

پیش بینی الگوی توزیع جمعیت علف هرز جوموشی (*Hordeum glaucum steud.*) با استفاده از شبکه عصبی مصنوعی

حسن مکاریان^{۱*} - عباس روحانی^۲

تاریخ دریافت: ۸۹/۳/۱۶

تاریخ پذیرش: ۸۹/۱۲/۱۱

چکیده

امروزه تشریح الگوهای توزیع مکانی جمعیت علف های هرز با استفاده از روش های درونیایی و تخمین تراکم به منظور بررسی امکان کنترل متناسب با مکان آنها مورد توجه بسیاری از محققین قرار گرفته است. این پژوهش به منظور ارزیابی قابلیت مدل شبکه عصبی پرسپترون چندلایه ای (MLPNN) در درونیایی و تخمین جمعیت گیاهچه علف هرز جوموشی در نقاط نمونه برداری نشده و نیز ترسیم نقشه پراکنش آن انجام شد. داده های مربوط به تراکم جمعیت علف هرز جوموشی از طریق نمونه برداری از سطح یک مزرعه زعفران در خراسان جنوبی بدست آمد. برای ارزیابی قابلیت شبکه عصبی MLP در درونیایی تراکم علف هرز از مقایسه آماری پارامترهایی مانند میانگین، واریانس، توزیع آماری و نیز ضریب تبیین معادله خطی رگرسیونی بین مقادیر پیش بینی شده توسط شبکه عصبی و مقادیر واقعی آنها استفاده شد. نتایج نشان داد که در فاز آموزش، آزمایش و کل، به ترتیب مقادیر $p \geq 0/49$ ، $p \geq 0/18$ و $p \geq 0/27$ بدست آمد که نشان دهنده عدم وجود تفاوت معنی داری در سطح ۵ درصد بین مقادیر ویژگی های آماری (میانگین، واریانس و توزیع آماری) مجموعه داده های پیش بینی شده تراکم علف هرز و مقادیر واقعی آنها بود. به عبارتی شبکه عصبی مصنوعی به خوبی توانست مدل داده های تراکم علف هرز را بیاموزد. نتایج نشان داد که شبکه عصبی آموزش دیده، دارای قابلیت بالایی در پیش بینی تراکم علف هرز در نقاط نمونه برداری نشده بود. شبکه عصبی توانست پس از درونیایی، نقشه توزیع و تراکم گیاهچه های علف هرز جوموشی را ترسیم نماید. نقشه حاصل از درونیایی نشان داد که علف هرز جوموشی دارای توزیع لکه ای است و لذا امکان کنترل متناسب با مکان آن در مزرعه مورد مطالعه وجود دارد.

واژه های کلیدی: توزیع مکانی، درونیایی، جوموشی، شبکه عصبی، علف هرز

مقدمه

و دقیق، عامل کلیدی در کاربرد موفق کشاورزی دقیق است. شناخت الگوهای پراکنش علف های هرز و کنترل متناسب با مکان آنها 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 (۳۳). به همین خاطر امروزه تحقیقات زیادی در مورد تهیه و استفاده از نقشه های توزیع علف های هرز با استفاده از مدل سازی پویایی جمعیت علف های هرز به منظور بکارگیری در مدیریت متناسب با مکان در حال انجام است (۹). اما آنچه رسیدن به این اهداف را محقق می سازد افزایش صحت و دقت روش های درونیایی و تهیه نقشه های کاربردی از جمعیت علف های هرز است. درونیایی مکانی شامل تخمین متغیرهایی مانند تراکم گیاهچه علف هرز، بیوماس 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 درونیایی ایده ال قادر است تا با

ظهور علف های هرز در جامعه گیاهی عمدتاً بصورت موضعی و لکه ای است (۷ و ۱۲) که این امر به دلیل اثرات متقابل بیولوژی علف هرز، شرایط موضعی ریزاقلیم^۳ و عملیات مدیریتی می باشد (۴). جهت بررسی اثر هر نوع عملیات کشاورزی بر مدیریت علف های هرز شناخت تغییرات در توزیع، تراکم و ترکیب علف های هرز در مکان و زمان ضروری است (۳۲). کاربرد متناسب با مکان نهاده های کشاورزی (مانند کودها، علفکش ها و...) بر اساس نقشه های صحیح

۱- استادیار گروه زراعت و اصلاح نباتات، دانشکده کشاورزی، دانشگاه صنعتی شاهرود

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

۲- استادیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود

شبکه عصبی شامل آموزش و آزمایش می باشد. آموزش، فرآیند یادگیری مجموعه داده های ورودی بمنظور تشخیص الگوهای آن توسط شبکه می باشد زیرا شبکه MLP از نوع بامعلم است. روش آموزش را قانون یادگیری گویند و اتصالات وزنی بین نرون ها از طریق قانون یادگیری در طول فاز آموزش اصلاح می شوند. الگوریتم پس انتشار^۵ معمولترین روش آموزش شبکه با معلم می باشد ولی در این مطالعه از الگوریتم پس انتشار با نرخ کاهش (BDLRF^۶)، نوع اصلاح شده الگوریتم اصلی پس انتشار (۲۷)، استفاده شد. اساس این دو الگوریتم کمینه کردن محاسبه انحراف خروجی شبکه از خروجی واقعی می باشد. آزمایش، ارزیابی قابلیت تعمیم پذیری و شایستگی شبکه آموزش دیده در شرایط کاملا جدید توسط مجموعه داده های غیر از داده های آموزش گویند (۱۴ و ۳۰). تاکنون 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 (۱۱، ۱۹ و ۲۵). 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 (۶)، ارزیابی کیفیت آب (۳۶)، تخمین بیوماس (۱۸)، و تخمین عملکرد (۱۰) 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 (۱)، با استفاده از مدل شبکه عصبی پرسپترون چند لایه برای تشخیص و تمایز بین گیاه زراعی هویج، علف هرز چچم و خاک مزرعه استفاده کردند. تمایز بین آفتابگردان، توف و پس زمینه خاک نیز با استفاده از یک شبکه MLP توسط کودیر (۲۱) انجام شد. ارماک و همکاران (۱۶)، 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. در حال حاضر، مطالعات متعددی به منظور درونیابی و تهیه نقشه های دقیق پوشش های گیاهی، تغییرات بیوماس 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 MLP در پیش بینی تراکم علف هرز جوموشی (*Hordeum glaucum steud.*) در نقاط نمونه برداری نشده بر اساس داده های حاصل از نقاط نمونه برداری شده در یک مزرعه زعفران می باشد.

