

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

### کشاورزی دقیق

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

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 پرسترنون 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 شاهروド در استان سمنان در سال ۱۳۸۹ بدست آمد. برای ارزیابی قابلیت شبکه‌های عصبی مورد استفاده در پیش‌بینی توزیع مکانی علف هرز از مقایسه آماری پارامترهای 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 آموزش دیده  $LVQ$  دارای قابلیت بالایی در پیش‌بینی مکانی علف هرز در نقاط نمونه برداری نشده با خطا تشخیص کمتر از  $14/6$  درصد بود. در حالیکه شبکه عصبی مصنوعی  $MLP$  دارای خطای تشخیص کمتر از  $14/6$  درصد بود. نقشه‌های ترسیم شده نشان داد که توزیع لکه‌ای علف هرز امکان کنترل مناسب با مکان را در مزرعه موردنظر مطالعه امکان پذیر می‌سازد.

**واژه‌های کلیدی:** توزیع مکانی، طبقه بندی، مدیریت مناسب با مکان، شبکه عصبی

#### مقدمه

(مکان‌های) مشابه تفکیک شده و پس از تشخیص خصوصیات هر یک از این واحداها، مدیران مزرعه نهاده‌ها را برای هر واحد و بر اساس مقدار مورد نیاز جهت دستیابی به حداقل بازده اقتصادی بکار می‌برند (Cardina and Doohan, 2008). جمع آوری اطلاعات و تهیه نقشه در سامانه مدیریت مناسب با مکان محوری ترین مسئله است (Grundy et al, 2005); زیرا عملکردها در فناوری نرخ متغیر بر اساس نقشه‌های تهیه شده تیمارها را اعمال می‌کند (Shaw, 2005). علف‌های هرز یکی از عوامل کاهش دهنده عملکرده 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 لکه‌ای ظاهر می‌شوند (Heijeting et al, 2007). از طرفی امروزه سیستم‌های کشاورزی وابسته به مواد

کشاورزی دقیق، جدید ترین فناوری در عرصه کشاورزی می‌باشد که بر اساس سه اصل افزایش عملکرد، افزایش بهره اقتصادی و کاهش اثرات سوء زیست محیطی دنیال می‌شود. 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 مناسب با شرایط نقاط مختلف زمین گام برداشت. اگرچه کشاورزان تغییرات موجود در قسمت‌های مختلف مزرعه را تشخیص می‌دهند اما ابزارآلات در دسترس اجازه مدیریت مناسب با مکان را به آن‌ها نمی‌دهد (Searcy, 2008). کشاورزی دقیق ابزارهای توانای برای افزایش کارآیی مدیریت مزرعه به ارتفاع آورده است. در این رهیافت با به خدمت گرفتن فن آوری اطلاعات، مزرعه به چندین واحد

۱- استادیاران دانشکده کشاورزی، دانشگاه صنعتی شاهروд  
(Email: abassrohani@yahoo.com)  
\* - نویسنده مسئول:

2000)، ارزیابی کیفیت آب (Zhang et al, 2002)، تخمین بیوماس (Drummond et al, 1997) و تخمین عملکرد (Jin and Liu, 1997) (2003) نیز پتانسیل بالای نشان داده است. مدل‌های شبکه عصبی دارای مزایایی از قبیل افزایش ظرفیت اطلاعات و توانایی بیان اثرات متقابل قوی بین متغیرهای ورودی می‌باشند. Irmak et al, (2006) 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. علف هرز تلخه گونه چندساله‌ای 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 پیش‌بینی، طبقه‌بندی 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 پرسپکtron چند لایه (MLP) و چندی ساز بردار یادگیر (LVQ4) در پیش‌بینی، طبقه‌بندی 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 شاهroud واقع در استان سمنان انجام شد. طول و عرض جغرافیایی محل به ترتیب  $54^{\circ} 57'$  شمالی و  $36^{\circ} 25'$  شرقی و ارتفاع محل از سطح دریا  $1349/1$  متر می‌باشد. میانگین بارندگی سالیانه منطقه  $150$  میلی‌متر، میانگین سالانه دما  $14/4$  درجه سانتی‌گراد می‌باشد. داده‌های مورد استفاده از مزرعه ای به ابعاد  $20 \times 100$  متر (متراً 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<sup>۱</sup> به ابعاد  $2 \times 2$  متر انجام و در مجموع از  $550$  نقطه در مزرعه نمونه برداری انجام شد. نمونه برداری از جمعیت علف هرز با استفاده از کوادراتی به ابعاد  $100 \times 50$  سانتی متر (مساحت  $5/0$  مترمربع) در محل تقاطع خطوط شبکه مربعی انجام شد. به طوری که در هر کوادرات جمعیت علف هرز تلخه شناسایی و شمارش شد.

