

تهیه نقشه‌های مدیریتی علف هرز با استفاده از شبکه‌های عصبی مصنوعی با هدف کاربرد در کشاورزی دقیق

عباس روحانی^{*۱} - حسن مکاریان^۲

تاریخ دریافت: ۱۳۸۹/۱۲/۲۱

تاریخ پذیرش: ۱۳۹۰/۷/۴

چکیده

با پدید آمدن تکنیک‌های آماری قوی و شبکه‌های عصبی، مدل‌های پیش‌بینی کننده پراکنش موجودات به سرعت در اکولوژی توسعه پیدا کرده است. این پژوهش به منظور پیش‌بینی و ترسیم نقشه توزیع جمعیت علف هرز تلخه با استفاده از شبکه‌های عصبی چندی ساز بردار یادگیر (LVQ) و پرسپترون چندلایه (MLP) در سطح مزرعه انجام شد. داده‌های مربوط به جمعیت علف هرز از طریق نمونه برداری 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. برای ارزیابی قابلیت شبکه‌های عصبی مورد استفاده در پیش‌بینی مکانی علف هرز از مقایسه آماری پارامترهایی مانند میانگین، واریانس، توزیع آماری و ضریب تبیین رگرسیونی خطی بین مقادیر پیش‌بینی شده مکانی توسط شبکه عصبی و مقادیر واقعی آن‌ها و نیز معیار دقت طبقه بندی استفاده شد. نتایج نشان داد که در فازهای آموزش و آزمایش بین مقادیر ویژگی‌های آماری میانگین، واریانس و توزیع آماری مجموعه داده‌های واقعی و پیش‌بینی شده مکانی علف هرز توسط شبکه عصبی LVQ تفاوت معنی داری وجود نداشت، ولی برای شبکه عصبی MLP این مقایسات بجز توزیع آماری معنی دار شدند. همچنین نتایج نشان داد که شبکه عصبی آموزش دیده LVQ ، دارای قابلیت بالایی در پیش‌بینی مکانی علف هرز در نقاط نمونه برداری نشده با خطای تشخیص کمتر از ۰/۶۴ درصد بود. درحالیکه شبکه عصبی مصنوعی MLP دارای خطای تشخیص کمتر از ۱۴/۶ درصد بود. نقشه‌های ترسیم شده نشان داد که توزیع لکه ای علف هرز امکان کنترل متناسب با مکان را در مزرعه مورد مطالعه امکان پذیر می‌سازد.

واژه های کلیدی: توزیع مکانی، طبقه بندی، مدیریت متناسب با مکان، شبکه عصبی

مقدمه

(مکان‌های) مشابه تفکیک شده و پس از تشخیص خصوصیات هر یک از این واحدها، مدیران مزرعه نهاده‌ها را برای هر واحد و بر اساس مقدار مورد نیاز جهت دستیابی به حداکثر بازده اقتصادی بکار می‌برند (*Cardina and Doohan, 2008*). جمع آوری اطلاعات و تهیه نقشه در سامانه مدیریت متناسب با مکان محوری ترین مسئله است (*Grundy et al, 2005*); زیرا عملگرها در فناوری نرخ متغیر بر اساس نقشه‌های تهیه شده تیمارها را اعمال می‌کند (*Shaw, 2005*) علف‌های هرز یکی از عوامل کاهش دهنده عملکرد محصولات کشاورزی در مزارع به حساب می‌آیند، بنابراین کنترل علف‌های هرز یکی از مهمترین جنبه‌های تولید در هر نظام کشاورزی است (*Rashed Mohassel et al, 2001*). در حال حاضر کنترل علف‌های هرز اغلب از طریق کاربرد یکنواخت علفکش‌ها در تمام سطح مزرعه انجام می‌شود. اما واقعیت این است که علف‌های هرز در سطح مزارع بصورت لکه ای ظاهر می‌شوند (*Heijeting et al, 2007*). از طرفی امروزه سیستم‌های کشاورزی وابسته به مواد

کشاورزی دقیق، جدید ترین فناوری در عرصه کشاورزی می باشد که بر اساس سه اصل افزایش عملکرد، افزایش بهره اقتصادی و کاهش اثرات سوء زیست محیطی دنبال می شود. مهمترین محور کشاورزی دقیق شناخت دقیق مزرعه و تمام نقاط زمین زراعی است، به طوری که بتوان زمین زراعی را آسیب شناسی کرد و در جهت مدیریت متناسب با شرایط نقاط مختلف زمین گام برداشت. اگرچه کشاورزان تغییرات موجود در قسمت‌های مختلف مزرعه را تشخیص می‌دهند اما ابزارآلات در دسترس اجازه مدیریت متناسب با مکان را به آن‌ها نمی‌دهد (*Searcy, 2008*). کشاورزی دقیق ابزارهای توانا برای افزایش کارایی مدیریت مزرعه به ارمغان آورده است. در این رهیافت با به خدمت گرفتن فن آوری اطلاعات، مزرعه به چندین واحد

۱ و ۲- استادیاران دانشکده کشاورزی، دانشگاه صنعتی شاهرود

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

(2000)، ارزیابی کیفیت آب (Zhang et al, 2002)، تخمین بیوماس (Drummond et al, 1997) و تخمین عملکرد (Jin and Liu, 2003) 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. (Irmak et al, 2006) 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. علف هرز تلخه گونه چندساله ای است که بخش وسیعی از اراضی زراعی و غیر زراعی ایران را مورد تهاجم قرار داده است و هر ساله خسارت قابل توجهی را به کشاورزان وارد می‌کند (Rashed Mohassel et al, 2001). در حال حاضر، مطالعات متعددی به منظور پیش بینی، طبقه بندی و تهیه نقشه‌های دقیق پوشش‌های گیاهی، تغییرات بیوماس، 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، مقایسه قابلیت مدل‌های شبکه عصبی پرسپترون چند لایه (MLP) و چندی ساز بردار یادگیر (LVQ4) در پیش بینی، طبقه بندی و ترسیم نقشه‌های توزیع مکانی علف هرز تلخه (*Acroptilon repens L.*) در نقاط نمونه برداری نشده بر اساس داده‌های حاصل از نقاط نمونه برداری شده در یک مزرعه در حال آیش است.

