

تعیین الگوی توزیع جمعیت علف‌هرز 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 علف‌هرز خارشتر و ترسیم نقشه پراکنش آن با استفاده از شبکه عصبی چندی‌ساز بردار یادگیر (LVQ4) در سطح مزرعه انجام شد. داده‌های مربوط به جمعیت علف‌هرز خارشتر از طریق نمونه‌برداری از ۵۵۰ نقطه از سطح یک مزرعه در حال آیش واقع در مزرعه تحقیقاتی دانشکده کشاورزی دانشگاه صنعتی شاهرود در استان سمنان در سال ۱۳۸۹ بدست آمد. ارزیابی قابلیت شبکه عصبی در پیش‌بینی توزیع مکانی علف‌هرز با مقایسه آماری پارامترهایی مانند میانگین، واریانس، توزیع آماری رگرسیونی بین مقادیر پیش‌بینی شده مکانی توسط شبکه عصبی و مقادیر واقعی آنها و نیز معیار دقت کلاس‌بندی انجام شد. نتایج نشان داد که در فاز آموزش، آزمایش و کل، به ترتیب مقادیر $p \geq 0/7$ ، $p \geq 0/2$ و $p = 1/000$ 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 کلاس بندی، نقشه توزیع مکانی علف هرز خارشتر را در تمام نقاط سطح مزرعه ترسیم نماید. نقشه حاصل از کلاس بندی نشان داد که علف هرز خارشتر دارای توزیع لکه ای است و لذا امکان کنترل متناسب با مکان آن در مزرعه مورد مطالعه وجود دارد.

واژه‌های کلیدی: توزیع لکه ای، کشاورزی دقیق، کلاس بندی، 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 کارایی بیشتری بکار رفته، هزینه‌های مورد نیاز کاهش می‌یابد و سود بیشتری نیز عاید کشاورز خواهد شد (۱۷). گرهاردس و کریستنسن (۱۰)، بیان کردند که کاربرد علفکش‌ها براساس نقشه‌های تهیه شده از جمعیت علف‌های هرز مزارع غلات زمستانه سبب کاهش ۶۰ و ۹۰ درصدی استفاده از علفکش‌ها بترتیب در کنترل پهن برگ‌ها و باریک برگ‌ها گردید. ویلیامز و همکاران (۳۸)، نیز توانستند با استفاده از سیستم کاربرد متناوب 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

(*)- نویسنده مسئول: (Email: abassrohani@yahoo.com)

۲- 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. آیتکنهد و همکاران (۱)، با استفاده از مدل شبکه عصبی پرسپترون چند لایه^۲ (MLP) برای تشخیص و تمایز بین گیاه زراعی هویج، علف هرز چچم و خاک مزرعه استفاده کردند. تمایز بین آفتابگردان، توت^۳ و پس زمینه خاک نیز با استفاده از یک شبکه عصبی MLP توسط کودیر (۲۱) انجام شد. ارماک و همکاران (۱۵) با استفاده از شبکه عصبی مصنوعی الگوهای مکانی عملکرد سویا را در سطح مزرعه پیش بینی 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. درحال حاضر، مطالعات متعددی به منظور پیش بینی 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 گونه ای 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، پیش بینی و طبقه بندی توزیع مکانی علف هرز خارشتر *Alhagi pseudalhagi* (M.B) Desv. با استفاده از شبکه عصبی چند لایه بردار یادگیر (LVQ4) 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 شاهرود واقع در استان سمنان انجام شد. طول و عرض جغرافیایی محل به ترتیب ۵۴° و ۵۸° شمالی و ۳۶° و ۲۵° شرقی