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. دزیانت و کازانل (۸) از روش آنالیز روند سطحی^۱ که یک روش درونیابی است جهت توصیف پراکنش جوامع علف هرز در یک مزرعه ذرت استفاده کردند. آنها با برازش 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 خطی^۲ و کریجینگ^۳ 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 (۱۷). 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 (۱۳). 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 (۲۲). بنابراین به نظر می رسد در آنالیز مکانی جوامع جهت فایق آمدن به این نارسایی ها می توان از روش های درونیابی با استفاده از مدل های شبکه عصبی پرسپترون چندلایه^۴ (MLPNN) بهره جست.

ساختار شبکه عصبی مصنوعی مشابه سیستم عصبی بیولوژی مغز انسان است (۲۶). امروز شبکه های عصبی در بسیاری از زمینه ها از جمله طبقه بندی، تشخیص الگو، پیش بینی و مدلسازی فرآیند ها بکار گرفته می شود. مزیت روش شبکه عصبی یادگیری مستقیم از روی داده ها، بدون نیاز به برآورد مشخصات آماری آنها است (۲۸). 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 (۲۰ و ۲۶). شبکه عصبی قادر به تخمین هر تابع غیر خطی پیوسته می باشد (۱۵). ویژگی دیگر شبکه عصبی، تحمل پذیری در مقابل خطا می باشد (۳). 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. در شبکه عصبی مصنوعی چندلایه پرسپترون، جریان داده ها بطور پیوسته از لایه ورودی به خروجی و بدون هیچگونه بازخوری جریان دارد. مراحل اصلی حل هر مسئله توسط

- 1- Trend surface
- 2- Linear triangulation
- 3- Kriging
- 4 - Multi layer perceptron neural network

5 - Back propagation

6- Back propagation with declining learning-rate factor (BDLRF)

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

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

شبکه عصبی پرسپترون چندلایه

بر اساس قضیه تقریب عمومی، شبکه عصبی با یک لایه مخفی و با تعداد کافی نرون در آن لایه قادر به تقریب هر تابع پیوسته دلخواه است (۱۵ و ۲۰)، بنابراین یک لایه مخفی برای شبکه عصبی انتخاب شد. 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 حد ممکن نزدیک به خروجی مطلوب d^q متناظر با خود باشد. برای آموزش شبکه از الگوریتم پس انتشار با نرخ یادگیری کاهش یافته (BDLRF^۲) استفاده شد. مزیت این الگوریتم در مقابل با الگوریتم پس انتشار اصلی (BB^۳) بعنوان یک الگوریتم رایج در آموزش شبکه MLP دارای مزایایی از قبیل سهولت در تنظیم پارامترهای یادگیری شبکه به سبب پایین آوردن حساسیت شبکه به مقادیر آهنگ یادگیری و عامل ممتوم، کاهش زمان یادگیری از طریق پایین آوردن تعداد تکرارهای مورد نیاز برای یادگیری و بهبود رفتار شبکه در طول آموزش می باشد. کد کامپیوتری این الگوریتم در محیط برنامه نویسی نرم افزار MATLAB نسخه ۷ تهیه شد (۲).

الگوریتم BDLRF

این الگوریتم نسخه اصلاح شده الگوریتم پس انتشار اصلی می باشد (۲۷). این الگوریتم آموزش با آهنگ یادگیری (η) و عامل ممتوم (α) ثابت و نسبتاً بزرگ شروع می کند و قبل از آنکه شبکه ناپایدار و یا همگرایی آن کند شود، هر T تکرار ($3 \leq T \leq 5$) آهنگ یادگیری و فاکتور ممتوم را از طریق تصاعد حسابی بصورت یکنواخت کاهش داده تا زمانی که این پارامترها به x درصد (۵٪) مقادیر اولیه خودشان برسند.