مواد و روش‌ها

آزمایش در سال ۱۳۸۹ در مزرعه دانشکده کشاورزی دانشگاه صنعتی شاهرود واقع در استان سمنان انجام شد. طول و عرض جغرافیایی محل به ترتیب ۵۴' و ۵۷' شمالی و ۳۶' و ۲۵' شرقی و ارتفاع محل از سطح دریا ۱۳۴۹/۱ متر می‌باشد. میانگین بارندگی سالانه منطقه ۱۵۰ میلی متر، میانگین سالانه دما ۱۴/۴ درجه سانتی‌گراد می‌باشد. داده‌های مورد استفاده از مزرعه ای به ابعاد ۲۰×۱۰۰ متر (۲۰۰۰ مترمربع) و در حال آیش در مرداد ماه جمع آوری شد. علف هرز تلخه یکی از گونه‌های 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 تلخه بر روی یک شبکه علامت گذاری شده مربعی^۱ به ابعاد ۲×۲ 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 ۵۰×۱۰۰ سانتی متر (مساحت ۵/ مترمربع) در محل تقاطع خطوط شبکه مربعی انجام شد. به طوری که در هر کوادرات جمعیت علف هرز تلخه شناسایی و شمارش شد،

شیمیایی به دلیل نگرانی ناشی از آلودگی‌های زیست محیطی، سلامت انسان و افزایش هزینه‌های اقتصادی کشاورز بطور فزاینده ای مورد بازنگری واقع شده اند. در این راستا مطالعات نشان داده است که پیش بینی گسترش لکه‌های علف هرز و سمپاشی لکه ای نسبت به سمپاشی سراسری سبب کاهش مصرف علف کش‌ها و آلودگی محیط شده و از نظر اقتصادی نیز برای زارعین سودمند می‌باشد (Jurado-Exposito et al, 2004). به عنوان مثال، در بررسی کنترل لکه ای علف‌های هرز گندم در یک دوره پنج ساله نشان داده شد که ۳۹ درصد کل سطح مزرعه برای کنترل علف‌های هرز باریک برگ و ۴۴ درصد آن برای کنترل علف‌های هرز پهن برگ نیاز به سمپاشی دارد (Nordmeyer, 2006). پیش بینی و تهیه نقشه‌های دقیق توزیع علف‌های هرز به منظور کاربرد در مدیریت لکه ای با روش‌های مختلفی مورد ارزیابی قرار گرفته است (Cardina and Doohan, 2008). امروزه شبکه‌های عصبی در بسیاری از زمینه‌ها از جمله طبقه بندی، تشخیص الگو، پیش بینی و مدل سازی فرآیندها در علوم مختلف بکار گرفته می‌شوند. مزیت روش شبکه عصبی یادگیری مستقیم از روی داده‌ها، بدون نیاز به برآورد مشخصات آماری آن‌ها 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 می باشد (Kaul et al, 2005; Torrecilla et al, 2004). ویژگی دیگر شبکه عصبی، تحمل پذیری در مقابل خطا می‌باشد (Azadeh et al, 2006). این مزایا دلایل بکارگیری شبکه عصبی در پیش بینی تراکم علف‌های هرز را برای ما روشن می سازد. شبکه‌های عصبی شامل تعدادی نرون‌های متصل بهم هستند. مراحل اصلی حل هر مسئله توسط شبکه عصبی شامل آموزش و آزمایش می‌باشد. آموزش، فرآیند یادگیری مجموعه داده‌های ورودی به منظور تشخیص الگوهای آن توسط شبکه می‌باشد. روش آموزش را قانون یادگیری گویند و اتصالات وزنی بین نرون‌ها از طریق قانون یادگیری در طول فاز آموزش اصلاح می‌شوند. آزمایش، ارزیابی قابلیت تعمیم پذیری و شایستگی شبکه آموزش دیده در شرایط کاملاً جدید توسط مجموعه داده‌های غیر از داده‌های آموزش گویند (Veelenturf, 1995; Gupta et al, 2003). امروزه مدل‌های شبکه عصبی بعنوان ابزارهای شناخته شده ای برای تخمین توابع در تحقیقات اکولوژیکی و محیطی به‌شمار می‌روند (Zhang et al, 2008) و می‌تواند با دقت بالا جمعیت علف هرز را از گیاه زراعی در مزارع متمایز کنند (Yang et al, 2003) گرچه با استفاده از این مدل‌ها توانسته اند روابط غیر خطی پیچیده و مرکب را با استفاده از تصاویر تهیه شده از شاخساره برای چند گیاه زراعی تشریح نمایند، اما این تکنیک در پیش بینی متغیرهای پیوسته ای مانند رطوبت خاک (Chang and Islam,

سپس داده‌ها در مدل مورد استفاده قرار گرفت.

پیش پردازش داده‌ها

در ابتدا داده‌های موجود بطور تصادفی به دو دسته مجموعه آموزش ۸۰ درصد کل داده‌ها و مجموعه آزمایش ۲۰ درصد کل داده‌ها تقسیم‌بندی شد. البته اگر این تقسیم‌بندی منجر به نتایج مطلوب نشود، می‌توان این مرحله را مجدداً تکرار کرد (Zhang and Fuh, 1998). قبل از بکارگیری داده‌های خام اولیه در آموزش و آزمایش شبکه باید نرمالیزه شود، زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد مناسبی داشته باشد و همچنین بدلیل دامنه تغییرات خروجی تابع فعالیت سیگموئیدی^۱ [۰، ۱] بکارگرفته شده در لایه میانی این امر ضروری به نظر می‌رسد. در غیر اینصورت شبکه در طول فاز آموزش همگرا نخواهد شد و نتایج مطلوب تولید نخواهد شد (Azadeh et al, 2006). زمانیکه از تابع فعالیت سیگموئیدی استفاده می‌شود، بهترین دامنه تبدیل داده‌ها [۰/۱، ۰/۹] می‌باشد (Vakil-Baghmisheh, 2002). برای تبدیل داده‌ها از نرمالیزاسیون خطی (معادله ۱) استفاده شد:

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

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

از شبکه‌های عصبی MLP و LVQ با هدف طبقه بندی سطح مزرعه به دو کلاس برای سه حالت مختلف استفاده شد. حالت اول برای زمانی است که مزرعه را به دو منطقه وجود علف هرز و یا عدم وجود علف هرز و به ترتیب حالت دوم و سوم برای زمانی است که تراکم علف هرز برای نقاطی از مزرعه کوچکتر یا مساوی و یا بزرگتر از ۲ و ۴ بوته در هر متر مربع می‌باشد. کلاس اول برای حالت اول، دوم و سوم به ترتیب شامل ۴۷۲، ۵۱۲ و ۵۲۷ نقطه نمونه برداری شده و کلاس دوم برای حالت اول، دوم و سوم به ترتیب شامل ۷۸، ۳۸ و ۲۳ نقطه نمونه برداری شده می‌باشد. به طور کاملاً تصادفی، ۸۰ درصد از کل داده‌ها برای آموزش شبکه و ۲۰ درصد باقی مانده برای آزمایش شبکه به منظور طبقه بندی انتخاب شد.