مدیریت متناسب با مکان، میزان علفکش ورودی به مزرعه ذرت را ۱۲ تا ۱۵ درصد کاهش دهند. تعیین نقشه آلودگی علف‌های هرز نه تنها برای کاربرد متناسب با مکان علف کش‌ها 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 و دقت روش‌های درون یابی و تهیه نقشه‌های کاربردی از جمعیت علف‌های هرز است. گوئل و همکاران (۱۲) تهیه نقشه‌های دقیق و آنالیز آن را از راه‌های کلیدی در کشاورزی دقیق می‌دانند. به هر حال یکی از نارسایی‌های روش‌های متداول 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 فایده آمدن به این نارسایی‌ها استفاده از روش‌های کلاس بندی و تهیه نقشه بوسیله مدل شبکه عصبی مصنوعی چند لایه ساز بردار یادگیر^۱ (LVQ4) می‌باشد. امروز شبکه‌های عصبی در بسیاری از زمینه‌ها از جمله طبقه بندی، تشخیص الگو، پیش بینی 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 مجموعه ای از ورودی‌ها و خروجی‌ها برای پیش بینی 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 طبقه بندی کننده در مقایسه با روش‌های آماری دارای مزایای بیشتری است (۱۲). بعضی از مشکلات طبقه بندی که از نظر کاربرد در کشاورزی خود را نشان داده اند بوسیله شبکه عصبی مصنوعی با موفقیت بر طرف شده اند (۴۰). امروزه شبکه‌های عصبی می‌توانند آموزش ببینند 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

2- Multi layer perceptron

3- Xanthium strumarium

1- Learning Vector Quantization Neural Network

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

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


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

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

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

$0 < \varepsilon < 1$ و $\lambda \geq 1$ می باشد. 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 آستانه های مختلف (صفر، ۲ و ۴ بوته در هر متر مربع) به منظور از بین بردن علف های هرز بالاتر از حد آستانه به کمک روش های مدیریتی معمول است. کلاس اول نقاطی از مزرعه که دارای علف هرز هستند و نقاط دیگری که فاقد علف هرز می باشند. به طور کاملاً تصادفی، ۸۰ درصد از کل داده ها 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 تراکم های مختلف در شکل ۱ نشان داده شده است. ورودی های شبکه مختصات مکانی علف های هرز می باشند 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 پیش بینی مکانی وجود علف هرز. (X, Y) مختصات نقاط نمونه برداری شده، W ماتریس بردارهای کد و W_{win} برچسب بردار کد برنده شده.

و ارتفاع محل از سطح دریا ۱۳۴۹/۱ متر می باشد. میانگین بارندگی سالیانه منطقه ۱۵۰ میلی متر، میانگین سالانه دما ۱۴/۴ درجه سانتی گراد می باشد. داده های مورد استفاده از مزرعه ای به ابعاد 200×100 متر (۲۰۰۰ مترمربع) و در حال آیش در مرداد ماه جمع آوری شد. علف هرز خارشتر یکی از گونه های با تراکم بالا در این مزرعه بود. بنابراین در این پژوهش توزیع جمعیت این علف هرز مورد مطالعه قرار گرفت. نمونه برداری از جمعیت علف هرز خارشتر بر روی یک شبکه علامت گذاری شده مربعی^۱ به ابعاد 2×2 متر انجام و در مجموع از ۵۵۰ نقطه در مزرعه نمونه برداری انجام شد. نمونه برداری از جمعیت علف هرز با استفاده از کوادراتی به ابعاد 50×10 سانتی متر (مساحت ۵/ مترمربع) در محل تقاطع خطوط شبکه مربعی و بصورت غیرتصادفی انجام شد. بطوریکه در هر کوادرات جمعیت علف هرز خارشتر شناسایی و شمارش شد. سپس داده ها در مدل مورد استفاده قرار گرفت.

شبکه عصبی چندی ساز بردار یادگیر (LVQ4)

شبکه عصبی LVQ4 یکی از روش های طبقه بندی و خوشه بندی است. نحوی کار آن بر اساس تقسیم فضای ورودی R^n به تعدادی منطقه های متمایز از هم با نام ناحیه های تصمیم گیری^۲ و اختصاص یک بردار کد^۳ به هر یک از آنها است. کلاس بندی بر حسب نزدیکی بردار ورودی x به بردارهای کد انجام می شود. بردار ورودی متعلق به کلاس نزدیکترین بردار کد خواهد شد. الگوریتم تا وقتی که ناحیه های تصمیم گیری و مرکزهای آنها ثابت نشود ادامه خواهد یافت. از بین شش گونه الگوریتم آموزش با نام های LVQ1، LVQ2.1، LVQ3، LVQ4 (۲۲، ۲۳) و LVQ4 (۳۴، ۳۵) از الگوریتم آموزش LVQ4 به جهت بالا بودن کارایی آن استفاده شد.

