

پیش بینی الگوی توزیع مکانی جمعیت علف هرز تلخه (*Acroptilon repens* L.) با استفاده از

مدل شبکه عصبی مصنوعی بردار چندی ساز یادگیر (LVQ)

حسن مکاریان^{1*} و عباس روحانی²

تاریخ دریافت: 89/9/22 تاریخ پذیرش: 91/6/8

1- استادیار، گروه زراعت، علف‌های هرز، دانشکده کشاورزی، دانشگاه صنعتی شاهرود

2- استادیار، گروه مکانیزاسیون کشاورزی، دانشکده کشاورزی، دانشگاه فردوسی مشهد

مسئول مکاتبه: E-mail: h.makarian@yahoo.com

چکیده

پیشرفت‌های اخیر در کشاورزی دقیق سبب شده است تا مدل‌های قابل انعطاف مختلفی جهت پیش‌بینی، طبقه‌بندی و تهیه نقشه‌های دقیق از جمعیت علف‌های هرز به منظور کنترل متناسب بامکان آنها ارائه شود. این پژوهش به منظور پیش‌بینی الگوی پراکنش جمعیت علف هرز تلخه با استفاده از شبکه عصبی بردار چندی ساز یادگیر (LVQNN) در سطح مزرعه انجام شد. داده‌های مربوط به تراکم جمعیت علف هرز تلخه از طریق نمونه برداری بر روی یک شبکه علامت گذاری شده مربعی به ابعاد 2×2 متر و در مجموع از 550 نقطه از سطح مزرعه در حال آیش در شهرستان شاهرود واقع در استان سمنان در سال 1389 بدست آمد. برای ارزیابی قابلیت شبکه عصبی LVQ در پیش‌بینی توزیع مکانی علف هرز از مقایسه آماری پارامترهایی مانند میانگین، واریانس، توزیع آماری و رابطه رگرسیونی بین مقادیر پیش‌بینی شده مکانی توسط شبکه عصبی و مقادیر واقعی آنها و نیز معیار دقت کلاس بندی استفاده شد. نتایج نشان داد که در فاز آموزش، آزمایش و کل، به ترتیب مقادیر $p \geq 0/7$ ، $p \geq 0/8$ و $p = 1/000$ بدست آمد، که نشان دهنده عدم وجود تفاوت معنی داری در سطح 5 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 دقت تشخیص کمتر از 2/7 درصد بود. شبکه عصبی توانست پس از کلاس بندی، نقشه توزیع مکانی علف هرز تلخه را در تمام نقاط سطح مزرعه ترسیم نماید. نقشه حاصل از کلاس بندی نشان داد که علف هرز تلخه دارای توزیع لکه ای است و لذا امکان کنترل متناسب با مکان آن در مزرعه مورد مطالعه وجود دارد.

واژه‌های کلیدی: تلخه، توزیع لکه، کلاس بندی، شبکه عصبی، مدیریت دقیق علف هرز، نقشه

Prediction of Spatial Distribution Pattern of *Acroptilon repens* L. Population Using Learning Vector Quantization Neural Network Model

H Makaria^{1*} and A Rohani²

Received: December 13, 2010 Accepted: August 29, 2012

¹Assist Prof, Department of Agriculture, Faculty of Agriculture, Shahrood University, Iran.

²Assist Prof, Dept of Agricultural Mechanization, Faculty of Agriculture, Ferdowsi Mashhad University, Iran

*Corresponding Author: E-mail: h.makarian@yahoo.com

Abstract

Recent advances in precision farming technologies have triggered the need for highly flexible modelling methods to estimate, classificate and map weed population patterns for using in site-specific weed management. In this research, a learning vector quantization neural network (LVQNN) model was used to predict and classify the spatial distribution of *Acroptilon repens* L. density. This method was evaluated on data of *A. repens* L. density in a fallow field in Shahrood, Semnan province in 2010. Weed density assessments were performed following a 2 m × 2 m grid pattern on the field and a total of 550 sampling units on field. At each node of grid pattern, the numbers of *A. repens* L. seedlings were counted in the field within a permanent 50 cm by 50 cm quadrat. Some statistical tests, such as comparisons of the means, variance, statistical distribution as well as coefficient of determination in linear regression were used between the observed point sample data and the estimated weed seedling density surfaces to evaluate the performance of the pattern recognition method. Results showed that in training LVQNN, test and total phase P-value was greater than 0.7, 0.8 and 1 percent respectively, indicating that there was no significant ($p < 0.05$) difference between statsitcal parameters such as average, variance, statistical distribution and also coefficient of determination in the observed and the estimated weed seedling density. This results suggest that LVQ neural network can learn weed density model very well. In addition, results indicated that trained LVQ neural network has a high capability in predicting weed density with recognition accuracy of 2.7 percent at unsampled points. The technique showed that the LVQNN could classify and map *A. repens* L. spatial variability on the field. Our map showed that patchy weed distribution offers large potential for using site-specific weed control on this field.

Keywords: Classification, Map, Neural network, Patchy distribution, Precision weed management, Russian knapweed.