1- Grid

شیمیایی به دلیل نگرانی ناشی از آلودگی‌های زیست محیطی، سلامت انسان و افزایش هزینه‌های اقتصادی کشاورز بطور فزاینده‌ای مورد بازنگری واقع شده‌اند. در این راستا مطالعات نشان داده است که پیش‌بینی گسترش لکه‌های علف هرز و سپاهشی لکه ای نسبت به سپاهشی 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 سپاهشی دارد (Nordmeyer, 2006). پیش‌بینی 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 طبقه‌بندی، تشخیص الگو، پیش‌بینی 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 است (Vakil-Baghmisheh, 2002). 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 پیش‌بینی هر خروجی متناظر با ورودی دلخواه می‌باشد (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 پیش‌بینی تراکم علف‌های هرز را برای ما روش می‌سازد. 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 به شمار می‌روند (Zhang et al, 2008) و می‌توانند با دقت بالا جمعیت علف هرز را از گیاه زراعی در مزارع تمایز 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 شاخصاره برای چند گیاه زراعی تشریح نمایند، اما این تکییک در پیش‌بینی متغیرهای پیوسته ای مانند رطوبت خاک (Chang and Islam,

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 (*Vakil-Baghmisheh and Pavešić, 2001*) این الگوریتم آموزش با آهنگ یادگیری ( $\eta$ ) و عامل ممتد  $T$  (اثبات و نسبتاً بزرگ شروع می‌کند و قبل از آنکه شبکه ناپایدار و یا همگرایی آن کند شود، هر  $T$  تکرار ( $T \leq 3$ ) آهنگ یادگیری و فاکتور ممتد را از طریق تصاعد حسابی بصورت یکنواخت کاهش داده می‌شود تا زمانیکه این پارامترها به  $x$  درصد (۰/۵٪) مقادیر اولیه خودشان برسند.  $\eta$  و بطور مشابه  $\alpha$  با استفاده از فرمول (معادله ۲) کاهش داده شد:

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

در اینجا  $n$ ،  $\eta_{\text{بر}}$  و  $T$  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 خطای  $(TSSE)$  می‌باشد و بصورت زیر محاسبه می‌شود:

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

و  $z_k^q$  به ترتیب  $k$  امین عنصر از بردارهای خروجی مطلوب 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.

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

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

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

سپس داده‌ها در مدل مورد استفاده قرار گرفت.

### پیش پردازش داده‌ها

در ابتدا داده‌های موجود بطور تصادفی به دو دسته مجموعه آموزش  $80$  درصد کل داده‌ها و مجموعه آزمایش  $20$  درصد کل داده‌ها تقسیم‌بندی شد. البته اگر این تقسیم‌بندی منجر به نتایج مطلوب نشود، می‌توان این مرحله را مجدد 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 بدليل دامنه تغییرات خروجی تابع فعالیت سیگموئیدی  $[0/1]$  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  $[0/1]$  باشد (*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،  $r_{\max}$  و  $r_{\min}$  به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه و  $x_{\min}$  و  $r_{\min}$  به ترتیب حد بالایی و پایینی دامنه تغییرات داده‌های تبدیل شده است.