الگوریتم آموزش شبکه عصبی LVQ4

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

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

$$w_m \in \mathcal{R}^n, \quad m=1, \dots, M$$

و w_m بردار کد باشد پیدا کردن نزدیکترین بردار کد به x^q :

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

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

$\alpha(n)$ 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 در مورد 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 ۰/۰۵ باشد، فرضیه صفر را نمی توان رد کرد. به ترتیب برای مقایسه میانگین، واریانس و توزیع آماری از آزمون F ، t 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 $p > 0/2$). بنابراین شبکه عصبی مصنوعی LVQ4 دارای قابلیت بالایی برای پیش بینی الگوی پراکنش علف هرز خارشتر می باشد. وجود $p = 1/1000$ در مورد توزیع آماری بین مقادیر پیش بینی شده و مقادیر واقعی تراکم علف هرز در سطح مزرعه بویژه در فاز آزمایش شبکه، 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 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 ($WD_1 = 0, WD_2 > 0$)، سطح مزرعه با تراکم کمتر یا مساوی ۲ بوته در هر متر مربع و بیشتر از آن ($WD_1 \leq 2, WD_2 > 2$) و سطح مزرعه با تراکم کمتر یا مساوی ۴ بوته در هر متر مربع و بیشتر از آن ($WD_1 \leq 4, WD_2 > 4$) 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 (۰/۹۱-۰/۰۰ 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 آزمایش (%)
$WD_2 > 0, WD_1 = 0$	۴۵۳	۹۷	۰/۴۵	۰/۰۰
$WD_2 > 2, WD_1 = 2$	۵۱۶	۳۴	۰/۶۸	۰/۹۱
$WD_2 > 4, WD_1 \leq 4$	۵۲۹	۱۱	۰/۲۳	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
$WD_2 > 0, WD_1 = 0$	فاز آموزش	۱/۰۰۰	۱/۰۰۰	۱/۰۰۰
	فاز آزمایش	۱/۰۰۰	۱/۰۰۰	۱/۰۰۰
$WD_2 > 2, WD_1 = 2$	فاز آموزش	۰/۶۶۶	۰/۲۴۷	۱/۰۰۰
	فاز آزمایش	۰/۷۹۰	۰/۵۱۹	۱/۰۰۰
$WD_2 > 4, WD_1 \leq 4$	فاز آموزش	۰/۸۰۷	۰/۲۲۷	۱/۰۰۰
	فاز آزمایش	۱/۰۰۰	۱/۰۰۰	۱/۰۰۰

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

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 می آید 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 شیب نزدیک به یک باشد ($p_v = 1/0.000 \cdot d_v + 0/0.000$). 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 شیب‌های نزدیک به واحد و عرض از مبداهای کوچکی هستند، بنابراین می‌توان به چنین شبکه‌هایی اطمینان کرد. این نتایج نشان می‌دهند که قابلیت تعمیم‌پذیری 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 شیب نزدیکتر به واحد و عرض از


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، 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 ($q = 2, 2, 4$)، خطا 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 نخواهند شد. لذا ادامه آموزش بی فایده 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 تعمیم‌پذیر بالایی نیز برخوردار باشد.

جدول ۳- رابطه خطی رگرسیونی و ضریب تبیین بین d_v و p_v

R^2	رابطه خطی رگرسیونی	مرحله بکارگیری شبکه	هدف شبکه برای طبقه بندی
۰/۹۶۹	$p_v = 0/984 \cdot d_v + 0/018$	فاز آموزش	$WD_2 > 0, WD_1 = 0$
۰/۹۹۹	$p_v = 1/000 \cdot d_v + 0/000$	فاز آزمایش	
۰/۸۸۲	$p_v = 0/888 \cdot d_v + 0/111$	فاز آموزش	$WD_2 > 2, WD_1 = 2$
۰/۸۶۶	$p_v = 0/990 \cdot d_v + 0/019$	فاز آزمایش	
۰/۸۸۷	$p_v = 0/889 \cdot d_v + 0/111$	فاز آموزش	$WD_2 > 4, WD_1 \leq 4$
۰/۹۹۹	$p_v = 1/000 \cdot d_v + 0/000$	فاز آزمایش	

توضیحات: d_v : مقادیر واقعی داده‌ها p_v : مقادیر پیش بینی شده توسط مدل. WD_1 و WD_2 : 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 WDC حد آستانه فرضی