مقدمه

سازد افزایش صحت و دقت روش های درون یابی و تهیه نقشه های کاربردی از جمعیت علف های هرز است. درونیابی مکانی شامل تخمین متغیرهایی مانند تراکم گیاهچه علف هرز، زیست توده² و عملکرد گیاه زراعی و غیره در نقاط نمونه برداری نشده با استفاده از داده های بدست آمده از نقاط نمونه برداری شده می باشد. به عبارتی یک روش درونیابی ایده ال قادر است تا با استفاده از اطلاعات مربوط به تراکم علف های هرز در تعداد نقاط محدود نمونه برداری شده (دارای مشاهده)، تراکم علف های هرز را در نقاط نمونه برداری نشده به درستی تخمین بزند (مکاریان 2008). دزیانت و کازانل (1994) از روش آنالیز روند سطحی³ که یک روش درونیابی است جهت توصیف پراکنش جوامع علف هرز در یک مزرعه ذرت استفاده کردند. آنها با برآزش یک تابع چندجمله ای، توزیع مکانی علف های هرز را نشان دادند. از دیگر روش های درونیابی مورد استفاده در مطالعات علم علف های هرز روش های مثلث بندی خطی⁴ و کریجینگ⁵ را می توان نام برد. در روش مثلث بندی خطی برای درونیابی، به مقادیر نزدیکترین سه نقطه نمونه برداری شده وزن یکسانی داده می شود (ایساک و اسریواستاوا 1989). کریجینگ نیز با استفاده از سمی واریوگرام ها با ترکیب وزن های داده شده به داده های نقاط مجاور، خطای مربوط به مقادیر پیش بینی شده را محاسبه می کند (گاتوی و همکاران 1996). به هرحال یکی از نارسایی های روش های متداول در آمار کلاسیک عدم توجه به سودمندی اطلاعات مربوط به موقعیت جغرافیایی مشاهدات بوده و متعاقب آن در تجزیه و تحلیل چنین داده هایی هیچگونه ارتباط ریاضی بین تغییرات مکانی نمونه ها بعنوان تابعی از فاصله بین آنها برقرار نمی شود (مکاریان و همکاران 2007). مطالعات متعددی نشان

امروزه توسعه روش دقیق تر در تولید محصولات کشاورزی یکی از راهکارها در جهت به حداقل رساندن فشار ناشی از عملیات کشاورزی بر کیفیت محیط زیست می باشد (گاتیریز و همکاران 2008). کاربرد متناسب با مکان نهاده های کشاورزی (مانند کودها، علفکش ها و...) بر اساس نقشه های صحیح و دقیق، عامل کلیدی در کاربرد موفق کشاورزی دقیق است که در نهایت منجر به کاهش کمیت نهاده های مصرفی و نیز آلودگی های زیست محیطی خواهد شد (کریمی و همکاران 2005). علف های هرز در قسمت هایی از مزرعه که شرایط موضعی برای سبز شدن آنها فراهم است تجمع می یابند یا به عبارت دیگر علف های هرز پراکنش یکنواخت و یا تصادفی ندارند بلکه در مقیاس های مختلف دارای توزیع لکه هستند (کلی و همکاران 2006 و گونزالز-آندوجار و سودرا 2003) که این امر به دلیل اثرات متقابل بیولوژی علف هرز، شرایط موضعی ریزاقلیم¹ و عملیات مدیریتی می باشد (بیگوود و اینوی 1988). توصیف، پیش بینی و مدیریت جوامع علف هرز نیازمند شناخت الگوهای توزیع علف های هرز و تاثیر الگوها بر پویایی جمعیت می باشد (ویلز 2005). شناخت الگوهای پراکنش علف های هرز اثرات قابل توجهی بر پیش بینی کاهش عملکرد، مدلسازی و مدیریت پایدار آنها داشته و می تواند سبب کاهش هزینه ها و نیز کاهش ورود مواد شیمیایی به محیط زیست شده و از طرفی سبب کنترل بهتر جمعیت علف های هرز در لکه ها شود (ویلیامز و همکاران 1999). به همین خاطر امروزه تحقیقات زیادی در مورد تهیه و استفاده از نقشه های توزیع علف های هرز با استفاده از مدلسازی پویایی جمعیت علف های هرز به منظور بکارگیری در مدیریت متناسب با مکان در حال انجام است (دیل و همکاران 2003). اما آنچه رسیدن به این اهداف را محقق می

² Biomass³ Trend surface⁴ Linear triangulation⁵ Kriging¹ Microclimate

و شایستگی شبکه آموزش دیده در شرایط کاملا جدید توسط مجموعه داده های غیر از داده های آموزش گویند (گوبتا و همکاران 2003 و ویلنترف 1995). امروزه شبکه های عصبی می توانند آموزش ببینند تا با دقت بالا جمعیت علف هرز را از گیاه زراعی در مزارع متمایز کنند (یانگ و همکاران 2003). شبکه های عصبی مصنوعی پتانسیل بالایی در تفکیک گیاهان زراعی مختلف در ماشین های بصری² دارند. بعنوان مثال این مدل ها توانسته اند سیب زمینی را بر اساس رنگ سبز برگ ها با 74 درصد دقت و براساس شکل برگ با 73/3 درصد دقت طبقه بندی کنند (دیک و همکاران 1995). علاوه براین شبکه های عصبی مصنوعی در تفکیک پوشش های گیاهی و نیز علف های هرز در روش های سنجش از دور مورد استفاده قرار گرفته است (گوئل و همکاران 2003 و کریمی و همکاران 2005 و شنین و همکاران 2002). گرچه با استفاده از این مدل ها توانسته اند روابط غیر خطی پیچیده و مرکب را با استفاده از تصاویر تهیه شده از کانوپی برای چند گیاه زراعی تشریح نمایند، اما این تکنیک در پیشگویی متغیرهای پیوسته ای مانند رطوبت خاک (چنگ و اسلام 2000)، ارزیابی کیفیت آب (زنگ و همکاران 2002)، تخمین بیوماس (حین و لیو 1997) و تخمین عملکرد (دراموندا و همکاران 2003) نیز پتانسیل بالایی نشان داده است. مدل های شبکه عصبی دارای مزایایی از قبیل افزایش ظرفیت اطلاعات و توانایی بیان اثرات متقابل قوی بین متغیرهای ورودی می باشند. آیتکنهد و همکاران (2003) با استفاده از مدل شبکه عصبی پرسپترون چند لایه³ (MLP) برای تشخیص و تمایز بین گیاه زراعی هویج، علف هرز چچم و خاک مزرعه استفاده کردند. تمایز بین آفتابگردان، توت و پس زمینه خاک نیز با استفاده از یک شبکه عصبی MLP توسط کودیر (2004) انجام