شبکه عصبی پرسپترون چندلایه (MLP)

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 ($q=1, \dots, Q$) تولید خواهد کرد. هدف اتخاذ پارامترهای

صحیح شبکه به منظور دستیابی به خروجی واقعی Z^q که تا جای 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^*) به عنوان یک الگوریتم رایج در آموزش شبکه MLP شامل سهولت در تنظیم پارامترهای یادگیری شبکه، کاهش زمان یادگیری و بهبود رفتار شبکه در طول آموزش می‌باشد.

الگوریتم $BDLRF^*$: این الگوریتم نسخه اصلاح شده الگوریتم پس انتشار اصلی می‌باشد (Vakil-Baghmisheh and Pavešić, 2001) این الگوریتم آموزش با آهنگ یادگیری (η) و عامل ممتنوم (α) ثابت و نسبتاً بزرگ شروع می‌کند و قبل از آنکه شبکه ناپایدار و یا همگرایی آن کند شود، هر T تکرار ($3 \leq T \leq 5$) آهنگ یادگیری و فاکتور ممتنوم را از طریق تصاعد حسابی بصورت یکنواخت کاهش داده می‌شود تا زمانی که این پارامترها به x درصد (۵٪) مقادیر اولیه خودشان برسند. η و بطور مشابه α با استفاده از فرمول (معادله ۲) کاهش داده شد:

$$\eta_n = \eta_0 + (x-1) \frac{\eta_0 T}{Q - n} \quad (2)$$

در اینجا n_1 ، n و l به ترتیب نقطه شروع $BDLRF$ ، آهنگ یادگیری در n امین جمله از تصاعد حسابی و مقدار اولیه آهنگ یادگیری می‌باشند.

تابع هزینه بکار رفته در این الگوریتم مجموع کل مربعات خطا ($TSSE^*$) می‌باشد و بصورت زیر محاسبه می‌شود:

$$TSSE = \sum_q \sum_k (d_k^q - z_k^q)^2, \quad q = 1, \dots, Q \quad (3)$$

d_k^q و z_k^q به ترتیب k امین عنصر از بردارهای خروجی مطلوب و واقعی از q امین ورودی است. یادگیری شبکه در دو فاز پیش انتشار و پس انتشار اتفاق می‌افتد. وزن‌های هر لایه از شبکه از طریق زیر محاسبه می‌شوند.

$$k = 1, \dots, l_3, \quad j = 1, \dots, l_2, \quad i = 1, \dots, l_1 \quad (4)$$

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


$$w_{ij}(n+1) = w_{ij}(n) - \eta \times \frac{\partial E}{\partial w_{ij}} + \alpha (w_{ij}(n) - w_{ij}(n-1)) \quad (5)$$

2- Backpropagation with declining learning-rate factor

3 - Basic backpropagation

4 - Total sum-squared error

1 - Sigmoid transfer function



شکل ۱. ساختار شبکه MLP با یک لایه مخفی (وکیل - باغمیشه ۲۰۰۲)

Fig. 1. Configuration of the MLP with one hidden layer.

پیدا کردن نزدیکترین بردار کد به \mathbf{x}^q :

$$\mathbf{c} = \arg \min_m (\|\mathbf{x}^q - \mathbf{w}_m\|) \quad (6)$$

تنظیم w_c :

$$\mathbf{w}_c(t+1) = \mathbf{w}_c(t) + \alpha(n)s(n)[\mathbf{x}^q - \mathbf{w}_c(t)] \quad (7)$$

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

$$\alpha(n) = \begin{cases} k_1 & \text{if } q \leq q_c \\ k_2 \exp\left(-\frac{q-q_c}{\tau}\right) & \text{if } q > q_c \end{cases}, 0 < \alpha(n) < 1 \quad (8)$$

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

$$d_c(n) = \frac{E_c(n)}{P_c(n)} \quad (9)$$

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

$$d_c(n) = \begin{cases} \varepsilon & \text{if } q = 1 \\ \lambda & \text{if } q \geq 2, P_c(n-1) \neq 0 \\ \lambda & \text{if } q \geq 2, P_c(n-1) = 0 \end{cases} \quad (10)$$

$0 < \lambda < 1$ و $\varepsilon \geq 1$ می باشد. مقادیر توصیه شده $\varepsilon = 10$ و $\lambda = 0.2$

□ است (Vakil-Baghmisheh and Pavešic, 2003)

ساختار شبکه عصبی LVQ استفاده شده به منظور طبقه بندی سطح مزرعه به دو منطقه یا طبقه بندی بر مبنی تراکم های مختلف، در شکل ۲ 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 مدل های شبکه عصبی در محیط نرم افزار Matlab نسخه ۷ انجام شد.

در اینجا w_{ij} اتصال وزنی بین گره های i و j و u_{jk} اتصال وزنی بین گره های j و k ، مقادیر اولیه این وزن ها بطور تصادفی از دامنه مقادیر $[-0.25, 0.25]$ انتخاب می شود. l_2 و l_3 به ترتیب تعداد نرون ها در لایه مخفی و لایه خروجی می باشند. α و η به ترتیب آهنگ یادگیری و فاکتور منتوم هستند و مقادیر آن ها در فاصله $[0, 1]$ قرار دارند و n شماره تکرار الگوریتم ($n = 1, \dots, N$). زمانی الگوریتم متوقف می شود که $TSSE$ کوچکتر از مقدار آستانه باشد. جزئیات بیشتر این الگوریتم را می توان در پژوهش Vakil-Baghmisheh and Pavešic (2003) مشاهده کرد.