مواد و روش ها

داده های مورد استفاده در این آزمایش در سال زراعی ۱۳۸۸-۱۳۸۹ از یک مزرعه تجاری زعفران هشت ساله در منطقه بشرویه واقع در استان خراسان جنوبی جمع آوری گردید. طول و عرض جغرافیایی محل به ترتیب ۵۷° و ۳۷° شمالی و ۵۸° و ۱۰° شرقی و ارتفاع محل از سطح دریا ۸۳۰ متر می باشد. میانگین بارندگی سالیانه منطقه ۱۰۰ میلی متر، حداکثر و حداقل دمای مطلق سالانه به ترتیب ۴۸+ و ۱۳- درجه سانتیگراد می باشد. طبق آزمایش خاک انجام شده مزرعه دارای بافت خاک شنی لومی بوده و بنا بر توصیه کودی آزمایشگاه مقدار ۲۰۰ کیلوگرم فسفات آمونیم در هکتار قبل از کاشت مورد استفاده قرار گرفته است. مزرعه انتخابی به ابعاد ۲۰۰۰ مترمربع بود. علف هرز جوموشی (باریک برگ یکساله زمستانه) یکی از مهمترین علف های هرز مزارع زعفران در استان های خراسان رضوی و جنوبی بشمار می رود (۲۴). نمونه برداری از جمعیت گیاهچه علف هرز زعفران در سطحی به ابعاد ۶۰×۳۲ متر بر روی یک شبکه علامت گذاری شده مربعی^۱ به ابعاد ۴×۴ متر انجام و در مجموع از ۱۴۴ نقطه در مزرعه نمونه برداری انجام شد. نمونه برداری از جمعیت گیاهچه علف های هرز در اوایل دی ماه با استفاده از کواترانی به ابعاد ۰/۱۵ مترمربع (۳۰×۵۰ سانتی متر) در محل تقاطع خطوط شبکه مربعی انجام شد. بطوریکه در هر کواترات جمعیت علف هرز جوموشی شناسایی و شمارش شد.


پیش پردازش داده ها

در ابتدا بطور تصادفی داده های موجود به دو دسته مجموعه آموزش با ۱۰۸ عضو (۷۵ درصد کل داده ها) و مجموعه آزمایش با ۳۶ عضو (۲۵ درصد کل داده ها) تقسیم بندی شد. البته اگر این تقسیم بندی منجر به نتایج مطلوب نشود، می توان این مرحله را مجدداً تکرار کرد (۳۵). قبل از بکارگیری داده های خام اولیه در آموزش شبکه، باید داده ها در دامنه مناسبی نرمالیزه شود زیرا الگوریتم یادگیری همراه با داده های خام نمی تواند عملکرد مناسبی داشته باشد و همچنین بدلیل دامنه تغییرات خروجی تابع فعالیت سیگموئیدی (۰/۱) بکارگرفته شده در لایه میانی، این امر ضروری به نظر می رسد. در غیر این صورت شبکه در طول فاز آموزش همگرا نخواهد شد و لذا نتایج مطلوب حاصل نخواهد شد (۳). زمانیکه از تابع فعالیت سیگموئیدی استفاده می شود، بهترین دامنه تبدیل داده ها (۰/۱/۰/۹) می باشد (۲۸). برای تبدیل داده ها از روش نرمالیزاسیون خطی معادله (۱) استفاده شد:

2- Back-propagation with declining learning-rate factor

3- Basic back-propagation

1- Grid



شکل ۱- ساختار شبکه MLP با یک لایه مخفی

علف هرز $(Wd)^2$ و مختصات مکانی (X, Y) در ابتدا نیاز به تعیین پارامترهای بهینه شبکه عصبی می باشد. در رابطه $(X, Y) = f(Wd)$ تابع f شبکه عصبی MLP است.

تنظیم پارامترهای شبکه

لایه ورودی شامل ۳ نرون می باشد زیرا ورودی های شبکه شامل عامل بایاس و مختصات مکانی (X, Y) علف هرز می باشند. لایه خروجی در شبکه تنها شامل یک نرون است که آن نشان دهنده تراکم علف هرز می باشد. تعیین توپولوژی بهینه، تعداد نرون ها در لایه مخفی شبکه از طریق آزمون سعی و خطا بدست آمد. اگر تعداد نرون ها در لایه مخفی کافی نباشد، شبکه قادر به یادگیری خوب نخواهد شد. ولی در تعداد بسیار زیاد آن مسئله بیش برآزشی^۳ بوجود خواهد آمد که این منجر به تضعیف ویژگی تعمیم پذیری شبکه می شود (۳۱). در طول آزمون آهنگ یادگیری، عامل ممتوم و تعداد تکرارها ($Q=10000$ ، $\alpha=0/8$ ، $\eta=0/4$ ، $n_1=1500$) ثابت نگه داشته شد. این فرآیند برای تعداد نرون های لایه مخفی ۷ تا ۲۰ انجام شد. نهایتاً بهترین نتیجه در ۱۷ نرون در لایه مخفی بدست آمد. بعد از این مرحله، باید مقادیر بهینه پارامتر یادگیری (η) و عامل ممتوم (α) بدست آورد. برای دستیابی به عملکرد بهتر و تسریع در همگرایی شبکه از عامل ممتوم استفاده شد (۱۴ و ۲۸). بدلیل اثرات متقابل این دو پارامتر در عملکرد شبکه، پیدا کردن مقادیر بهینه آنها مشکل می باشد (۲۷). از آنجا که این دو پارامتر تنها در آموزش شبکه بکار می روند، از معیارهای عملکردی در طول فاز آموزش برای بهینه کردن آنها استفاده شد. مقادیر بهینه پارامترهای η و α نیز از طریق

تابع هزینه بکار رفته در این الگوریتم مجموع کل مربعات خطا $(TSSE^1)$ می باشد و با استفاده از معادله ۳ محاسبه می شود:

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

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 می افتد. وزن های هر لایه از شبکه از طریق معادله زیر (۴) محاسبه می شوند.

$$k = 1, \dots, l_3, \quad j = 1, \dots, l_2, \quad i = 1, \dots, l_1 \quad \text{و}$$

$$u_{jk}(n+1) = u_{jk}(n) - \eta \times \frac{\partial E}{\partial u_{jk}} + \alpha(u_{jk}(n) - u_{jk}(n-1)) \quad (3)$$

$$w_{ij}(n+1) = w_{ij}(n) - \eta \times \frac{\partial E}{\partial w_{ij}} + \alpha(w_{ij}(n) - w_{ij}(n-1)) \quad (4)$$

در اینجا w_{ij} اتصال وزنی بین گره های i و j اتصال u_{jk} 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 ممتوم هستند و مقادیر آنها در فاصله (۰ ۱) قرار دارند و n شماره تکرار الگوریتم ($n = 1, \dots, N$) می باشد. زمانی الگوریتم متوقف می شود که $TSSE$ کوچکتر از مقدار آستانه ($0/0001$) مقدار آستانه در نظر گرفته شده برای مطالعه حاضر) باشد. جزئیات بیشتر این الگوریتم را می توان در مطالعات وکیل-باغمیشه و پائوسیک (۲۹) مشاهده کرد.