داده است که شبکه های عصبی توانایی بالایی در تشخیص الگوهای توزیع مکانی جمعیت های اکولوژیکی دارند (مکاریان و روحانی 1389، گوئل و همکاران 2003، دراموند و همکاران 2003، ایرماک و همکاران 2006). در پژوهشی مدل شبکه عصبی بردار چندی ساز یادگیر¹ (LVQNN) توسط زنگ و همکاران (2008) برای مطالعه توزیع مکانی حشرات در اراضی مرتعی استفاده شد و کارائی مطلوبی نشان داد.

شبکه عصبی مصنوعی دارای ساختاری شبیه سیستم عصبی بیولوژی مغز انسان است (تورسیلا و همکاران 2004). امروز شبکه های عصبی در بسیاری از زمینه ها از جمله طبقه بندی، تشخیص الگو، پیش بینی و مدلسازی فرآیند ها در علوم مختلف بکار گرفته می شوند. مزیت روش شبکه عصبی یادگیری مستقیم از روی داده ها، بدون نیاز به برآورد مشخصات آماری آنها است (وکیل باغمیشه 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 ورودی ها و خروجی ها برای پیش بینی هر خروجی متناظر با ورودی دلخواه می باشد (کائول و همکاران 2005 و تورسیلا و همکاران 2004). ویژگی دیگر شبکه عصبی، تحمل پذیری در مقابل خطا می باشد (آزاده و همکاران 2006). این مزایا دلایل بکارگیری شبکه عصبی در پیش بینی تراکم علف های هرز را برای ما روشن می سازد. شبکه های عصبی شامل تعدادی نرون های متصل بهم هستند. مراحل اصلی حل هر مسئله توسط شبکه عصبی شامل آموزش و آزمایش می باشد. آموزش، فرآیند یادگیری مجموعه داده های ورودی بمنظور تشخیص الگوهای آن توسط شبکه می باشد. روش آموزش را قانون یادگیری گویند و اتصالات وزنی بین نرون ها از طریق قانون یادگیری در طول فاز آموزش اصلاح می شوند. آزمایش، ارزیابی قابلیت تعمیم پذیری

² Machine vision³ Multi layer perceptron¹ Learning Vector Quantization Neural Network

از جمعیت علف هرز تلخه در سطحی به ابعاد 20×100 متر (2000 مترمربع) بر روی یک شبکه علامت گذاری شده مربعی¹ به ابعاد 2×2 متر انجام و در مجموع از 550 نقطه از کل سطح مزرعه نمونه برداری انجام شد. نمونه برداری از جمعیت علف‌های هرز در مرداد ماه با استفاده از کادرهای مربعی به ابعاد 50×50 سانتی متر (مساحت 25/ مترمربع) در محل تقاطع خطوط شبکه مربعی انجام شد. بطوریکه در هرکوارات جمعیت علف هرز تلخه شناسایی و شمارش شد. سپس داده ها در مدل مورد استفاده قرار گرفت.

شبکه عصبی LVQ

شبکه عصبی LVQ یکی از روش های طبقه بندی و خوشه بندی است. نحوه کار آن بر اساس تقسیم فضای ورودی \mathcal{R}^n به تعدادی منطقه های متمایز از هم با نام ناحیه های تصمیم گیری² و اختصاص یک بردار کد³ به هر یک از آنها است. کلاس 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 مرکز های آنها ثابت نشود ادامه خواهد یافت. از بین شش گونه الگوریتم آموزش با نام های LVQ1، LVQ2.1، LVQ3، LVQ4 (کوهورن 1990 و 1995) و LVQ4 (وکیل باغمیشه 2002 و وکیل باغمیشه و پائوسیک 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:

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

شد. ارماک و همکاران (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. درحال حاضر، مطالعات متعددی به منظور پیش بینی و تهیه نقشه های دقیق پوشش های گیاهی، تغییرات زیست توده و عملکرد و غیره با روش های مختلف درونیابی در حال انجام است و هدف اصلی در همه آنها تهیه نقشه های قابل اطمینان جهت مدیریت دقیق مزارع می باشد. بنابراین هدف ما نیز در این مطالعه، ارزیابی قابلیت شبکه عصبی بردار چندی ساز یادگیر (LVQNN) به عنوان یک روش نوین جایگزین در پیش بینی و طبقه بندی تراکم علف هرز مهاجم تلخه (*Acroptilon repens* L.) در نقاط نمونه برداری نشده بر اساس داده های حاصل از نقاط نمونه برداری شده در یک مزرعه در حال آیش بود.