شبکه عصبی LVQ

نحوی کار شبکه عصبی LVQ بر اساس تقسیم فضای ورودی \mathcal{R}^n به تعدادی منطقه های متمایز از هم با نام ناحیه های تصمیم گیری ۱ و اختصاص یک بردار کد ۲ به هر یک از آن ها است. طبقه بندی بر حسب نزدیکی بردار ورودی \mathbf{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 آن ها ثابت نشود، ادامه خواهد یافت. LVQ1, LVQ2.1, LVQ3, LVQ4 (Kohonen, 1990; Kohonen, 1995) و (Vakil-LVQ4) (Vakil-Baghmisheh and Pavešic, 2002; Vakil-Baghmisheh and Pavešic, 2003) از الگوریتم آموزش LVQ4 به جهت بالا بودن کارایی آن استفاده شد.

الگوریتم آموزش LVQ4

فرض شود \mathbf{x}^q بردار ورودی از مجموعه آموزش باشد:

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

و بردار کد باشد


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

1 - Decision regions (Voronoi cells)

2 - Codebook (Voronoi) vector

ظاهر می‌شوند. لذا به نظر می‌رسد که تفاوت عملکرد مدل‌های شبکه عصبی به دلیل ماهیت متفاوت علف‌های هرز و حشرات باشد. علاوه بر این زمان یادگیری شبکه عصبی *MLP* بسیار بیشتر از شبکه عصبی *LVQ* بود، زیرا به ترتیب حداکثر و حداقل تعداد تکرارهای الگوریتم در شبکه‌های عصبی *MLP* و *LVQ* جهت یادگیری الگوی پراکنش علف هرز، ۱۰ تکرار و ۱۰۰۰ تکرار بود.

برای اطمینان از یادگیری شبکه‌های عصبی آموزش دیده برای پیش‌بینی الگوی پراکنش علف هرز تلخه، داده‌های واقعی و داده‌های پیش‌بینی 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. 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 طبقه بندی در جدول ۲ نشان داده شده است. نتایج نشان می‌دهد که میانگین، واریانس و توزیع آماری مقادیر واقعی و پیش‌بینی شده در هر مورد طبقه بندی به کمک شبکه عصبی *LVQ*، اختلاف معنی‌داری با هم ندارند (در تمام موارد $p > 0.05$). ولی نتایج مقایسات آماری برای شبکه عصبی *MLP* نشان از وجود اختلاف معنی دار در سطح احتمال ۹۵ درصد بین میانگین و واریانس در دو مرحله آموزش و آزمایش دارد ($p < 0.001$). با این وجود بین توزیع آماری مقادیر واقعی و پیش‌بینی شده توسط شبکه عصبی *MLP* اختلاف معنی داری در سطح احتمال ۹۵ درصد وجود ندارد ($p > 0.05$). بنابراین شبکه عصبی مصنوعی *LVQ* دارای قابلیت بالایی برای پیش‌بینی الگوی پراکنش علف هرز تلخه در مقایسه با مدل شبکه عصبی *MLP* می‌باشد. وجود $p = 0.001$ در مورد توزیع آماری بین مقادیر پیش‌بینی 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 *LVQ* به منظور طبقه بندی سطح مزرعه از نظر تراکم علف هرز با هر مقدار تراکم بحرانی می‌باشد.



شکل ۲. ساختار شبکه *LVQ* 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 برنده شده.
Fig. 2. Configuration of the LVQ for prediction of weed spatial existence. (X, Y) : coordinate of sampled points, W : code vectors matrix. W_{win} : label of winner code vector.

نتایج و بحث

خطای تشخیص شبکه عصبی مصنوعی *LVQ* و *MLP* در دو مرحله یادگیری و آزمایش در جدول ۱ نشان داده شده است. واضح است که خطای تشخیص مدل شبکه عصبی *MLP* کمتر از $14/6\%$ درصد بدست آمده در مقابل خطای تشخیص مدل شبکه عصبی *LVQ* کمتر از $0/64\%$ درصد است. این امر در هر سه مورد طبقه بندی به خوبی مشاهده می‌شود. مقایسه خطای تشخیص نشان داد که قابلیت شبکه عصبی *LVQ* در تفکیک و طبقه بندی سطح مزرعه براساس تراکم آن‌ها بسیار بالاتر از شبکه عصبی *MLP* است. نکته قابل توجه آن است که خطای تشخیص در مرحله آزمایش برای شبکه عصبی *LVQ* صفر می‌باشد؛ که این نشان دهنده قابلیت تعمیم پذیری بسیار بالای آن می‌باشد. بنابراین براساس این نتایج می‌توان به شبکه عصبی *LVQ* اعتماد کرد. در مطالعه الگوهای پراکنش حشرات (Zhang et al, 2008) خطای تشخیص برابر با صفر را بوسیله شبکه عصبی *MLP* بدست آوردند. زیرا حشرات دارای قابلیت تحرک می‌باشند لذا برای بدست آوردن غذای کافی تمایل دارند از یکدیگر فاصله گرفته و یک نوع پراکنش تقریباً یکنواختی داشته باشند. اما علف‌های هرز قابلیت تحرک ندارند و عوامل خارجی به صورت اجباری در پراکنش آن‌ها نقش دارند لذا عمدتاً بصورت لکه ای

جدول ۱. خطای تشخیص شبکه عصبی *LVQ* و *MLP* در دو فاز آموزش و آزمایش

Table 1. Recognition error of LVQ and MLP neural network in training and test phases.

Network goals for classification	Members of class 1	Members of class 2	Recognition error in training phase (%)	Recognition error in test phase (%)	Network type
$WD_1 = 0, WD_2 > 0$	472	78	0.21 10.90	0.00 14.60	LVQ MLP
$WD_1 \leq 2, WD_2 > 2$	512	38	0.64 4.49	0.00 12.2	LVQ MLP
$WD_1 \leq 4, WD_2 > 4$	527	23	0.21 4.06	0.00 1.22	LVQ MLP

توضیحات: WD_1 و WD_2 به ترتیب تراکم علف هرز در کلاس اول و کلاس دوم طبقه بندی

WD_1 and WD_2 : weed density in class 1 and 2, respectively.

جدول ۲. مقایسات آماری مقادیر واقعی و پیش‌بینی شده تراکم علف هرز توسط شبکه عصبی *MLP* و *LVQ*

Table 2. Statistical comparisons between the observed and estimated weed density by MLP and LVQ neural networks.

