L. 2005. Sampling to make map for site specific weed management. *Weed Sci.* 53: 228- 235.
- 38- Williams II M.M., Gerhards R., Reichtart S., Mortensen D.A., and Martin A.R. 1998. Weed seedling population responses to a method of site-specific weed management. Proceedings of the 4th International Conference on Precision Agriculture, edited by P. C. Robert, R. H. Rust, and W. E. Larson (ASA/CSA/SSA, Madison, Wisconsin, USA). p. 417.
- 39- 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.
- 40- Yang C.C., Prasher S.O., and Landry J.A. 1999. Use of artificial networks to recognize weeds in corn field. *Journe'e d'information Scientifique et Technique en genie agroalimentaire*, Saint-Hyacinthe, QC.
- 41- Yang C.C., Prasher S.O., Landry J.A., and Ramaswamy H.S. 2003. Development of a herbicide application map using artificial neural networks and fuzzy logic. *Agr. Sys.* 76: 561-574.
- 42- Zhan Y.L., Wu H.F., and Huang J.F. 2010. Application of neural networks to discriminate fungal infection levels in rice panicles using hyperspectral reflectance and principal components analysis. *Comput. Electron. Agr.* 72: 99-106 .
- 43- Zhang Y.F., and Fuh J.Y.H. 1998. A neural network approach for early cost estimation of packaging products. *Comput. Engineer.* 34: 433-50.
- 44- 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 Sens. Environ.* 81: 327-336.