مواد و روش ها

داده های مورد استفاده در این آزمایش در سال 1389 از یکی از مزارع در حال آیش دانشکده کشاورزی دانشگاه صنعتی شاهرود واقع در استان سمنان جمع آوری گردید. طول و عرض جغرافیایی محل به ترتیب $54'$ و $58'$ شمالی و $36'$ و 25° شرقی و ارتفاع محل از سطح دریا $1349/1$ متر می باشد. میانگین بارندگی سالیانه منطقه 150 میلی متر، میانگین سالانه دما $14/4$ درجه سانتیگراد می باشد. مزرعه انتخابی به ابعاد 2000 مترمربع بود. از بین گونه های علف هرز موجود در این مزرعه تلخه (علف هرز پهن برگ چندساله) دارای بالاترین تراکم در واحد سطح بود و از طرفی به گفته راشد محصل و همکاران (1380) تلخه یکی از مهمترین علف های هرز مزارع و مراتع در ایران بشمار می رود. بنابراین در این پژوهش توزیع جمعیت این علف هرز مورد مطالعه قرار گرفت. نمونه برداری

¹Grid

²Decision regions (Voronoi cells)

³Codebook (Voronoi) vector

و w_m بردار کد باشد

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

1- پیدا کردن نزدیکترین بردار کد به x^q :

$$c = \operatorname{argmin}_m (\|x^q - w_m\|) \quad [1]$$

2- تنظیم w_c :

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

$\alpha(n)$ آهنگ یادگیری در طول زمان آموزش از رابطه

زیر بدست آمد.

[3]

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

اگر کلاس بندی صحیح باشد $d_c(n)=s(n)$ می باشد و

در صورتی که 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:



شکل 1- ساختار شبکه LVQ استفاده شده برای پیش بینی مکانی وجود علف هرز. (X, Y) مختصات نقاط نمونه

بردارای شده، W ماتریس بردارهای کد و W_{win} برچسب بردار کد برنده شده.

نتایج و بحث

تعداد بردارهای کد، خطای تشخیص در مرحله

آموزش و آزمایش و تعداد تکرارهای مورد نیاز

الگوریتم آموزش برای یادگیری در جدول 1 نشان داده

[5]

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

$0 < \varepsilon < 1$ و $\lambda \geq 1$ می باشد. مقادیر توصیه شده $\varepsilon = 0/2$ و

$\lambda = 10$ است (وکیل باغمیشه و پاوسیک 2003).

هدف در استفاده از شبکه Lvq کلاس بندی

سطح مزرعه به دو کلاس است. کلاس اول نقاطی از

مزرعه که دارای علف هرز هستند و نقاط دیگری که

فاقد علف هرز می باشند. از بین 550 نقطه نمونه

بردارای شده، 295 نقطه فاقد علف هرز و 255 نقطه

دارای علف هرز بودند. به طور کاملا تصادفی، 80

درصد از کل داده ها برای آموزش شبکه و 20 درصد

باقی مانده برای آزمایش شبکه بمنظور کلاس بندی

انتخاب شد. ساختار شبکه عصبی Lvq 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 1 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 7 انجام شد.

شده است. بر اساس نتایج مندرج در جدول 1، درصد

خطای تشخیص در دو مرحله آموزش و آزمایش شبکه

عصبی با افزایش تعداد بردارهای تعیین کننده هر کلاس

روند نزولی دارند. همچنین با افزایش تعداد بردارهای

کد، تعداد تکرارهای مورد نیاز برای یادگیری شبکه

شبکه عصبی به واسطه تازگی داده ها برای شبکه عصبی می باشد. براساس نتایج حاصل شده می توان توصیه کرد که حداقل تعداد بردارهای کد برای کلاس بندی علف های هرز در سطح مزرعه توسط شبکه عصبی **Lvq** باید 80 درصد تعداد کل داده های هر کلاس باشد.

کاهش می یابد و این موجب کم شدن مدت زمان آموزش خواهد شد. افزایش تعداد بردارهای کد از 10 به 100 درصد، به ترتیب، باعث کاهش تعداد تکرارهای الگوریتم آموزش، خطای آموزش و خطای آزمایش تا حدود 85، 96 و 85 درصد خواهد شد. بالا بودن درصد خطای تشخیص در فاز آزمایش نسبت به فاز آموزش


جدول 1- خطای تشخیص و تعداد تکرارهای الگوریتم در فاز آموزش و آزمایش بر حسب افزایش تعداد بردارهای کد.

100	90	80	70	60	50	40	30	20	10	Np(%)
0/4	3	5	7	8	16	14	18	21	25	Re _{train} (%)
7	10	10	12	15	20	25	35	35	50	N _{train}
1/7	8	7	15	17	17	20	25	30	30	Re _{test} (%)

توضیحات: **Np**: تعداد بردارهای کد هر کلاس نسبت به تعداد نمونه های هر کلاس بر حسب درصد، **Re_{train}**: خطای تشخیص در فاز آموزش، **Re_{test}**: خطای تشخیص در فاز آزمایش، **N_{train}**: تعداد تکرارهای الگوریتم

افزایش تعداد تکرارهای الگوریتم نیز موجب حرکت بردارهای کد به موقعیت دیگری نخواهند شد. لذا ادامه آموزش بی فایده خواهد بود. بنابراین باید آموزش شبکه را متوقف کرد. معیار توقف الگوریتم بر اساس همین فرض بنا نهاده شد. می توان با توجه به این نمودار مقدار **q₀** در رابطه 1 را پیدا کرد. نتایج نشان داد که 2 تکرار (**q₀ = 2**) می تواند مقدار بهینه برای شروع کم شدن آهنگ یادگیری باشد.

نمودار همگرایی شبکه عصبی **Lvq** در مدت زمان آموزش در شکل 2 نشان داده شده است. خطای تشخیص یا کلاس بندی از تعداد 26 نقطه (**Re=26**) برای کل مجموعه آموزش شروع و به تدریج کم تر می شود و بعد از 5 تکرار (**q=5**)، خطا ثابت باقی می ماند زیرا مرکزها و ناحیه های تشخیص هر بردار کد بدون تغییر می مانند.