Network goals for	Network utilization	Statistical values
-------------------	---------------------	--------------------

classification	phase	comparisons of means	comparisons of variance	comparisons of sdistribution	Network type
$WD_1 = 0, WD_2 > 0$	Training Phase	0.852	0.789	1.000	LVQ
		0.000	0.000	0.073	MLP
	Test Phase	1.000	1.000	1.000	LVQ
$WD_1 \leq 2, WD_2 > 2$	Training Phase	0.692	0.323	1.000	LVQ
		0.001	0.000	0.828	MLP
	Test Phase	1.000	1.000	1.000	LVQ
$WD_1 \leq 4, WD_2 > 4$	Training Phase	0.870	0.596	1.000	LVQ
		0.005	0.000	0.967	MLP
	Test Phase	1.0000	1.000	1.000	LVQ
		0.563	0.002	1.000	MLP

براساس قضیه تقریب عمومی از یک لایه مخفی استفاده شد (Rohani et al, 2011). ولی با این وجود در مسئله مورد بررسی نتایج شبکه عصبی MLP بهتر از شبکه عصبی LVQ نشد. محققین دیگر نیز بیان کردند که شبکه‌های عصبی می‌توانند در شرایط متفاوت نتایج بسیار متغیر و حتی دور از انتظار داشته باشند (Zhang et al, 2008; Olden et al, 2004; Filippi and Jensen, 2006). اما در بیشتر این مطالعات شبکه‌های عصبی نسبت به مدل‌های رایج، برتری نشان داده اند (Dawson et al, 2006; Yu et al, 2006).

نقشه‌های توزیع مکانی علف هرز تلخه

نقشه پراکنش مکانی علف هرز تلخه که توسط شبکه‌های عصبی LVQ و MLP تفکیک و ترسیم شده در شکل ۳ نشان داده شده است. در این شکل ابتدا جمعیت علف هرز تلخه بر اساس حد آستانه صفر به دو کلاس جمعیتی فاقد علف هرز (صفر بوته) و دارای علف هرز، تقسیم و نقشه‌های آن ترسیم شد (شکل ۳ a, b و c). در شکل ۳ d, e و f و نیز در شکل ۳ g, h و i به ترتیب، جمعیت علف هرز بر اساس دو حد آستانه ۲ و ۴ بوته در متر مربع ترسیم شده است. حد صفر، ۲ و ۴ بوته انتخاب شده می‌تواند یک حد آستانه فرضی برای علف هرز باشد تا به کمک آن قابلیت شبکه‌های عصبی نشان داده شود. اگرچه پیش‌تر با مقایسات آماری، خطای تشخیص و معادله رگرسیونی مابین مقادیر واقعی و پیش بینی شده به عدم وجود تفاوت معنی داری بین آن‌ها دست پیدا کردیم، ولی با مقایسه بین نقشه حاصل از داده‌های واقعی و داده‌های پیش بینی شده توسط شبکه عصبی LVQ متوجه خواهیم شد که تفاوت چندانی بین آن‌ها وجود ندارد و اگر بعضی نقاط دو نقشه متناظر متفاوت از هم هستند ناشی از خطای مدل شبکه عصبی است.

ضرایب تبیین و رابطه خطی رگرسیونی بین مقادیر واقعی هر کلاس در مقابل مقادیر پیش‌بینی شده توسط شبکه عصبی LVQ و MLP 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 پیش‌بینی شده توسط شبکه عصبی علاوه بر داشتن ضرایب تبیین بالا دارای کمترین عرض از مبدأ (نزدیک به صفر) و شیب نزدیک به یک باشد ($pv = 1/0.00 dv + 0/0.00$). کاملاً واضح است که ضرایب تبیین بین داده‌های واقعی و پیش‌بینی شده در دو مرحله آموزش و آزمایش در شبکه عصبی LVQ بسیار بالا می‌باشند ($R^2 > 0/9$) در حالیکه این مقدار برای شبکه عصبی MLP کوچکتر از ۰/۴۹ است. همچنین معادله خطی رگرسیونی مابین آن‌ها دارای شیب‌های نزدیک به واحد و عرض از مبدأهای کوچکی هستند، بنابراین می‌توان به شبکه عصبی LVQ اطمینان کرد. در مورد شبکه عصبی MLP این رابطه خطی در تمام موارد از شیب بسیار پایین (کوچکتر از ۰/۹) و نیز از عرض از مبدأ بسیار بزرگ (بزرگتر از ۰/۰۲) برخوردار شد. این نتایج نشان می‌دهند که قابلیت تعمیم‌پذیری شبکه عصبی LVQ در مقابل شبکه عصبی MLP 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 پیش‌بینی شده از شیب نزدیکتر به واحد و عرض از مبدأ نزدیکتر به صفر برخوردار است. در پژوهشی که به منظور تعیین الگوهای پراکنش حشرات در یک مرغزار بوسیله شبکه‌های عصبی انجام شد، بیان شد که شبکه‌های عصبی MLP، LVQ و خطی می‌توانند به خوبی الگوهای توزیع حشرات را تشخیص دهند. اما در بین شبکه‌های مذکور MLP دارای قوی‌ترین الگوریتم در تشخیص الگوها بود (Zhang et al, 2008). به هر حال با کاربرد مناسب تعداد لایه مخفی و نرون، توابع تبدیل، توابع آموزش و آزمایش، شبکه MLP می‌تواند هر گونه تابع خطی یا غیرخطی را با دقت مطلوب، برآورد نماید (Zhang and Barrion, 2006). اگرچه در این پژوهش از الگوریتم اصلاح شده شبکه عصبی MLP استفاده شد و همچنین