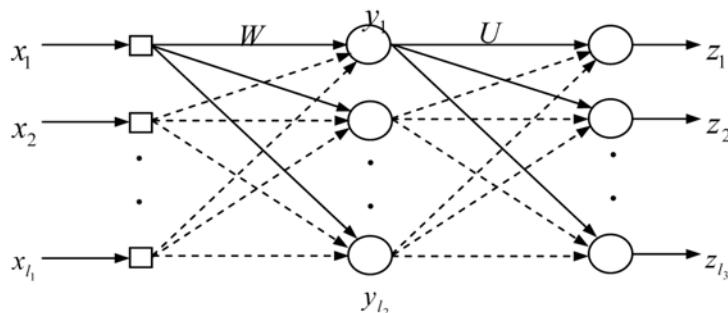
از شبکه‌های عصبی  $MLP$  و  $LVQ$  با هدف طبقه بندی سطح مزرعه به دو کلاس برای سه حالت مختلف استفاده شد. حالت اول برای زمانی است که مزرعه را به دو منطقه وجود علف هرز و یا عدم وجود علف هرز و به ترتیب حالت دوم و سوم برای زمانی است که تراکم علف هرز برای نقاطی از مزرعه کوچکتر یا مساوی و یا بزرگتر از ۲ و ۴ 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

1 - Sigmoid transfer function

- 2 - Backpropagation with declining learning-rate factor  
3 - Basic backpropagation  
4 - Total sum-squared error



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  $\mathbf{x}^q$ :

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

تغییم  $\mathbf{w}_c$

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

آنچه یادگیری در طول زمان آموزش از رابطه زیر بدست آمد:

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

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

$$d_q(n) = \frac{E_q(n)}{D_q(n)} \quad (9)$$

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

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

است (Vakil-Baghmisheh and Pavešic, 2003) و  $\lambda = 0.01$ .

ساختار شبکه عصبی  $LVQ$  استفاده شده به منظور طبقه بندی سطح مزروعه به دو منطقه یا طبقه بندی بر مبنی تراکم‌های مختلف، در شکل ۲ نشان داده شده است. ورودی‌های شبکه مختصات مکانی علف‌های هرز می‌باشند و خروجی شبکه بردار کد تعبیین نزدیکترین فاصله اقلیدسی را با ورودی دارد. برنامه نویسی مدل‌های شبکه عصبی کلاس بردار ورودی است. برنامه نویسی  $Matlab$  نسخه ۷ انجام شد.

در اینجا  $w_{ij}$  اتصال وزنی بین گره‌های  $i$  و  $j$  و  $u_{jk}$  اتصال وزنی بین گره‌های  $j$  و  $k$ ، مقادیر اولیه این وزن‌ها بطور تصادفی از دامنه مقادیر  $[-0.25, 0.25]$  انتخاب می‌شود.  $l_2$  و  $l_3$  به ترتیب تعداد نرون‌ها در لایه مخفی و لایه خروجی می‌باشند.  $\eta$  و  $\alpha$  به ترتیب آهنگ یادگیری و فاکتور ممتوnom هستند و مقادیر آن‌ها در فاصله  $[0, 1]$  قرار دارند و  $n$  شماره تکرار الگوریتم ( $n = l_1, \dots, N$ ). زمانی که الگوریتم متوقف می‌شود که  $TSSE$  کوچکتر از مقدار آستانه باشد. جزئیات بیشتر این الگوریتم را می‌توان 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 منطقه‌های متمایز از هم با نام ناحیه‌های تصمیم‌گیری ۱ و اختصاص یک بردار کد به هر یک از آن‌ها است. طبقه بندی بر حسب نزدیکی بردار ورودی  $x$  به بردارهای کد خواهد شد. بردار ورودی متعلق به کلاس نزدیکترین بردار کد خواهد شد. الگوریتم تا وقتی که ناحیه‌های تصمیم‌گیری و مرکزهای آن‌ها ثابت نشود، ادامه خواهد یافت.  $0LVQ$ ,  $LVQ3$ ,  $LVQ2.1$ ,  $LVQ1$ , (Vakil-LVQ4 (Kohonen, 1990; Kohonen, 1995) و Baghmisheh, 2002; Vakil-Baghmisheh and Pavešic, 2003) از الگوریتم آموزش  $LVQ4$  به جهت بالا بودن کارآبی آن استفاده شد.