شکل 2- نمودار همگرایی شبکه عصبی **Lvq** در طول مدت آموزش. **q**: تعداد تکرارهای آموزش شبکه و **Re**: خطای کلاس بندی در مرحله آموزش.

پیش‌بینی شده سه مجموعه داده در سطح 5 درصد اختلاف معنی داری با هم ندارند. بنابراین شبکه عصبی Lvq آموزش دیده، دارای قابلیت بالایی برای پیش‌بینی موقعیت علف هرز در سطح مزرعه است. زنگ و همکاران (2010) با استفاده از شبکه عصبی بردار چندی ساز یادگیر (Lvq) 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. در پژوهش حاضر نیز جمعیت علف هرز تلخه با توجه به سطوح آستانه فرضی صفر، 2، 4 و 6 بوته در هر کوادرات با شبکه عصبی پیش‌بینی و کلاس بندی شد (شکل 3). این کلاس بندی می‌تواند در مدیریت متناسب با مکان علف هرز نقش مهمی ایفا کند.

برای اطمینان از قابلیت شبکه عصبی آموزش دیده در پیش‌بینی موقعیت علف‌های هرز، داده‌های واقعی و داده‌های پیش‌بینی شده توسط شبکه، از نظر آماری با هم مقایسه شد. در اینجا فرضیه صفر بر تساوی میانگین، واریانس و توزیع آماری هر دو سری داده دلالت دارد. هر فرضیه در سطح احتمال 95 درصد به کمک پارامتر p آزمایش شد. به ترتیب برای مقایسه میانگین، واریانس و توزیع آماری از آزمون‌های F ، t و کولموگروف-اسمیرنو استفاده شد. مقادیر p محاسبه شده برای هر سه مجموعه داده‌های آموزش، آزمایش و کل در جدول 2 نشان داده شده است. بطوریکه در فاز آموزش، آزمایش و کل، به ترتیب مقادیر $p \geq 0/7$ ، $p \geq 0/8$ و $p = 1/000$ بدست آمد. نتایج نشان داد که میانگین، واریانس و توزیع آماری مقادیر واقعی و

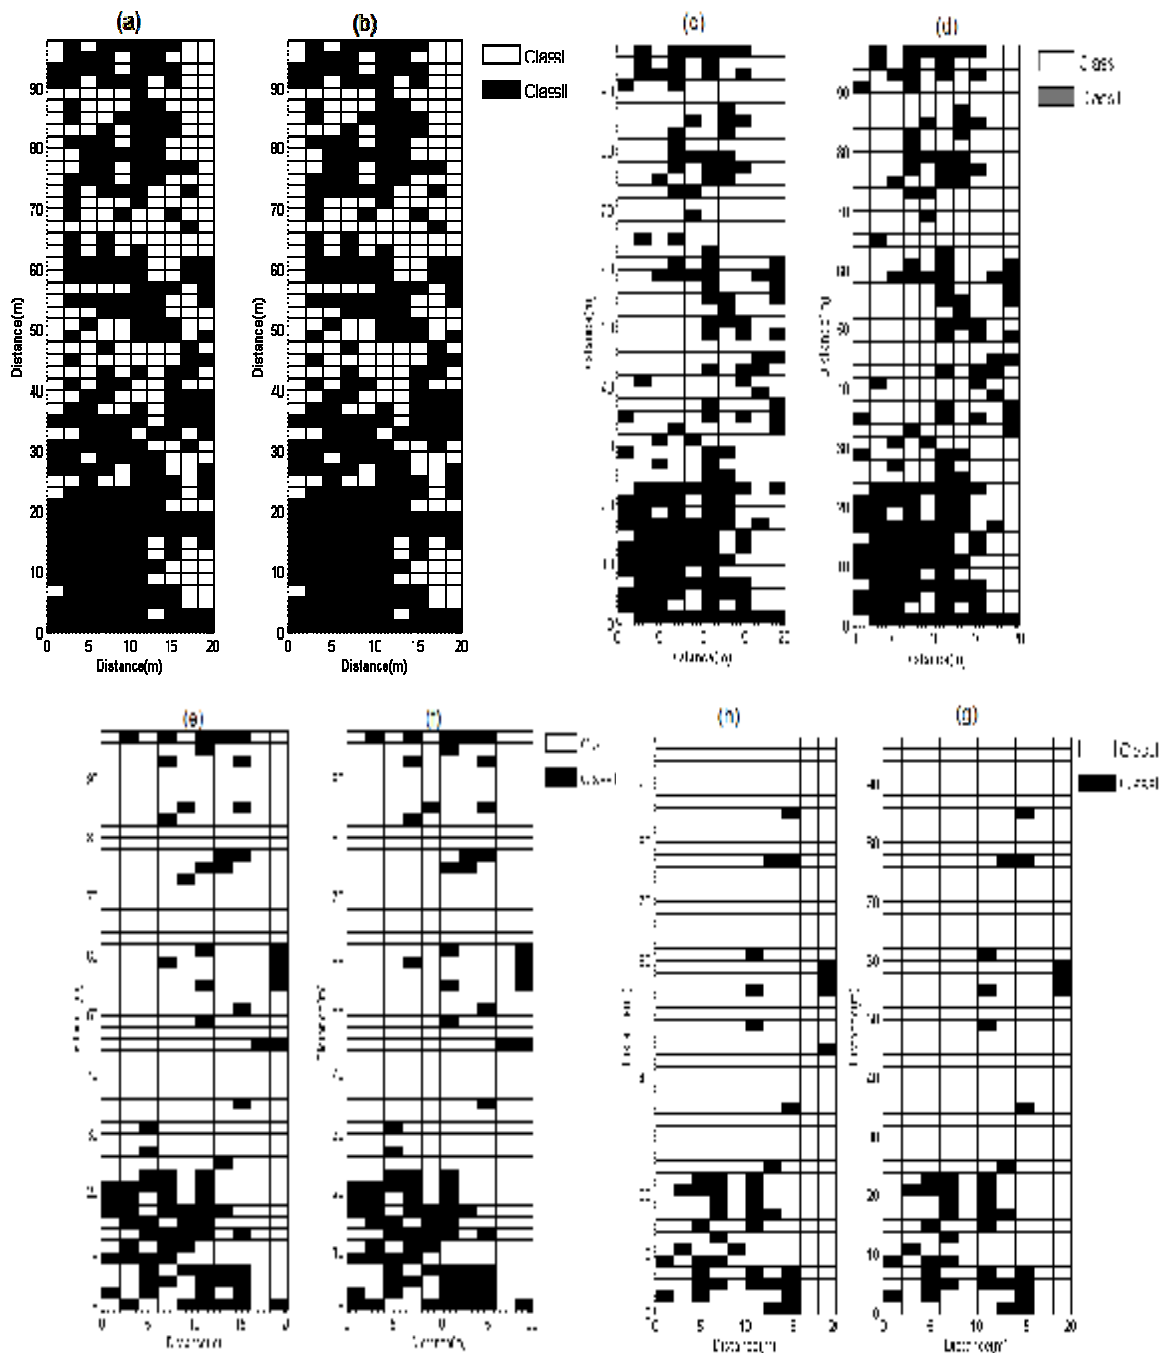
جدول 2- مقادیر p حاصل از مقایسات آماری بین مقادیر واقعی و پیش‌بینی شده موقعیت علف هرز تلخه در مرحله‌های آموزش، آزمایش و همچنین کل داده‌ها.