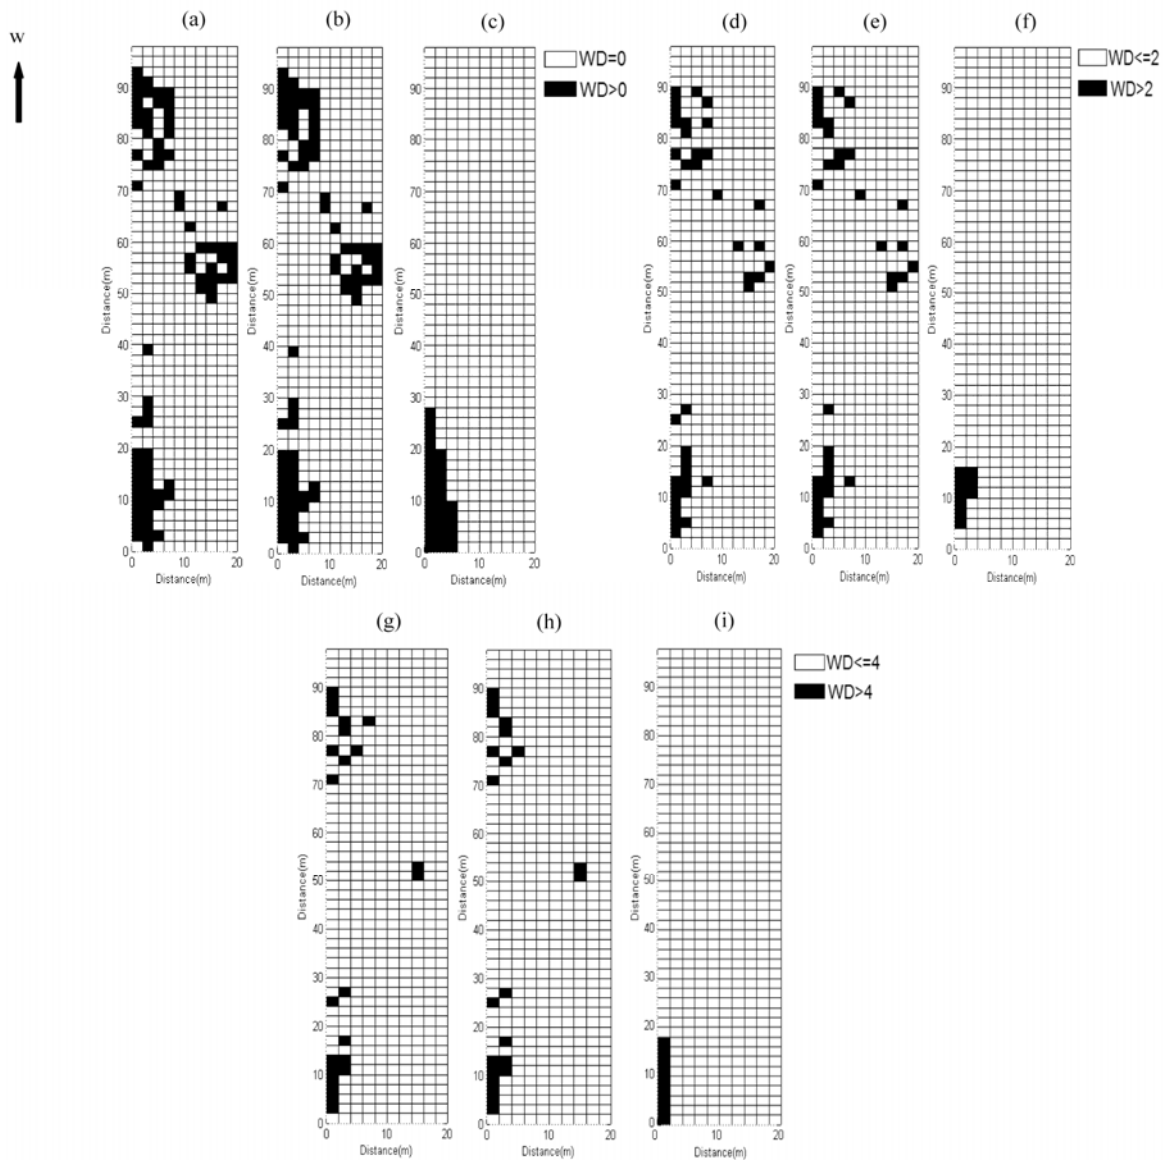
جدول ۳. رابطه خطی رگرسیونی و ضریب تبیین بین dv (مقادیر واقعی داده‌ها) و pv (مقادیر پیش‌بینی شده توسط مدل).

Table 3. Linear regression relationship and coefficient of determination between dv (actual value) and pv (predicted value by

model).				
Network goals for classification	Network utilization phase	Linear regression relationship	R ²	Network type
WD ₁ = 0, WD ₂ > 0	Training Phase	pv= 0.994 dv + 0.009	0.965	LVQ
		pv= 0.292 dv + 0.722	0.195	MLP
	Test Phase	pv= 1.000 dv + 0.000	0.999	LVQ
		pv= 0.139 dv + 0.875	0.073	MLP
WD ₁ ≤ 2, WD ₂ > 2	Training Phase	pv= 0.906 dv + 0.093	0.900	LVQ
		pv= 0.256 dv + 0.745	0.210	MLP
	Test Phase	pv= 1.000 dv + 0.000	0.999	LVQ
		pv= 0.090 dv + 0.909	0.079	MLP
WD ₁ ≤ 4, WD ₂ > 4	Training Phase	pv= 0.950 dv + 0.050	0.947	LVQ
		pv= 0.222 dv + 0.781	0.150	MLP
	Test Phase	pv= 1.000 dv + 0.000	0.999	LVQ
		pv= 0.987 dv + 0.028	0.490	MLP

بندی کردند. نقشه‌های تهیه شده بوسیله شبکه‌های عصبی چنانچه از دقت بالایی برخوردار باشند می‌توانند به مدیر مزرعه در جهت اعمال کنترل لکه ای علفکش‌ها کمک کنند. علاوه بر این چنانچه نقشه‌ها منطبق بر مختصات جغرافیایی هر مکان تهیه شوند، راهنمای خوبی برای فعال شدن نازل‌ها در نقاط بالای حد آستانه علف هرز در عملگرهای نرخ متغیر^۲ خواهند بود. نقشه‌های ترسیم شده نشان دهنده توزیع نا همگون و تجمعی علف هرز تلخه در مزرعه مورد مطالعه بود. علف هرز تلخه گیاهی چندساله و مهاجم است که قادر به تکثیر از طریق بذر می‌باشد، اما این گیاه عمدتاً از طریق پراکنش قطعات ریشه بوسیله عوامل گوناگون تکثیر می‌شود (Roberts et al, 2004). در مطالعه ای با استفاده از مدل‌های شبیه سازی، پراکنش علف هرز تلخه در ایالت کلرادو آمریکا مورد مطالعه قرار گرفت (Goslee et al, 2006). این محققین نقشه‌های پراکنش 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، بافت خاک و نیز روش‌های مدیریتی اعمال شده سبب توزیع ناهمگون این علف هرز در سطح ایالت شده است.