برای طراحی شبکه عصبی MLP جهت تعیین رابطه بین تراکم


2 - Weed density
3 - Over-fitting

1 - Total sum-squared error


نتایج و بحث

برخی ویژگی های آماری داده های استفاده شده در سه مرحله آموزش، آزمایش و کل، همراه با مقادیر پیش بینی شده آنها توسط شبکه عصبی با ساختار ۱-۱۷-۳ در جدول ۱ نشان داده شده است. تفاوت زیادی بین ویژگی های آماری مقادیر پیش بینی شده تراکم علف هرز جوموشی و مقادیر واقعی آنها ملاحظه نمی شود. تفاوت بین ویژگی آماری بین مقادیر واقعی و پیش بینی شده در فاز آزمایش به دلیل تازگی این داده ها برای شبکه عصبی بیشتر از فاز آموزش است. بر اساس این نتایج می توان ادعا کرد که شبکه عصبی با موفقیت آموزش دیده است. همچنین بدلیل نزدیک بودن مقادیر میانگین، مجموع و کشیدگی می توان نتیجه گرفت که داده های واقعی و پیش بینی شده مشابه هم هستند.

آزمون و خطا انتخاب شدند. عملکرد شبکه برای تمام ترکیبات مقادیر آهنگ یادگیری و عامل ممتوم در بازه تغییراتی (۰/۵-۰/۹۰) برای η و (۰/۰-۰/۹) برای α با هم مقایسه شدند. نتایج نشان داد که بهترین عملکرد در سطح ثابت $\alpha=0/30$ بدست می آید. بنابراین در طی آموزش شبکه، تنها پارامتر یادگیری از آهنگ کاهشی برخوردار شد. مقدار بهینه اولیه $\eta=0/8$ برای شبکه بدست آمد. تعداد بهینه تکرارهای مورد نیاز شبکه برای یادگیری مجموعه داده های علف هرز جوموشی ۵۰۰۰۰۰ بدست آمد، همچنین نقطه بهینه شروع الگوریتم BDLRF در ۵۰۰۰ حاصل شد. مقدار نهایی η به ۰/۰۴ رسید. ساختار شبکه مورد استفاده برای پیش بینی علف هرز (Wd) بر اساس مختصات مکانی (X,Y) در شکل ۲ نشان داده شده است. نمودار همگرایی شبکه عصبی در طول مرحله آموزش در شکل ۳ نشان داده شده است. در شکل ۳ تا نقطه n_1 شبکه بر اساس الگوریتم BB آموزش داده می شود و بعد از آن آموزش شبکه از طریق الگوریتم BDLRF انجام می شود.



شکل ۲- ساختار شبکه MLP استفاده شده برای پیش بینی تراکم علف هرز (Wd)



شکل ۳- نمودار همگرایی شبکه عصبی MLP در طی مدت مرحله آموزش توضیحات: Q تعداد تکرارهای الگوریتم، TSSE مجموع مربعات خطا، n_1 نقطه شروع الگوریتم BDLRF

جدول ۱- ویژگی های آماری مقادیر واقعی و پیش بینی شده تراکم گیاهچه علف هرز جوموشی

	av*	var	std	min	max	kur	ske	sum	
فاز آموزش	۱۰۸	۳۹۱۹۷	۱۹۷	۰	۱۲۵۳	۱۳/۵	۲/۹	۱۱۶۷۹	dv
	۱۰۹	۳۴۳۳۲	۱۸۵	۰	۱۲۰۵	۱۳/۹	۲/۸	۱۱۸۳۱	pv
فاز آزمایش	۱۴۴	۷۳۸۶۴	۲۷۱	۰	۱۲۰۰	۹/۸	۲/۶	۵۲۰۱	dv
	۱۳۶	۵۶۵۹۸	۲۳۷	۰	۱۰۶۸	۸/۶	۲/۳	۴۹۲۳	pv
کل	۱۱۷	۴۷۶۵۸	۲۱۸	۰	۱۲۵۳	۱۲/۸	۲/۹	۱۶۸۸۰	dv
	۱۱۶	۳۹۶۸۲	۱۹۹	۰	۱۲۰۵	۱۲/۲	۲/۷	۱۶۷۵۵	pv

* توضیحات: av: میانگین، var: واریانس، std: انحراف معیار، min: کمینه، max: بیشینه، kur: کشیدگی، ske: چولگی، sum: مجموع، dv: مقادیر واقعی داده ها، pv: مقادیر پیش بینی شده توسط مدل MLP شبکه عصبی