نوع تحلیل آماری	مقایسه واریانس		مقایسه میانگین	فاز آموزش
	مقایسه توزیع			
	1/000	0/984	0/945	فاز آموزش
	1/000	0/838	0/766	فاز آزمایش
	1/000	0/995	0/952	کل

نقشه توزیع مکانی علف هرز تلخه

e و f و 3 و g و h جمعیت تلخه بترتیب به دو کلاس مساوی یا کمتر از 4 و بیشتر از 4 بوته در متر مربع و مساوی یا کمتر از 6 و بیشتر از 6 بوته در متر مربع تقسیم شده است. هر یک از سطوح صفر، 2، 4 و 6 بوته انتخاب شده می‌تواند حد آستانه فرضی برای علف هرز باشد تا به کمک آن قابلیت شبکه عصبی نشان داده شود. آستانه اقتصادی به صورت تراکمی از علف‌هرز تعریف شده که در آن هزینه کنترل علف‌هرز معادل سود حاصل از کنترل است (اودونوان 1991). آستانه

نقشه پراکنش مکانی علف هرز تلخه که توسط شبکه عصبی Lvq تفکیک و ترسیم شده در شکل 3 نشان داده شده است. در این شکل ابتدا جمعیت علف هرز تلخه به دو کلاس جمعیتی فاقد علف هرز(صفر بوته) و دارای علف هرز تقسیم شده و نقشه‌های آن ترسیم شد (شکل 3 a و b). اما در شکل 3 c و d جمعیت علف هرز به دو کلاس مساوی یا کمتر از 2 و بیشتر از دو بوته در متر مربع تقسیم شده است. در شکل‌های 3



شکل 3- نقشه توزیع جمعیت علف هرز تلخه در دو حالت واقعی (شکل های a ، c ، e و h) و تفکیک شده توسط مدل شبکه عصبی Lvq (شکل های b ، d ، f و g) : Class I. در شکل های a و b نقاطی از مزرعه که فاقد علف هرز هستند و در شکل های c و d نقاطی از مزرعه که دارای کمتر از دو بوته علف هرز در متر مربع و در شکل های e و f نقاطی از مزرعه که دارای کمتر از چهار بوته علف هرز در متر مربع و در شکل های g و h نقاطی از مزرعه که دارای کمتر از شش بوته علف هرز در متر مربع هستند. در شکل های a و b نقاطی از مزرعه که دارای علف هرز هستند و در شکل های c و d نقاطی از مزرعه که دارای تعداد بیشتر از دو بوته علف هرز در متر مربع و در شکل های e و f نقاطی از مزرعه که دارای تعداد بیشتر از چهار بوته علف هرز در متر مربع و در شکل های g و h نقاطی از مزرعه که دارای تعداد بیشتر از شش بوته علف هرز در متر مربع هستند.

شبکه عصبی LVQ، MLP و روش تفکیک خطی¹ 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 کارایی مدل های شبکه عصبی موثر دانستند. در آزمایش زنگ و همکاران (2008) شبکه LVQ، از نظر دقت تشخیص حدواسط دو شبکه دیگر قرار گرفت. اما در آزمایش ما نیز شبکه LVQ، در تعیین الگوهای پراکنش علف های هرز کارایی بسیار خوبی داشت. بنابراین به نظر می رسد با توجه به ویژگی های اکولوژیکی متفاوت حشرات و علف های هرز در سطح مزارع، تفاوت در عملکرد شبکه LVQ در دو آزمایش دور از ذهن نباشد.