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 پیش بینی 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 پیش تر با مقایسات آماری، خطای تشخیص و معادله رگرسیونی مابین مقادیر واقعی و پیش بینی شده به عدم وجود تفاوت معنی دار بین آنها دست پیدا کردیم ولی با مقایسه بین نقشه حاصل از داده‌های واقعی و داده‌های پیش بینی شده توسط شبکه عصبی LVQ4 متوجه خواهیم شد که تفاوت چندانی 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 کارایی یک مدل نمی‌توان تنها با مقایسه یک یا چند نقطه قضاوت کرد (۴۳). واضح است که نقاط دارای تراکم بیشتر از حد آستانه مورد نظر در مدیریت متناسب 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 علف‌هرز تعریف شده که در آن هزینه کنترل علف‌هرز 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 دانه ای را در اثر رقابت با علف‌های هرز باریک برگ یکساله بصورت موضعی 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 باشد، برای استفاده عملی از آن، نقشه‌های تهیه شده با شبکه عصبی LVQ4 ابزارهای موثر و دقیقی خواهد بود که به مدیر مزرعه جهت کنترل متناسب 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 نا همگون و تجمعی علف هرز خارشتر در این شکل‌ها به خوبی

مشهود است. به نظر می‌رسد با استفاده از روش‌های مدیریت متناسب 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 سم صرفه جویی نمود، آلودگی‌های زیست محیطی را کاهش داده و نیز کنترل موثرتری را برای این علف هرز انجام داد. به اعتقاد کولر و لاینی (۲۴) ترسیم نقشه‌های دقیق، اختصاصی و به موقع علف‌های هرز کلید دستیابی به تمام مزایای مدیریت متناسب 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، چرای حیوانات، فعالیت‌های زارعین و عوامل محیطی در سطح مزرعه جابجا می‌شوند (۳۱).