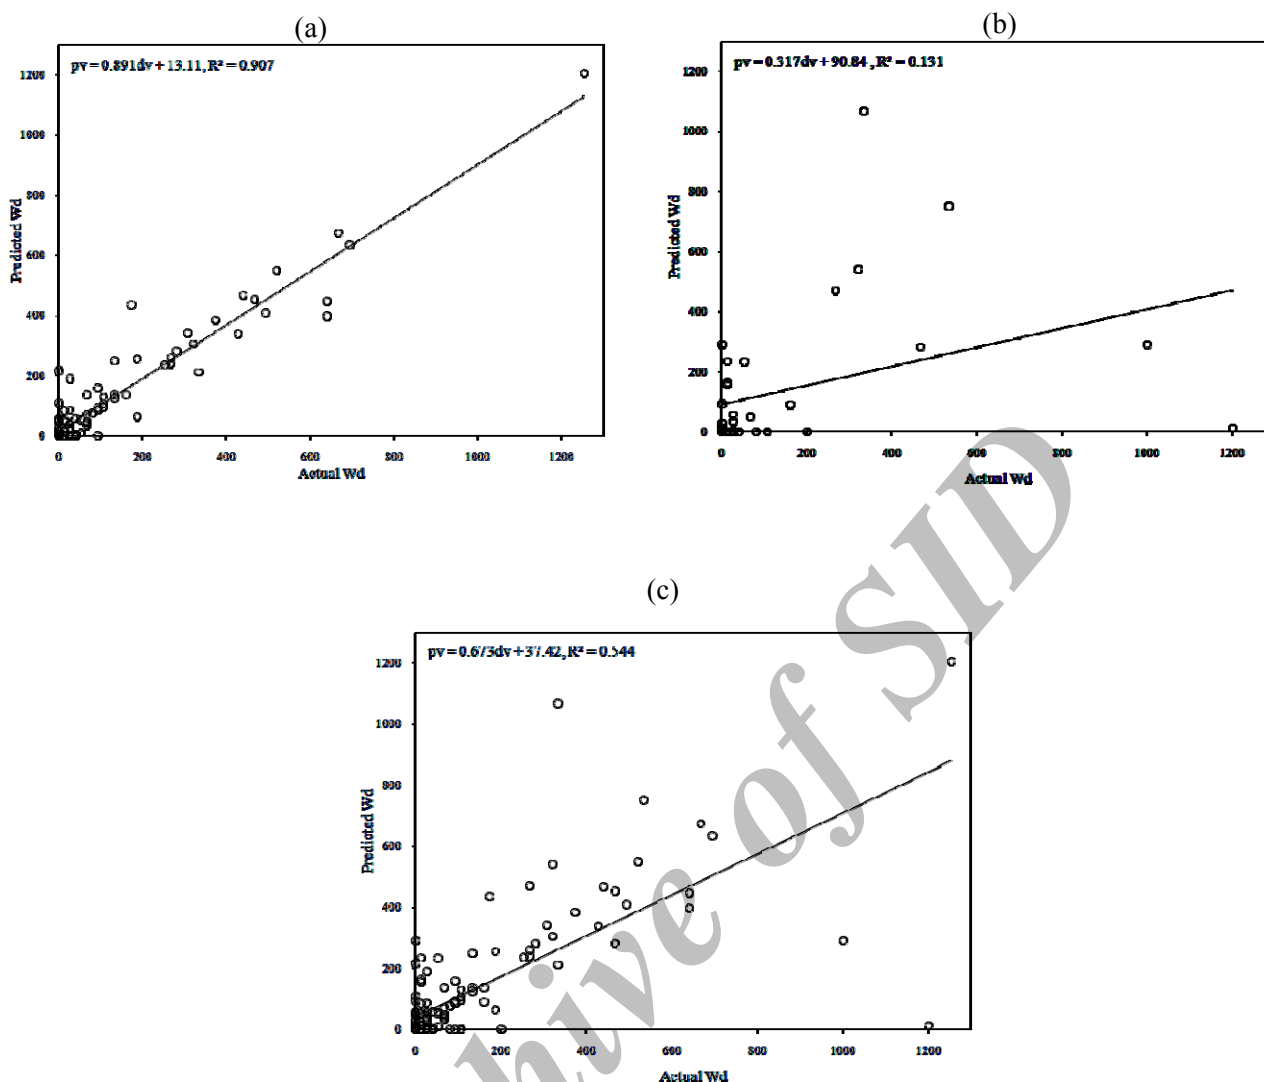
مصنوعی رابطه بین فاکتورهای رقم، خاک و وضعیت زمین را با عملکرد مکانی ذرت و محتوای پروتئین دانه بررسی کردند، با استفاده از این روش، آنها نشان دادند که رقم مهمترین فاکتور تاثیر گذار بر میزان پروتئین دانه بود.

ضرایب تبیین و رابطه خطی رگرسیونی و نیز نحوه پراکندگی بین تراکم های واقعی علف هرز در مقابل مقادیر پیش بینی شده آنها توسط شبکه عصبی در شکل ۴ نشان داده شده است. بهترین نتایج براساس معیار وقتی بدست می آید که معادله خطی مابین مقادیر واقعی و مقادیر پیش بینی شده توسط شبکه عصبی علاوه بر داشتن ضرایب تبیین بالا دارای کمترین عرض از مبدا (نزدیک به صفر) و شیب نزدیک به یک باشد. همانطور که ملاحظه می شود، بهترین نتیجه ($R^2 = 90$) بر اساس نمودارهای پراکندگی برای فاز آموزش شبکه عصبی بدست آمده است (شکل ۴). دلیل پایین بودن ضریب تبیین، بالا بودن عرض از مبدا و نیز پایین بودن ضریب زاویه خط ماربر بین مقادیر واقعی و پیش بینی شده در فاز آموزش به دلیل تازگی این داده ها برای شبکه عصبی است. اکسین و همکاران (۳۴) نیز نشان دادند که شبکه های عصبی مصنوعی نسبت به ضرایب همبستگی ساده یا ضرایب معادلات رگرسیون چند متغیره اطلاعات بسیار بیشتری را در مورد رابطه بین عوامل مربوط به خاک و وضعیت زمین با عملکرد و کیفیت دانه ذرت ارائه کردند.