نقشه های تهیه شده نشان داد که لکه ها در راستای ردیف های گیاه زراعی فصل قبل و یا جهت شخم کشیده تر می باشد. در اراضی کشاورزی بذور و اندام های رویشی تکثیر شونده علف های هرز بوسیله عملیات مدیریتی مختلف از جمله شخم، آبیاری، برداشت، چرای حیوانات، فعالیت های زارعین و عوامل محیطی در سطح مزرعه جابجا می شوند (شوکت و صدیقی 2004). علف هرز تلخه گیاهی چندساله و مهاجم از خانواده کاسنی² است که قادر به تکثیر از طریق بذر می باشد، اما این گیاه عمدتاً از طریق پراکنش قطعات ریشه بوسیله عوامل گوناگون تکثیر می شود. تلخه در مکان هایی که رطوبت بیشتر است یا دارای بافت خاک سبک است، لکه های متراکمی ایجاد می کند (روبرت و همکاران 2004). آرایش ناهمگون علف هرز تلخه در این مطالعه نشان داد که استراتژی های نمونه برداری مدل های اکولوژیکی که توزیع تصادفی علف های هرز را مبنای کار خود قرار داده اند قادر به توصیف صحیح این قبیل جوامع نمی باشند. این پژوهش نشان

خسارت اقتصادی به کشاورز در جهت تصمیم گیری صحیح در مورد کنترل علف های هرز کمک می کند. بدین ترتیب که نقاط دارای تراکم بیشتر از حد آستانه در مدیریت متناسب با مکان مورد تیمار قرار می گیرد و سایر نقاط که زیر حد آستانه قرار دارند نیاز به کاربرد علفکش یا هر عملیات کنترلی ندارند یا به عبارتی قابل تحمل هستند. کلی و همکاران (2006) با استفاده از روش درونیابی میزان کاهش عملکرد ذرت دانه ای را در اثر رقابت با علف های هرز باریک برگ یکساله بصورت مکانی 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 تحقیقات تعریف شده باشد، برای کاربرد عملی آن، نقشه های تهیه شده با شبکه عصبی Lvq ابزارهای موثر و دقیقی خواهد بود که به مدیر مزرعه جهت کنترل متناسب با مکان (نقاط بالای حد آستانه) کمک خواهد کرد. در نقشه ترسیم شده لکه هایی از علف هرز با اشکال و اندازه های متفاوت به چشم می خورد. نقشه نشان می دهد که دامنه تغییرات لکه های آلوده در سطح مزرعه بالاست. توزیع ناهمگون و تجمعی علف هرز تلخه در این شکل ها به خوبی مشهود است.

مکاریان و روحانی (1389) الگوی توزیع جمعیت علف هرز جوموشی را با استفاده از شبکه عصبی پرسپترون چند لایه (MLP) مورد مطالعه قرار دادند و نتیجه گرفتند که شبکه عصبی پرسپترون چند لایه می تواند به خوبی لکه های علف هرز را پیش بینی کرده و نقاط با جمعیت کم یا زیاد را در سطح مزرعه مشخص نماید. تهیه نقشه هایی که بطور دقیق لکه های علف هرز را نشان دهند یکی از اهداف مهم در مدیریت لکه ای علف های هرز می باشد (کلی و همکاران 2006). زنگ و همکاران (2008) در مقایسه سه مدل

¹ Linear Recognition Method

² Asteraceae

که تلخه دارای آرایش لکه‌ای است. بنابراین راهکار مدیریت متناسب با مکان در کنترل موثرتر این علف هرز و نیز کاهش سموم و هزینه‌های مصرفی نقش موثری ایفا خواهد کرد.

داد که شبکه عصبی Lvq توانست علاوه بر پیش بینی، نقشه پراکنش جمعیت علف هرز تلخه را به خوبی ترسیم نماید. شبکه عصبی می‌تواند بر اساس هر آستانه تعیین شده نقشه‌های مدیریتی برای اعمال تیمار نقاط بالای حدآستانه تهیه کند. نقشه حاصل از شبکه نیز نشان داد

منابع مورد استفاده

- راشد محصل م ح، نجفی ح و اکبرزاده م، 1380. بیولوژی و کنترل علف‌های هرز. انتشارات دانشگاه فردوسی مشهد.
- مکاریان، ح. و روحانی، ع. 1389. پیش بینی الگوی توزیع جمعیت علف هرز جوموشی (*Hordeum glaucum steud.*) با استفاده از شبکه عصبی مصنوعی. نشریه حفاظت گیاهان (علوم و صنایع کشاورزی). شماره 4، صفحه‌های 480-471.
- Aitkenhead MJ, Dalgetty IA, Mullins CE, McDonald AJS and Strachan NJC, 2003. Weed and crop discrimination using image analysis and artificial intelligence methods. *Computers and Electronics in Agriculture* 39: 157-171.
- Azadeh A, Ghaderi SF and Sohrabkhani S, 2006. Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. *Applied Mathematics and Computation* 186: 1753-1761.
- Bigwood DB and Inouye DW, 1988. Spatial pattern analysis of seed banks: an improved method and optimized sampling. *Ecology* 69: 497-507.
- Chang DH and Islam S, 2000. Estimation of soil physical properties using remote sensing and artificial neural network. *Remote Sensing of Environment* 74: 534-544.
- Clay SA, Kreutner B, Clay DE, Reese C, Kleinjan J and Forcella F, 2006. Spatial distribution, temporal stability, and yield loss estimates for annual grasses and common ragweed (*Ambrosia artemisiifolia*) in a corn /soybean production field over nine years. *Weed Science* 54: 380-390.
- Deck SH, Morrow CT, Heinemann DH and Sommer HJ, 1995. Comparison of a neural network approach. *Transactions of the American Society of Agricultural and Biological Engineers* 39: 2319-2324.
- Dessiant F, and Caussanel JP, 1994. Trend surface analysis: a simple tool for modeling spatial patterns of weeds. *Crop Protection* 13: 433-438.
- Dille JA, Milner M, Groeteke JJ, Mortensen DA and Williams II, MM, 2003. How good is your weed map? A comparison of spatial interpolators. *Weed Science* 51: 44 – 55.