ولی در مورد صحت کارایی یک مدل نمی‌توان تنها با مقایسه یک یا چند نقطه قضاوت کرد (Zhang and Fuh, 1998). در مقایسه نقشه‌های تفکیک شده توسط مدل شبکه عصبی MLP و نقشه‌های حاصل از داده‌های واقعی مشاهده می‌شود، لکه‌هایی از علف هرز که در بخش‌های میانی و غرب مزرعه وجود داشته توسط شبکه MLP (شکل‌های ۳، c، f و i) قابل تشخیص نبوده، درحالی‌که این لکه‌ها آلوده به علف هرز بوده است. Zhang et al, (2008) در مقایسه سه مدل شبکه عصبی LVQ، MLP و روش تفکیک خطی ۱ برای تعیین الگوهای پراکنندگی حشرات در سطح یک چمن زار، بیان کردند که شبکه عصبی MLP الگوریتم قوی تری در تشخیص الگوهای پراکنش حشرات بود. آن‌ها رفتارهای اکولوژیکی را در کارایی مدل‌های شبکه عصبی موثر دانستند. بنابراین به نظر می‌رسد با توجه به ویژگی‌های اکولوژیکی متفاوت حشرات و علف‌های هرز در سطح مزارع، تفاوت در عملکرد شبکه MLP در دو آزمایش دور از ذهن نباشد. در آزمایش Zhang et al, (2008) شبکه LVQ، از نظر دقت تشخیص حدواسط دو شبکه دیگر قرار می‌گرفت. در پژوهشی دیگر که با استفاده از شبکه عصبی LVQ انجام شد، محققین میزان آلودگی پانیکول برنج به بیماری بلایت را به چند سطح سالم، با آلودگی کم، متوسط و شدید طبقه بندی کرده و سپس بر اساس آستانه آلودگی مورد نظر اقدام به کنترل بیماری کردند (Zhang et al, 2010). آستانه اقتصادی به صورت تراکمی از علف‌هرز تعریف می‌شود که در آن هزینه کنترل علف‌هرز معادل سود حاصل از کنترل است (O Donovan, 1991). واضح است که نقاط دارای تراکم بیشتر از حد آستانه 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. Kavdir (2004) با کاربرد شبکه عصبی مصنوعی بوته‌های آفتاب گردان و علف هرز تپوق را دو تا سه هفته بعد از سبز شدن با توجه به اندازه، شکل و رنگ طبقه



شکل ۳. نقشه توزیع علف هرز تلخه در دو حالت واقعی (شکل‌های *a*، *d* و *g*) و تفکیک شده، توسط مدل شبکه عصبی *LVQ* (شکل‌های *b*، *e* و *h*) و مدل شبکه عصبی *MLP* (شکل‌های *c*، *f* و *i*). نقشه‌های *a* و *b* براساس حدآستانه صفر بوته، نقشه‌های *d*، *e* و *f* براساس حدآستانه دو بوته و نقشه‌های *g*، *h* و *i* براساس حدآستانه چهار بوته علف هرز در متر مربع ترسیم شده است.

Fig. 3. *Acroptilon repense* distribution maps in actual (a, d and g) and classified conditions by LVQNN (b, e and h) and by MLPNN (c, f and i). The maps of a, b, c and d, e, f and g, h, i have been drawn according to economic threshold of 0, 2 and 4 plants/m² respectively.

قیاق^۳ که بوسیله اندام‌های رویشی زیر زمینی تکثیر می‌شوند نیز گزارش شده است (Christensen et al, 1998). علف‌های هرزی که حالت لکه‌ای بودن و پایداری بیشتری دارند برای مدیریت متناسب با

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. وجود توزیع لکه ای در علف‌های هرز چند ساله ای نظیر شاهی وحشی^۱ (Makarjian, 2008)، خارلته^۲ و

2 - *Cirsium arvense* (L.)

3 - *Sorghum halepense*

1 - *Cardaria draba* (L.)

مکان مناسب‌ترند (Colbach et al, 2000).

بالایی علاوه بر پیش بینی، نقشه پراکنش جمعیت علف هرز تلخه را ترسیم نماید. نقشه حاصل از هر دو شبکه نیز نشان داد که تلخه دارای آرایش لکه ای است. بنابراین تنها از طریق تیمار کردن لکه‌های دارای علف هرز می‌توان به اهداف مدیریت متناسب با مکان و کاهش علفکش‌های مصرفی دست یافت.

نتیجه گیری کلی

این پژوهش نشان داد که یکی دیگر از روش‌های مدل‌سازی رفتار علف‌های هرز، شبکه‌های عصبی مصنوعی است. در این گونه مدل‌ها بدون در نظر گرفتن معادلات پیچیده غیرخطی، می‌توان دینامیک حاکم بر سیستم را استخراج نموده و از این طریق، خروجی‌های مدل را پیش‌بینی کرد. از بین شبکه‌های عصبی LVQ و MLP بکار گرفته شده در این مطالعه شبکه LVQ توانست با دقت

سیاسگزاری

بدینوسیله از معاونت محترم پژوهشی دانشگاه صنعتی شاهرود به خاطر حمایت مالی از این پژوهش قدردانی می‌شود.