برای اثبات ادعای ما در مورد قابل اطمینان بودن شبکه عصبی آموزش دیده در پیش بینی تراکم علف هرز، داده های واقعی و داده های پیش بینی 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 ۹۵ درصد به کمک پارامتر p آزمایش شد. اگر p محاسبه شده برای هر مقایسه بیشتر از ۰/۰۵ باشد، فرضیه صفر را نمی توان رد کرد. برای مقایسه میانگین، واریانس و توزیع آماری به ترتیب از آزمون های t ، F و کولموگروف-اسمیرنو استفاده شد. مقادیر p محاسبه شده برای هر سه مجموعه داده های آموزش، آزمایش و کل در جدول ۲ نشان داده شده است. بطوریکه در فاز آموزش، آزمایش و کل، به ترتیب مقادیر $p \geq 0/49$ ، $p \geq 0/18$ و $p \geq 0/27$ بدست آمد. که نشان می دهد میانگین، واریانس و توزیع آماری مقادیر واقعی و پیش بینی شده سه مجموعه داده در سطح ۵ درصد اختلاف معنی داری با هم ندارند. بنابراین شبکه عصبی MLP آموزش دیده، دارای قابلیت بالایی برای پیش بینی تراکم علف هرز در نقاط نمونه برداری نشده است. دراموندا و همکاران (۱۰)، در ارزیابی روش های قابل اطمینان برای مطالعه ارتباط بین متغیرهایی مانند نوع خاک، پستی و بلندی زمین و عملکرد گیاه زراعی در طی چند سال و مکان مختلف، نشان دادند که مدل شبکه عصبی دارای حداقل خطا در پیش بینی مکانی متغیرهای مذکور بود. اکسین و همکاران (۳۴)، با استفاده از شبکه عصبی

جدول ۲- مقادیر p حاصل از مقایسات آماری بین مقادیر واقعی و پیش بینی شده تراکم علف هرز جوموشی در فازهای آموزش، آزمایش و کل

مجموعه داده	نوع تحلیل آماری	
	مقایسه واریانس	مقایسه توزیع
فاز آموزش	۰/۹۵۷	۰/۴۹۴
فاز آزمایش	۰/۸۹۹	۰/۱۸۰
کل	۰/۹۷۲	۰/۳۱۸



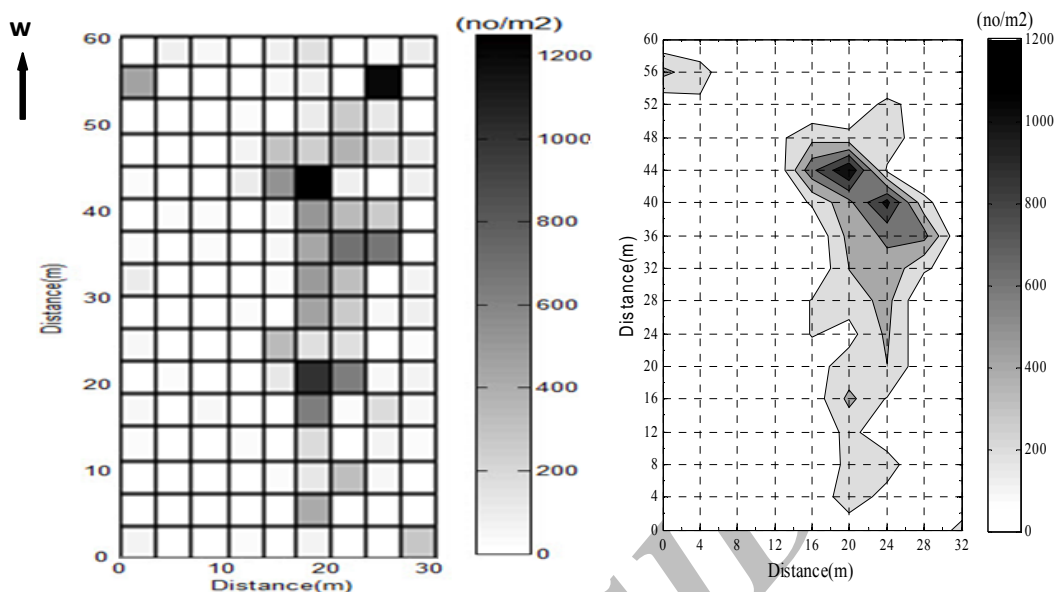
شکل ۴- نمودار پراکندگی مقادیر واقعی تراکم علف هرز (Actual Weed density) در مقابل مقادیر پیش بینی شده (Predicted Weed density) (a) نمودار پراکندگی در فاز آموزش شبکه عصبی، (b) نمودار پراکندگی در فاز آزمایش شبکه عصبی، (c) نمودار پراکندگی برای تمام داده ها

شبکه عصبی MLP درونیابی و ترسیم شده در شکل ۵ نشان داده شده است. در این نقشه لکه هایی با اشکال و اندازه های متفاوت به چشم می خورد. در این لکه ها با فاصله گرفتن از نقطه مرکزی لکه، تراکم علف هرز کاهش یافته و بتدریج به یک بخش حاشیه ای با تراکم کمتر و در مواردی به تراکم صفر می رسد. نقشه نشان می دهد که دامنه تغییرات تراکم در سطح مزرعه بالاست. توزیع نا همگون و تجمعی علف هرز جوموشی در این شکل به خوبی مشهود است.

همین محققین بیان کردند که مدل شبکه عصبی مصنوعی ابزاری قوی در مطالعه اثر فاکتورهای تاثیرگذار بر الگوهای مکانی عملکرد گیاه زراعی می باشند. ارماک و همکاران (۱۶)، نشان دادند مدل شبکه عصبی با الگوریتم پس انتشار توانست تغییرات مکانی عملکرد سویا را با ریشه میانگین مربعات خطای پیش بینی شده ۱۴/۲ درصد پیش بینی کند.