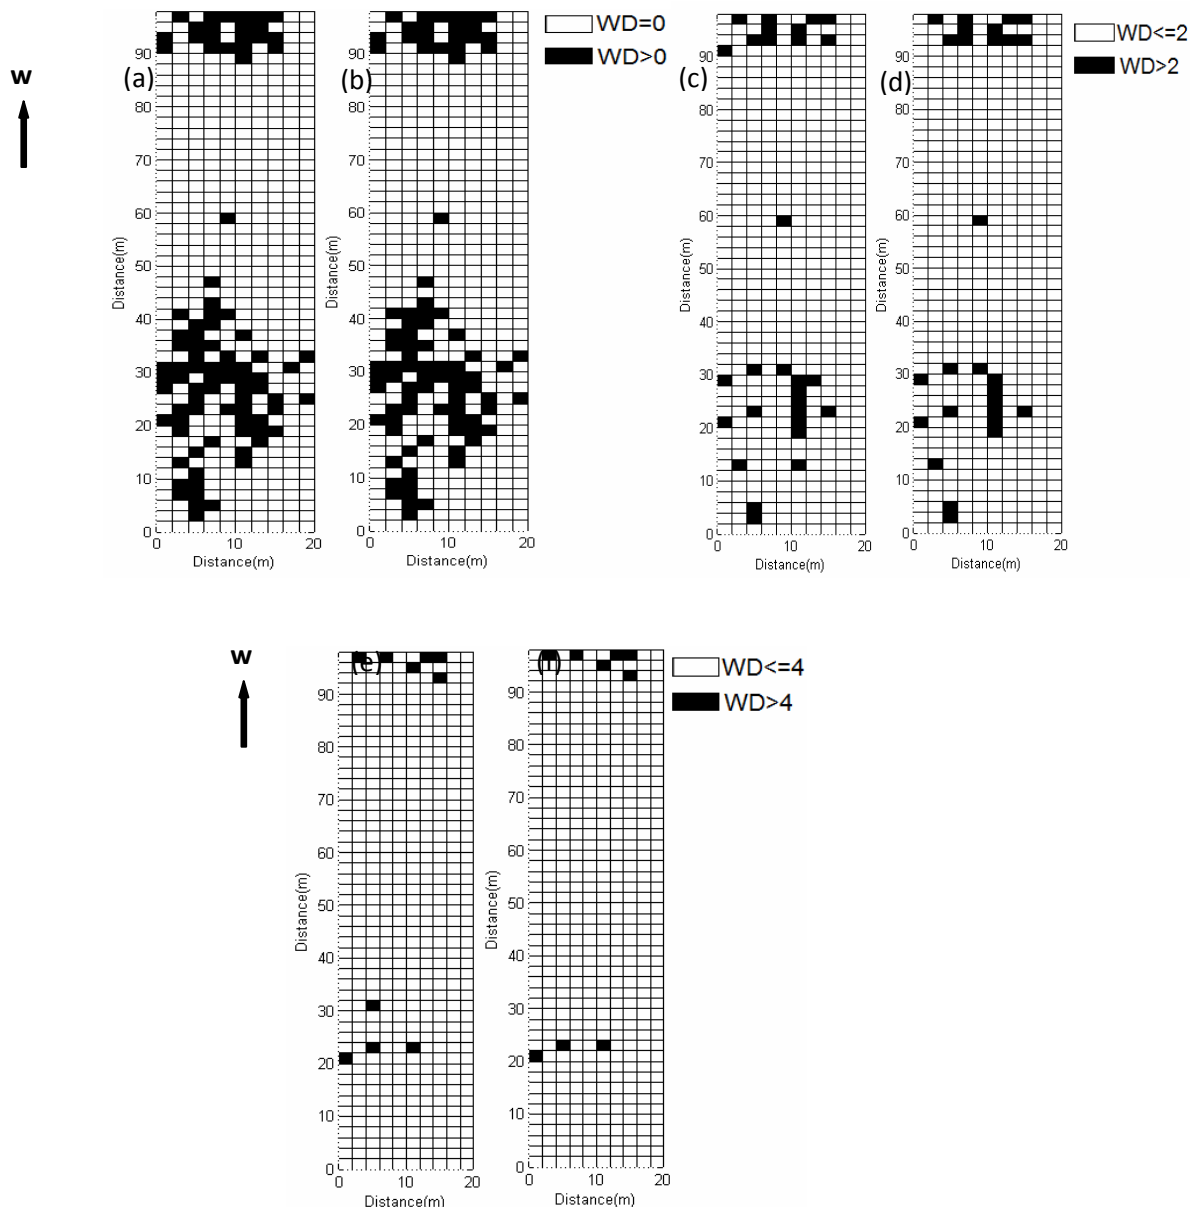
علف هرز خارشتر گیاهی چندساله از خانواده بقولات^۱ است که قادر به تکثیر از طریق بذر می‌باشد، اما این گیاه عمدتاً از طریق پراکنش قطعات ریشه بوسیله عوامل گوناگون تکثیر می‌شود (۲۸). بذور علف هرز خارشتر مکانیسم پراکنش خاصی ندارد و از طرفی چون اغلب عواملی مانند شخم با گاوآهن، دیسک و سایر عملیات مدیریتی سبب قطعه قطعه شدن ریشه‌های این گیاه و جابجایی آن در فاصله اندک از گیاه مادری می‌شوند لذا پراکنش جمعیت این علف هرز بصورت لکه ای است. وجود توزیع لکه ای در علف‌های هرز چند ساله ای نظیر خارلته^۲، قیاق^۳ که بوسیله اندام‌های رویشی زیر زمینی تکثیر می‌شوند نیز گزارش شده است (۶). گرهاردس و همکاران (۱۰) بیشترین پایداری لکه‌ها را متعلق به چند ساله‌ها می‌دانند. گوسلی و همکاران (۱۳) با استفاده از مدل‌های شبیه سازی، 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 لکه ای ظاهر می‌شود، به گفته همین محققین برهمکنش 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 لکه ای تلخه، امکان کنترل نقاط آلوده به این علف هرز و کاهش میزان سم مصرفی و هزینه‌های کنترل وجود دارد. کولباخ و همکاران (۸) نیز بیان کردند که پایداری لکه‌ها در بین گونه‌های مختلف علف هرز