### الگوریتم آموزش $LVQ4$

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

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

و  $\mathbf{w}_m$  بردار کد باشد

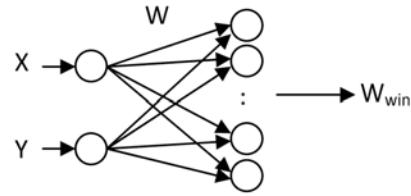
$$\mathbf{w}_m \in \mathbb{R}^n, \quad m=1, \dots, M$$

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 تاخه، 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  $t$  و کولموگروف-اسمیرنوف 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 شبکه عصبی *LVQ*، اختلاف معنی‌داری با هم ندارند) ( $p > 0.03$ ). ولی نتایج مقایسات آماری برای شبکه عصبی *MLP* نشان از وجود اختلاف معنی‌داری 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 معنی‌داری در سطح احتمال ۹۵ درصد وجود ندارد ( $p > 0.07$ ). بنابراین شبکه عصبی مصنوعی *LVQ* دارای قابلیت بالایی برای پیش‌بینی الگوی پراکنش علف هرز تاخه در مقایسه با مدل شبکه عصبی *MLP* می‌باشد. وجود  $p = 1/1000$  در مورد توزیع آماری بین مقادیر پیش‌بینی شده و مقادیر واقعی تراکم در سطح 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 ۱۴/۶ کمتر از  $0.64$  در مقابل خطای تشخیص مدل شبکه عصبی *LVQ* کمتر از  $0.001$  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 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 آورده‌اند. زیرا حشرات دارای قابلیت تحرک می‌باشند لذا برای بدست آوردن غذای کافی تمایل دارند از یکدیگر فاصله گرفته و یک نوع پراکنش 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	<i>LVQ</i> <i>MLP</i>
$WD_1 \leq 2, WD_2 > 2$	512	38	0.64 4.49	0.00 12.2	<i>LVQ</i> <i>MLP</i>
$WD_1 \leq 4, WD_2 > 4$	527	23	0.21 4.06	0.00 1.22	<i>LVQ</i> <i>MLP</i>

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 *LVQ* و *MLP*

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

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

classification	phase	comparisions of means	comparisions of variance	comparisions of sdistribution	Network type
$WD_1 = 0, WD_2 > 0$	Training Phase	0.852 0.000 1.000 0.008	0.789 0.000 1.000 0.000	1.000 0.073 1.000 0.548	LVQ MLP LVQ MLP
	Test Phase				
	Training Phase	0.692 0.001 1.000 0.003	0.323 0.000 1.000 0.000	1.000 0.828 1.000 0.548	LVQ MLP LVQ MLP
	Test Phase				
$WD_1 \leq 2, WD_2 > 2$	Training Phase	0.870 0.005 1.0000	0.596 0.000 1.000	1.000 0.967 1.000	LVQ MLP LVQ
	Test Phase	0.563	0.002	1.000	MLP
	Training Phase				
	Test Phase				

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 سیار 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 Yu (Dawson et al, 2006; Dawson et al, 2006; Yu et al, 2006)