منابع

- 1- Azadeh, A., Ghaderi, S. F., and S. Sohrabkhani. 2006. Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. *Applied Mathematics and Computation*, 186: 1753-1761.
- 2- Cardina, J., and D. J. Doohan. 2008. Weed biology and precision farming. *Site-specific management guideline*. www.ppi-far.org/ssmg.
- 3- Chang, D.H., and S. Islam. 2000. Estimation of soil physical properties using remote sensing and artificial neural network. *Remote Sensing of Environment*, 74: 534-544.
- 4- Christensen, S., T. Heisel, and M. Paice. 1998. Simulation of long term *Alopecurus myosuroides* population using three patch spraying strategies. *Proceedings of the 15th Danish Plant Protection Conference Weeds. DJF-RC. Prot No. 2*, pp. 141-150.
- 5- Colbach, N., F. Forcella, and G.A. Johnson. 2000. Spatial and temporal stability of weed populations over five years. *Weed Science*, 48:366-377.
- 6- Dawson, C. W., R. J. Abraham, and A.Y. Shamseldin. 2006. Flood estimation at un gauged sites using artificial neural networks. *J. Hydrol.* 319:391-409.
- 7- Drummond, S.T., K.A. Sudduth, A. Joshi, S. J. Birrell and N. R. Kitchen. 2003. Statistical and neural methods for site-specific yield prediction. *Transactions of the American Society of Agricultural and Biological Engineers (ASABE)*, 46: 5-14.
- 8- Filippi, A. M., and J. R. Jensen. 2006. Fuzzy learning vector quantization for hyperspectral coastal vegetation classification. *Remote Sensing Environment*. 100:512-530
- 9- Goel, P. K., S. O. Prasher, R. M. Patel, J. A. Landry, R. B. Bonnell, and A. A. Viau. 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.
- 10- Goslee, C. S., D. P. C. Peters, and K. George-Beck. 2006. Spatial prediction of invasion success across heterogeneous landscapes using an individual-based model. *Biological Invasions*. 8: 193- 200.
- 11- Grundy, A. C., C. M. Onyango, K. Phelps, R. J. Reader, J. A. Marchant, L. R. Benjamin, and M. Mesd. 2005. Using a competition model to quantify the optimal trade-off between machine vision capability and weed removal effectiveness. *Weed Research*. 45: 388- 405.
- 12- Gupta, M. M., J. Jin, and N. Homma. 2003. *Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory*. John Wiley & Sons, Inc., Hoboken, New Jersey.
- 13- Heijting, S., W. Van Der Werf, A. Stein, and M. Kropff. 2007. Are weed map stable in location? Application of an explicitly two – dimensional methodology. *Weed Research*, 47: 381-395.
- 14- Irmak, a., J. W. Jones, W. D. Batchelor, S. Irmak, k. J. Boote, and j. O. Paz. 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.
- 15- Jin, Y. Q., and C. Liu. 1997. Biomass retrieval from high-dimensional active/passive remote sensing data by using artificial neural networks. *International Journal of Remote Sensing*, 18: 971-979.
- 16- Jurado-Exposito, M., F. Lopez-Granados, J. L. Gonzalez-Andujar, and L. Garcia-Torres. 2004. Spatial and temporal analysis of *Convolvulus arvensis* L. populations over four growing seasons. *European Journal of Agronomy*, 21: 287-296.
- 17- Kaul, M., R. L. Hill, and C. Walthall. 2005. Artificial neural networks for corn and soybean yield

- prediction. *Agriculture system*, 85: 1-18.
- 18- Kavdir, S. 2004. Discrimination of sunflower, weed and soil by artificial neural networks. *Computer and Electronic in Agriculture*, 44: 153-160.
 - 19- Kohonen, T. 1990. *The Self-Organizing Map*, Proceedings of IEEE, Vol. 78, No. 9.
 - 20- Kohonen, T. 1995. *Self-Organizing Map*, Springer-Verlag, Berlin, Heidelberg.
 - 21- Liu, Z. Y., H. F. Wu., and J.-F. Huang .2010. Application of neural networks to discriminate fungal infection levels in rice panicles using hyperspectral reflectance and principal components analysis. *Computers and Electronics in Agriculture*, 72: 99-106 .
 - 22- Makarian H., M. H. Rashed Mohassel, M. Bannayan and M. Nassiri. 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.(in farsi)
 - 24- Nordmeyer, H. 2006. Patchy weed distribution and site-specific weed control in winter cereals. *Precision Agriculture*, 7: 219 -231.
 - 25- Olden, J. D., M. K. Joy, and R.G. Death. 2004. An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data. *Ecological Modelling*, 178:389–397.
 - 26- Rashed Mohassel, M. H., H. Najafi, and M. D. Akbarzadeh. 2001. *Weed Biology and Control*. Ferdowsi University Press, 404p. (In farsi)
 - 27- Roberts, E. A., R.L. Sheley, and R. L. Lawrence. 2004. Using sampling and inverse distance weighting modeling for mapping invasive plants. *Western North American Naturalist*, 64: 312-323.
 - 28- Rohani, A., Abbaspour-Fard, M.H., Abdolahpour, S. 2011. Prediction of tractor repair and maintenance costs using artificial neural network. *Expert Sys. Applications* 38: 8999–9007.
 - 29- Searcy, S. W. 2008. Precision farming: a new approach to crop management. Texas agricultural extension service. txprecag.tamu.edu/content/pub/pf-ncm.pdf.
 - 30- Shaw, D. R. 2005. Translation of remote sensing data into weed management decisions. *Weed Science*. 53: 264-273.
 - 31- Torrecilla, J. S., L. Otero, and P. D. Sanz. 2004. A neural network approach for thermal/pressure food processing. *Food Engineering*, 62: 89-95.
 - 32- Vakil-Baghmisheh, M. T. 2002. Farsi Character Recognition Using Artificial Neural Networks. PhD Thesis, Faculty of Electrical Engineering, University of Ljubljana.
 - 33- Vakil-Baghmisheh, M. T., and N. Pavešic. 2001. Back-propagation with declining learning rate. Proceeding of the 10th Electrotechnical and Computer Science Conference, Portorož, Slovenia. Vol B: 297-300.
 - 34- Vakil-Baghmisheh, M. T., and N. Pavešic. 2003. Premature clustering phenomenon and new training algorithms for LVQ. *Pattern recognition*, 36:1901-1921.
 - 35- Veelenturf, L. P. J. 1995. Analysis applications of artificial neural networks. Simon & Schuster international group, United States of America.
 - 36- Yang, C. C., S. O. Prasher, J. A. Landry, and H. S. Ramaswamy. 2003. Development of a herbicide application map using artificial neural networks and fuzzy logic. *Agricultural Systems*, 76: 561-574.
 - 37- Yu, R., P. S. Leung, and P. Bienfang. 2006. Predicting shrimp growth: artificial neural network versus non-linear regression models. *Aqua- cultural Engineering*, 34:26–32
 - 38- Zhang, W. J., and A.T. Barrion. 2006. Function approximation and documentation of sampling data using artificial neural networks. *Environmental Monitoring and Assessment*, 122(1–3):185–201.
 - 39- Zhang, W. J., X. Q. Zhong, and G. H. Liu. 2008. Recognizing spatial distribution patterns of grassland insects: neural network approaches. *Stochastic Environmental. Research and Risk Assessment*, 22:207–216.
 - 40- Zhang, Y. F., and J. Y.H. Fuh. 1998. A neural network approach for early cost estimation of packaging products. *Computers & Industrial Engineering*, 34: 433-50.
 - 41- Zhang, Y., J. Pulliainen, S. Koponen, and M. Hallikainen. 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.