نقشه توزیع و تراکم علف هرز

نقشه توزیع و تراکم گیاهچه های علف هرز جوموشی که توسط



شکل ۵- نقشه توزیع و تراکم جمعیت گیاهچه علف هرز جوموشی در دو حالت بدون درونبایی (شکل سمت چپ) و درونبایی شده توسط مدل شبکه عصبی MLP (شکل سمت راست)

محیطی در سطح مزرعه جابجا می شوند (۲۴). بذور علف هرز دم موشی مکانیسم پراکنش مشخصی ندارد، بنابراین به نظر می رسد که عملیات آبیاری و سله شکنی که بلافاصله قبل از شروع رشد زعفران در اوایل فصل رشد انجام می شود بذور را از اطراف گیاه مادری به فواصل دورتر منتقل کرده و لذا لکه های حاصل از جمعیت گیاهچه های این علف هرز دارای کشیدگی در راستای ردیف های گیاه زراعی و عملیات سله شکنی هستند (۲۲). بیولر (۵)، نیز بیان کرده است که دامنه طولی تر در جهت ردیف گیاه زراعی احتمالاً بدلیل مدیریت گیاه زراعی، آب و باد می باشد. مکاریان (۲۳)، با استفاده از روش کریجینگ جمعیت علف های هرز را در نقاط نمونه برداری نشده درونبایی کرده و نشان داد که علف های هرز جو موشی و شاهی وحشی دارای آرایش لکه ای و علف هرز کاردوس دارای توزیع نسبتاً یکنواخت در سطح مزارع بودند. همین محقق بیان کرد که این الگوی جهت دار لکه های علف هرز در راستای حرکت ادوات کشاورزی و شیارهای آبیاری نشان دهنده این است که مدیریت مزرعه می تواند نقش قابل توجهی در توزیع علف های هرز داشته باشد. آرایش لکه ای علف هرز جوموشی در این مطالعه نشان داد که استراتژی های نمونه برداری مدل های اکولوژیک 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 داد که شبکه عصبی مصنوعی توانست علاوه بر درونبایی، نقشه پراکنش جمعیت علف هرز جو موشی را به خوبی ترسیم نماید. نقشه حاصل از شبکه نیز نشان

وجود مراکز پر تراکم در لکه ها، بذوری را که منشاء گیاهچه ها در سال بعد می باشند را فراهم می کند و می تواند بیانگر نقاطی از مزرعه با تراکم بانک بذور بالا و یا شرایط مناسب برای جوانه زنی باشد. بنابراین استفاده از روش های مدیریت متناسب با لکه ها از جمله استفاده از روش های کنترل پس رویشی و یا استفاده از روش های کنترل پیش رویشی از طریق تیمار کردن محل لکه ها با علفکش های بذركش قبل از شروع فصل رشد گیاه زعفران می توان به مقدار زیادی در مصرف سم صرفه جویی نمود، آلودگی های زیست محیطی را کاهش داده و نیز کنترل موثرتری را برای این علف هرز انجام داد. مکاریان (۲۳) نشان داد که کنترل لکه ای بر اساس نقشه های درونبایی شده بوسیله کریجینگ سبب کاهش ۳۷/۵ و ۳۱/۷ درصدی علفکش مورد نیاز برای کنترل جوموشی، ۲۰ و ۲۳/۳ درصدی علفکش مورد نیاز برای کنترل شاهی وحشی، ۴۳/۳ و ۳۶/۷ درصدی علفکش مورد نیاز برای کنترل کاردوس^۱ نسبت به کاربرد سراسری بترتیب در سال های اول و دوم آزمایش شد. نقشه نشان می دهد که لکه در راستای ردیف های گیاه زراعی کشیده تر می باشد. معمولاً در نتیجه پراکنش اولیه، بذور بصورت مجتمع در اطراف گیاه مادری در داخل یا سطح خاک پراکنده می شوند. در اراضی کشاورزی بذور پس از ریزش بوسیله عملیات مدیریتی مختلف از جمله شخم، آبیاری، برداشت، چرای حیوانات، فعالیت های زارعین و عوامل

1 - *Cardaria draba* L.

2 - *Carduus pycnocephalus* L.

می شود که امکان استفاده از مدیریت متناسب با مکان و کاهش علفکش های مصرفی را در مزارع ممکن می سازد.

داد که جوموشی دارای آرایش لکه ای است و بنابراین نقاط زیادی بصورت عاری از علف هرز یا با تراکم کم علف هرز در مزرعه دیده