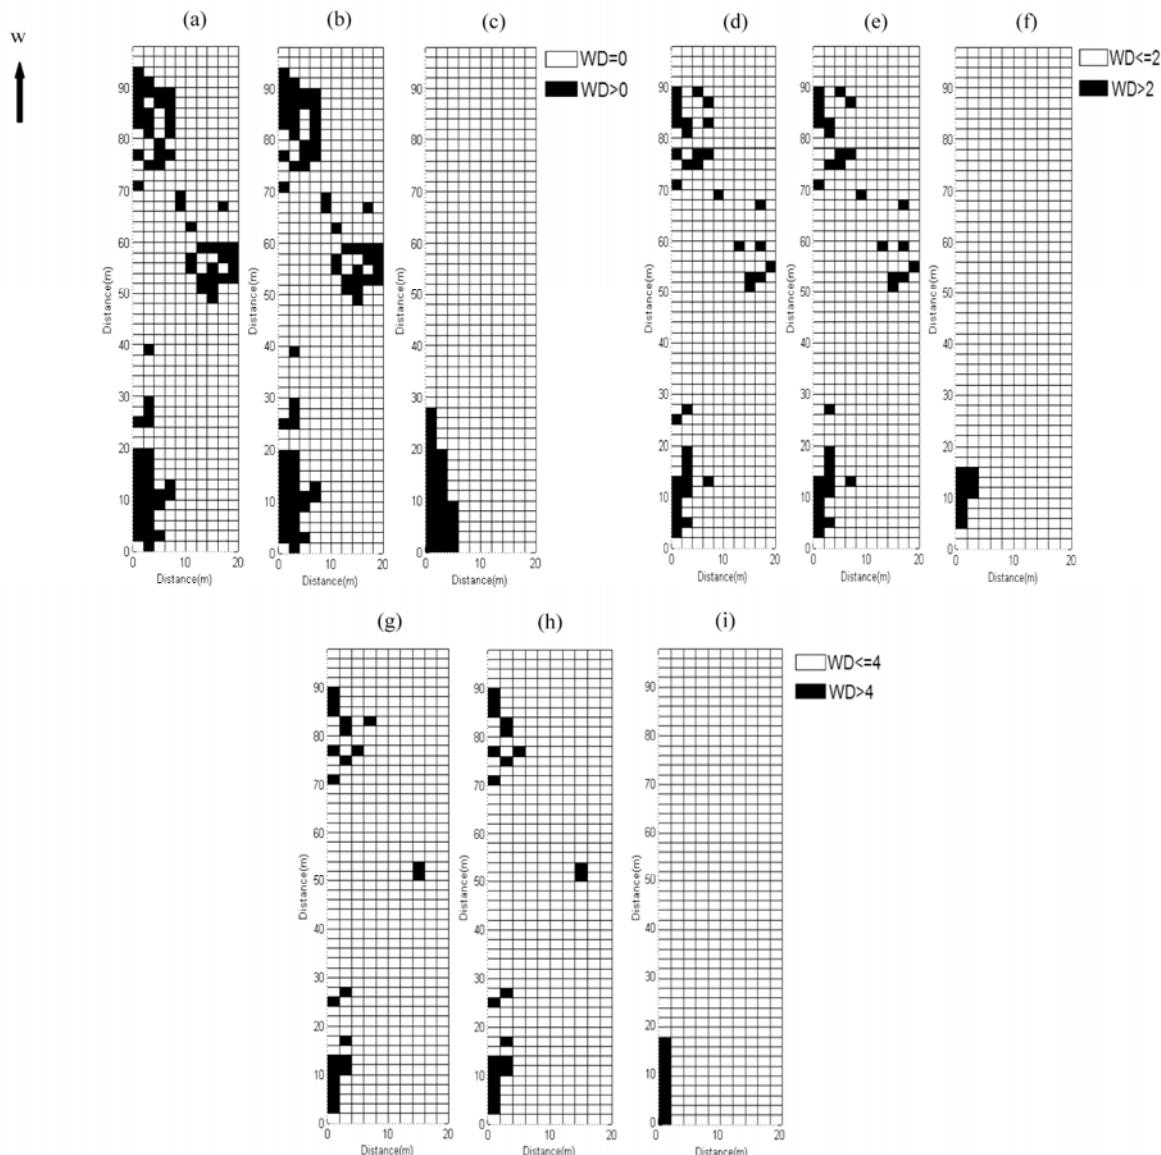
ضرایب تبیین و رابطه خطی رگرسیونی بین مقادیر واقعی هر کلاس در مقابل مقادیر پیش‌بینی شده توسط شبکه عصبی LVQ و MLP در جدول ۳ نشان داده است. بهترین نتایج براساس این دو معیار وقتی بدست می‌آید که معادله خطی مابین تراکم علف هرز واقعی و تراکم علف هرز پیش‌بینی شده توسط شبکه عصبی علاوه بر داشتن ضرایب تبیین بالا دارای کمترین عرض از مبدأ (نژدیک به صفر) و شبکه نژدیک به یک باشد ( $R^2 = 0.967$ ). 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  $0.49$  است. همچنین معادله خطی رگرسیونی مابین آن‌ها دارای شبکه نژدیک 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 شبکه عصبی پایین ( $R^2 < 0.9$ ) و نیز از عرض از مبدأ بسیار بزرگ (بزرگتر از  $0.02$ ) برخوردار شد. این نتایج نشان می‌دهند که قابلیت تمییز پذیری شبکه عصبی LVQ در مقابل شبکه عصبی MLP آموزش دیده بسیار بالا می‌باشد، زیرا فاز آزمایش در مقایسه با فاز آموزش دارای ضرایب تبیین بالاتر و نیز معادله خطی رگرسیونی مابین مقادیر واقعی و پیش‌بینی شده از شبکه نژدیکتر به واحد و عرض از مبدأ نژدیکتر 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 LVQ و خطی می‌توانند به خوبی الگوهای توزیع حشرات را تشخیص دهند. اما در بین شبکه‌های مذکور دارای قوی ترین الگوریتم در تشخیص الگوها بود MLP دارای  $R^2 = 0.967$  (Zhang et al, 2008). به هر حال با کاربرد مناسب تعداد لایه MLP مخفی و نرون، توابع تبدیل، توابع آموزش و آزمایش، شبکه 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 ضرایب 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