- Drummond ST, Sudduth KA, Joshi A, Birrell SJ, Kitchen NR, 2003. Statistical and neural methods for site-specific yield prediction. Transactions of the American Society of Agricultural and Biological Engineers 46: 5–14.
- Goel PK, Prasher SO, Patel RM, Landry JA, Bonnell RB, and Viau AA, 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.
- Gonzales-Andujar JL and Saavedra M, 2003. Spatial distribution of annual grass weed populations in winter cereals. Crop Protection 22: 629-633.
- Gotway CA, Ferguson RB, Hergert GW, and Peterson TA, 1996. Comparison of kriging and inverse distance methods for mapping soil parameters. Soil Science Society America Journal 60: 1237-1247.
- Gupta MM, Jin J and Homma N, 2003. Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory. John Wiley & Sons, Inc., Hoboken, New Jersey.
- Gutierrez PA, Lopez-Granados F, Pena-Barragan JM, Jurado-Exposito M, Gomez- Casero, MT and Hervas-Martinez C, 2008. Mapping sunflower yield as affected by *Ridolfia segetum* patches and elevation by applying evolutionary product unit neural networks to remote sensed data. computers and electronics in agriculture 60 : 122-132.
- Irmak A, Jones JW, Batchelor WD, Irmak S, Boote kJ and Paz Jo, 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.
- Isaaks EH, and Srivastava RM, 1989. An introduction to Applied Geostatistics. Oxford University Press, New York.
- Jin YQ and Liu C, 1997. Biomass retrieval from high-dimensional active/passive remote sensing data by using artificial neural networks. International Journal of Remote Sensing 18: 971–979.
- Karimi Y, Prasher SO, McNairn H, Bonnell RB, Dutilleul P and Goel PK, 2005. Classification accuracy of discriminate analysis, artificial neural networks, and decision trees for weed and nitrogen stress detection in corn. Transactions of the American Society of Agricultural and Biological Engineers 48 :1261–1268.
- Kaul M, Hill RL and Walthall C, 2005. Artificial neural networks for corn and soybean yield prediction. Agriculture system 85: 1-18.
- Kavdir S, 2004. Discrimination of sunflower, weed and soil by artificial neural networks. Computer and Electronic in Agriculture 44: 153-160.
- Kohonen T, 1990. The Self-Organizing Map, Proceedings of IEEE, Vol. 78, No. 9.
- Kohonen T, 1995. Self-Organizing Map, Spriger-Verlag, Berlin, Heidelberg.

- Makarjian 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.
- Makarjian H, Rashed Mohassel MH, Bannayan M and Nassiri M, 2007. Soil seed bank and seedling populations of *Hordeum murinum* and *Cardaria draba* in saffron fields. Agriculture Ecosystems and Environment 120: 307- 312.
- O Donovan JT, 1991. Quackgrass (*Elytrigia repens*) interference in canola (*Brassica campestris*). Weed Science 39: 397-401.
- Roberts EA, Sheley, RL and Lawrence, RL, 2004. Using sampling and inverse distance weighting modeling for mapping invasive plants. Western North American Naturalist 64: 312-323.
- Shanin MA, Tollner EW, McClendon RW and Arabnia HR, 2002. Apple classification based on surface bruises using image processing and neural networks. Trans. American Society of Agricultural and Biological Engineers 45:1619–1627.
- Shaukat SS and Siddiqui IA, 2004. Spatial pattern analysis of seed bank and its relationship with above-ground vegetation in an arid region. Journal of Arid Environments 57: 311-327.
- Torrecilla JS, Otero L and Sanz PD, 2004. A neural network approach for thermal/pressure food processing. Food Engineer 62: 89-95.
- Vakil-Baghmisheh MT, 2002. Farsi Character Recognition Using Artificial Neural Networks. PhD Thesis, Faculty of Electrical Engineering, University of Ljubljana.
- Vakil-Baghmisheh MT and Pavešić N, 2003. Premature clustering phenomenon and new training algorithms for LVQ. Pattern recognition 36: 1901-1921.
- Veelenturf LPJ, 1995. Analysis applications of artificial neural networks. Simon & Schuster international group, United States of America.
- Wiles L and Schweizer E, 2002. Spatial dependence of weed seed banks and strategies for sampling. Weed Science 50: 595- 606.
- Wiles L, 2005. Sampling to make map for site specific weed management. Weed Science 53: 228-235.
- Williams MM, Gerhards R and Mortensen DA, 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.
- Yang CC, Prasher SO, Landry JA, and Ramaswamy HS, 2003. Development of a herbicide application map using artificial neural networks and fuzzy logic. Agricultural Systems 76: 561-574.
- Zhang Y, Pulliainen J, Koponen S and Hallikainen M, 2002. Application of an empirical neural network to surface water quality estimation in the Gulf of Finland using combined optical data and microwave data. Remote Sensing of Environment 81: 327–336.

- Zhang YL, Wu HF and Huang JF, 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 .
- Zhang, WJ, Zhong XQ and Liu G H, 2008. Recognizing spatial distribution patterns of grassland insects: neural network approaches. *Stochastic Environmental. Research and Risk Assessment*, 22:207–216.