1 - Fabaceae

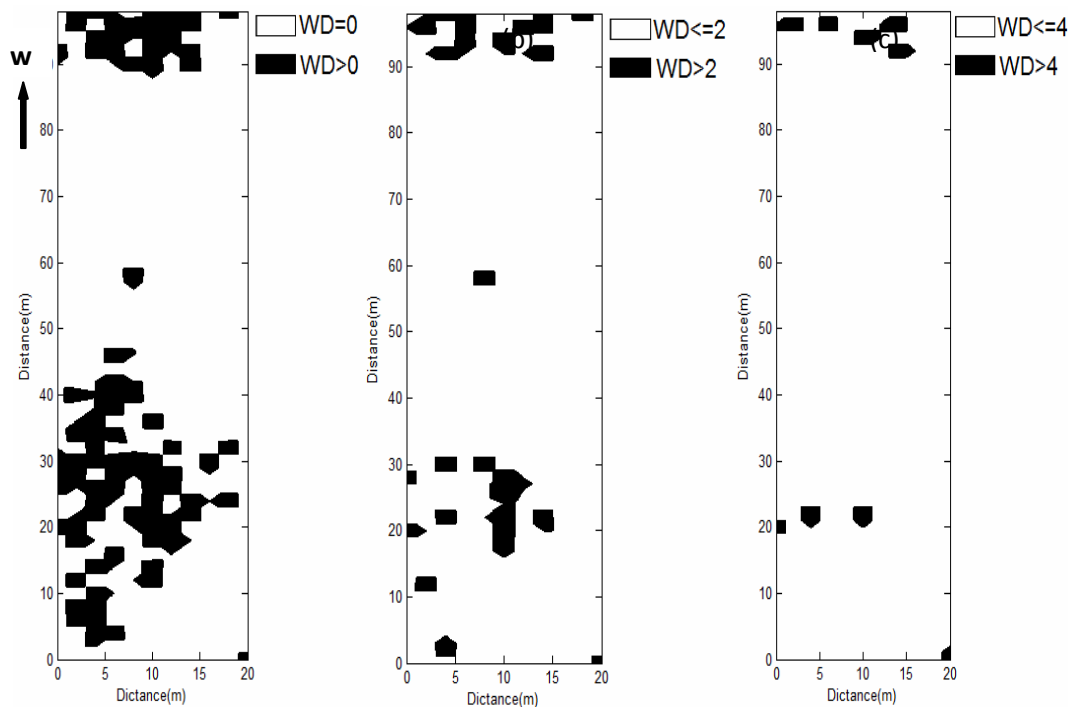
2 - *Cirsium arvense* L.3 - *Sorghum halepense* L.4 - *Acroptilon repens* L.

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 اشتباه سبب مصرف بیش از حد نیاز علفکش و آلودگی‌های زیست محیطی خواهند شد.

متفاوت است. لف های هرزی که حالت لکه‌ای بودن و پایداری بیشتری دارند برای مدیریت متناسب با مکان مناسبند. به هر حال، تراوای داکار و همکاران (۳۳) دریافته‌اند که علی‌رغم اینکه عملکرد ذرت در شرایط مصرف علف کش به صورت کاربرد متناسب با مکان و کاربرد سراسری، مشابه بوده است ولی از طریق مدیریت متناسب با مکان، مصرف آترزین ۳۲ و دایکامبا ۴۵ درصد کاهش یافت. در این



شکل ۳- نقشه توزیع جمعیت علف هرز خارشتر در دو حالت واقعی (شکل‌های a، c، e) و تفکیک شده توسط مدل شبکه عصبی LVQ4 (شکل‌های b، d، f). WD: تراکم علف هرز (Weed Density). شکل‌های (b و a) نقاطی از مزرعه که فاقد علف هرز و یا دارای علف هرز هستند. شکل‌های (d و c) 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. شکل‌های a، b و c بر ترتیب بر اساس حد آستانه‌های فرضی صفر، ۲ و ۴ بوته خارشتر در مترمربع ترسیم شده اند.

حاصل از شبکه نشان داد که خارشتر دارای آرایش لکه ای است. بنابراین به نظر می‌رسد از طریق تیمار کردن لکه‌های دارای علف هرز می‌توان به اهداف مدیریت متناسب با مکان و کاهش علفکش‌های 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 یافته‌های زان و همکاران (۴۲) شبکه عصبی می‌تواند بر اساس هر آستانه تعیین شده نقشه‌های مدیریتی برای اعمال تیمار نقاط بالای حدآستانه 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 ve'ge'tales du Que'bec, 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](http://www.Isprs.org).
- 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. *Trans. of the Americ. Soc. of Agri. and Biol. Engin. (ASABE)*. 48 :1261–1268.
- 20- Kaul M., Hill R.L., and Walthall 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*, Spriger-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- ODonovan 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 management 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., Reichart 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. *Journé 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.