<i>model).</i>					
<b>Network goals for classification</b>	<b>Network utilization phase</b>	<b>Linear regression relationship</b>	<b>R<sup>2</sup></b>	<b>Network type</b>	
$WD_1 = 0, WD_2 > 0$	<i>Training Phase</i>	$pv = 0.994 \ dv + 0.009$	0.965	<i>LVQ</i>	
		$pv = 0.292 \ dv + 0.722$	0.195	<i>MLP</i>	
	<i>Test Phase</i>	$pv = 1.000 \ dv + 0.000$	0.999	<i>LVQ</i>	
		$pv = 0.139 \ dv + 0.875$	0.073	<i>MLP</i>	
$WD_1 \leq 2, WD_2 > 2$	<i>Training Phase</i>	$pv = 0.906 \ dv + 0.093$	0.900	<i>LVQ</i>	
		$pv = 0.256 \ dv + 0.745$	0.210	<i>MLP</i>	
	<i>Test Phase</i>	$pv = 1.000 \ dv + 0.000$	0.999	<i>LVQ</i>	
		$pv = 0.090 \ dv + 0.909$	0.079	<i>MLP</i>	
$WD_1 \leq 4, WD_2 > 4$	<i>Training Phase</i>	$pv = 0.950 \ dv + 0.050$	0.947	<i>LVQ</i>	
		$pv = 0.222 \ dv + 0.781$	0.150	<i>MLP</i>	
	<i>Test Phase</i>	$pv = 1.000 \ dv + 0.000$	0.999	<i>LVQ</i>	
		$pv = 0.987 \ dv + 0.028$	0.490	<i>MLP</i>	