منابع

- 1- Aitkenhead M.J., Dalgetty I.A., Mullins C.E., McDonald A.J. S., and Strachan N.J.C. .2003. Weed and crop discrimination using image analysis and artificial intelligence methods. *Computers and Electronics in Agriculture*, 39: 157-171.
- 2- Anonymous .2007. Matlab. The Language of Technical Computing. Version 7.4 . The Mathworks of Natick, Massachusetts, USA.
- 3- Azadeh A., Ghaderi S.F., and Sohrabkhani S. 2006. Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. *Applied Mathematics and Computation*, 186: 1753-1761.
- 4- Bigwood D.B., and Inouye D.W. 1988. Spatial pattern analysis of seed banks: an improved method and optimized sampling. *Ecology*, 69: 497-507.
- 5- Buhler D.D. 1999. Expanding the Context of Weed Management. Food products press.
- 6- Chang D.H., Islam S., 2000. Estimation of soil physical properties using remote sensing and artificial neural network. *Remote Sensing of Environment*, 74: 534-544.
- 7- Clay S.A., Kreutner B., Clay D.E., Reese C., Kleinjan J., and Forcella F. 2006. Spatial distribution, temporal stability, and yield loss estimates for annual grasses and common ragweed (*Ambrosia artemisiifolia*) in a corn /soybean production field over nine years. *Weed Science*, 54: 380-390.
- 8- Dessiant F., and Caussanel J.P. 1994. Trend surface analysis: a simple tool for modeling spatial patterns of weeds. *Crop Protection*, 13: 433-438.
- 9- Dille J.A., Milner M., Groeteke J.J., Mortensen D.A., and Williams II, M.M. 2003. How good is your weed map? A comparison of spatial interpolators. *Weed Science*, 51: 44 – 55.
- 10- Drummond S.T., Sudduth K.A., Joshi A., Birrell S.J., Kitchen N.R. 2003. Statistical and neural methods for site -specific yield prediction. *Transactions of the American Society of Agricultural and Biological Engineers (ASABE)*, 46: 5-14.
- 11- Goel P.K., Prasher S.O., Patel R.M., Landry J.A., Bonnell R.B., and Viau A.A. 2003. Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn. *Computers and Electronics in Agriculture*, 39: 67-93.
- 12- Gonzales-Andujar J.L., and Saavedra M. 2003. Spatial distribution of annual grass weed populations in winter cereals. *Crop Protection*, 22: 629-633.
- 13- Gotway C.A., Ferguson R.B., Hergert G.W., and Peterson T.A. 1996. Comparison of kriging and inverse distance methods for mapping soil parameters. *Soil Science Society America Journal*, 60: 1237-1247.
- 14- Gupta M.M., Jin J., and Homma N. 2003. Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory. John Wiley & Sons, Inc., Hoboken, New Jersey.
- 15- Haykin S., 1994. Neural networks: A comprehensive foundation. McMillan College Publishing Company, New York.
- 16- Irmak A., Jones J.W., Batchelor W.D., Irmak S., Boote k.J., and Paz j.O. 2006. Artificial neural network model as a data analysis tool in precision farming. *Transactions of the American Society of Agricultural and Biological Engineers*, 49: 2027-2037.
- 17- Isaaks E.H., and Srivastava, R.M. 1989. An introduction to Applied Geostatistics. Oxford University Press, New York.
- 18- Jin Y.Q., 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.
- 19- Karimi Y., Prasher S.O., McNairn H., Bonnell R.B., Dutilleul P., and Goel P.K. 2005. Classification accuracy of discriminate analysis, artificial neural networks, and decision trees for weed and nitrogen stress detection in corn. *Transactions of the American Society of Agricultural and Biological Engineers*, 48 :1261-1268.
- 20- Kaul M., Hill R.L., and Walthall C. 2005. Artificial neural networks for corn and soybean yield prediction. *Agriculture system*, 85: 1-18.
- 21- Kavdir S. 2004. Discrimination of sunflower, weed and soil by artificial neural networks. *Computers and*

- [Electronics in Agriculture](#), 44: 153-160.
- 22-Makarjian H., Rashed Mohassel M.H., Bannayan M., and Nassiri M. 2007. Soil seed bank and seedling populations of *Hordeum murinum* and *Cardaria draba* in saffron fields. *Agriculture Ecosystems and Environment*, 120: 307- 312.
- 23-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.
- 24-Rashed M.H. 1992. Weeds of South Khorasan saffron fields. *Agriculture Science and Technology*, 6:118-135.
- 25-Shanin M.A., Tollner E.W., McClendon R.W., and Arabnia H.R. 2002. Apple classification based on surface bruises using image processing and neural networks. *Trans. American Society of Agricultural and Biological Engineers*, 45:1619–1627.
- 26-Torrecilla J.S., Otero L., and Sanz P.D. 2004. A neural network approach for thermal/pressure food processing. *Food Engineer*, 62: 89-95.
- 27-Vakil-Baghmisheh M.T., and Pavešic N. 2001. Back-propagation with declining learning rate. *Proceeding of the 10th Electrotechnical and Computer Science Conference, Portorož, Slovenia. Vol B:* 297-300.
- 28-Vakil-Baghmisheh M.T. 2002. Farsi Character Recognition Using Artificial Neural Networks. PhD Thesis, Faculty of Electrical Engineering, University of Ljubljana.
- 29-Vakil-Baghmisheh M.T., Pavešic N. 2003. A Fast simplified fuzzy ARTMAP network. *Neural Processing Letters*. 17: 273-301.
- 30-Veelenturf L.P.J. 1995. Analysis applications of artificial neural networks. Simon & Schuster international group, United States of America.
- 31-Wang Y.M., Elhag T.M.S. 2007. A comparison of neural network, evidential reasoning and multiple regression analysis in modeling bridge risks. *Expert Systems with Applications*, 32: 336-348.
- 32-Wiles L. 2005. Sampling to make map for site specific weed management. *Weed Science*, 53: 228- 235.
- 33-Williams M.M., Gerhards R., and Mortensen D.A. 1999. Spatiotemporal outcomes of site-specific weed management in maize. Pages 897-906 in J. V. Stafford, ed. *Precision Agriculture 99*. Sheffield, Great Britain: Society of Chemical Industry.
- 34-Yuxin M., Mulla D.J., and Pierre C.R. 2006. Identifying important factors influencing corn yield and grain quality variability using artificial neural networks. *Precision Agriculture* 7: 117–135.
- 35-Zhang Y.54F., Fuh J.Y.H. 1998. A neural network approach for early cost estimation of packaging products. *Computer Ind Engineer*, 34: 433-50.
- 36-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.