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<sup>۳</sup> خواهد بود. نقشه‌های ترسیم شده نشان دهنده توزیع ناهمگون 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 مطالعه‌ای با استفاده از مدل‌های شبیه سازی، پراکنش علف هرز تلخه در ایالت کلرادوی امریکا 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 کارآیی یک مدل نمی‌توان تنها با مقایسه یک یا چند نقطه قضاؤت کرد (*Zhang and Fuh, 1998*). در مقایسه نقشه‌های تفکیک شده توسط مدل شبکه عصبی *MLP* و *MLP* مقایسه‌های حاصل از داده‌های واقعی مشاهده می‌شود، لکه‌هایی از علف هرز که در بخش‌های میانی و غرب مزرعه وجود داشته توسط شبکه *MLP* (شکل‌های ۳، ۴ و ۵) قابل تشخیص نبوده، در حالیکه این در لکه‌های آلووده به علف هرز بوده است. (*Zhang et al., 2008*) در مقایسه سه مدل شبکه عصبی *MLP*, *LVQ* و روش تفکیک خطی<sup>۱</sup> برای تعیین الگوهای پراکندگی 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 کارآیی 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*) از نظر دقت تشخیص حدواتسط دو شبکه دیگر قرار می‌گرفت. در پژوهشی دیگر که با استفاده از شبکه عصبی *LVQ* انجام شد، محققین میزان الودگی پانیکول برنج به بیماری بلایت را به چند سطح سالم، با الودگی کم، متوسط و شدید طبقه بندی کرده و سپس بر اساس آستانه الودگی مورد نظر اقدام به کنترل بیماری کردند (*Zhang et al., 2010*). آستانه اقتصادی به صورت تراکمی از علف‌هرز تعیین می‌شود که در آن هزینه کنترل علف‌هرز معادل سود حاصل از کنترل است (*O Donovan, 1991*). واضح است که نقاط دارای تراکمی گردید و سایر نقاط که زیر حد آستانه قرار دارند نیاز به مصرف علفکش یا هر عملیات کنترلی ندارند. (*Kavdir et al., 2004*) با کاربرد شبکه عصبی مصنوعی بوته‌های آفتاب‌گردان و علف هرز توق 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 (شکل های a, d و g) و تفکیک شده، توسعه مدل شبکه عصبی LVQ (شکل های b, e و h) و مدل شبکه عصبی MLP (شکل های c, f و i). نقشه های a و b براساس حد آستانه صفر بوده، نقشه های d و e براساس حد آستانه دو بوده و نقشه های g و h براساس حد آستانه چهار بوده 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/m<sup>2</sup> respectively.*

قیاق<sup>۳</sup> که بوسیله اندام های رویشی زیر زمینی تکثیر می شوند نیز گزارش شده است (Christensen et al, 1998). علفهای هرزی که حالت لکه ای بودن و پایداری بیشتری دارند برای مدیریت متناسب با

در نهایت آن ها بیان کردند که با توجه به توزیع لکه ای تلخه، امکان کنترل نقاط آلوده به این علف هرز و کاهش میزان سهم مصرفی و هزینه های کنترل وجود دارد. وجود توزیع لکه ای در علفهای هرز چند ساله ای نظیر شاهی و حشی<sup>۱</sup> (Makarian, 2008)، خارنه<sup>۲</sup> و

2 - *Cirsium arvense* (L.)

3 - *Sorghum halepense*

1 - *Cardaria draba* (L.)

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

### سپاسگزاری

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

مکان مناسب‌ترند (Colbach et al, 2000).

### 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 دقیق

### 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](http://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 15<sup>th</sup> 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. Abrahart, 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. Önyango, 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- Heijeteng, 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/pассив 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. Walther. 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. Najafî, 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 10<sup>th</sup> 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.