

مقایسه الگوریتم‌های BB و BDLRF در آموزش شبکه عصبی MLP به منظور پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور مسی فرگوسن

ایرج رنجبر^۱، یحیی عجب شرجی^{۱*}، عباس روحانی^۲، محمد حسین عباسپور^۳ و شمس‌اله عبدالله پور^۱

تاریخ پذیرش: ۸۷۳/۱۰

۱- گروه ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه تبریز

۲- دانشجوی دکتری مکانیزاسیون کشاورزی، دانشکده کشاورزی، دانشگاه تبریز

۳- گروه ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه فردوسی مشهد

*مسئول مکاتبه: E-mail:yajabshir@tabrizu.ac.ir

چکیده

مدیر مزرعه باید قادر به پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور باشد. این هزینه‌ها تأثیرات قابل ملاحظه بر تصمیمات جایگزینی دارند. هدف از این تحقیق بررسی قابلیت شبکه عصبی MLP در پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور بر حسب عمر تراکتور است. این مطالعه با استفاده از داده‌های مزرعه‌ای ۱۷ تراکتور مسی فرگوسن از کشت و صنعت آستان قدس رضوی انجام شد. به منظور آموزش شبکه، داده‌های جمع‌آوری شده پیش‌پردازش شدند. شبکه MLP با استفاده از دو الگوریتم یادگیری BB و BDLRF آموزش داده شد. پارامترهای بهینه شبکه از طریق آزمون و خطا تعیین شدند. مقایسات آماری داده‌های واقعی و پیش‌بینی شده در فاز تست انجام شد. نتایج نشان می‌دهند که مدل شبکه عصبی قادر به پیش‌بینی هزینه‌های تعمیر و نگهداری با متوسط قدرمطلق درصد خطای کمتر از ۲/۲۷ است. همچنین الگوریتم BDLRF در مقایسه با الگوریتم BB دارای عملکرد بهتری بود.

واژه‌های کلیدی: شبکه عصبی، هزینه تعمیر و نگهداری، BB و BDLRF

Comparison of BB and BDLRF Algorithms in the Training MLP Neural Network for Tractor Repair and Maintenance Costs Prediction

I Ranjbar¹, Y Ajabshir^{1*}, A Rohani², MH Abbaspour Fard³ and Sh Abdolshpour¹

¹Dept. of Farm Machinery Engineering, University of Tabriz, Tabriz, Iran

²Ph. D Student, Dept. of Farm Machinery Engineering, University of Tabriz, Tabriz, Iran

³Dept. of Farm Machinery Engineering, College of Agriculture, Ferdowsi University of Mashhad, Mashhad, Iran

*Corresponding author: E-mail:yajabshir@tabrizu.ac.ir

Abstract

The farm manager must be able to predict repair and maintenance costs. These costs can have significant impacts on replacement decisions. The purpose of this research was to evaluate MLP neural network capability in predicting tractor repair and maintenance costs in terms of with regatta

tractor age. The study was conducted using field data on 17 Messy Ferguson tractors from Astan Ghodse Razavi Agro-Industry. In order to train the network, collected data were preprocessed. MLP network trained by both BB and BDLRF learning algorithm. The optimal parameters of the network were determined by a trial and error procedure. Statistical comparisons of actual and predicted test data in the test phase were carried out. The results revealed that the neural network model was capable of predicting the repair and maintenance costs with a mean absolute percentage error of less than 3.37. Also, it was found that BDLRF algorithm in comparison to BB algorithm had a better performance.

Keywords: BB, BDLRF, Neural network, Repair cost, Maintenance cost

مقدمه

یکی از ابزارهای تعیین‌کننده برای انجام به موقع عملیات زراعی از پیش برنامه‌ریزی شده، تراکتور است (گیرارد و هابرت ۱۹۹۹). تصمیمیات اقتصادی با هدف رسیدن به بیشترین سود از ماشین یکی از عوامل تعیین‌کننده در موفقیت مدیر است (پاسکال و اورنگا ۲۰۰۶). جایگزینی تراکتور، مهمترین تصمیم اقتصادی مدیر ماشین است (آلماسی و همکاران ۱۳۷۸ و اسکونزاد ۱۳۸۲). کلید موفقیت در این تصمیم‌گیری، پیش‌بینی دقیق کل هزینه‌های تراکتور است (کیم ۱۹۸۹). پیش‌بینی اقتصادی، کشف الگوی تغییراتی داده‌های موجود است (هانک و رینش ۱۹۹۵). پیش‌بینی هزینه‌های تعمیر و نگهداری در مقایسه با هزینه‌های مالکیت تراکتور مشکل‌تر است زیرا چنین هزینه‌های بشدت وابسته به مکان، زمان و سیاست‌های مدیریتی هستند (میشل ۱۹۹۸). هزینه‌های تعمیر و نگهداری دارای روند افزایشی و در مقابل هزینه‌های مالکیتی دارای روند کاهش در طول عمر مالکیتی تراکتور هستند (روتز ۱۹۸۷). نقطه برخورد نمودار تغییرات هزینه‌های تعمیر و نگهداری و هزینه‌های مالکیتی، زمان بهینه جایگزینی تراکتور را تعیین می‌کند (آلماسی و همکاران ۱۳۷۸ و بهروزی لار ۱۳۸۰). انجمن مهندسان کشاورزی آمریکا برای اولین بار مدل‌های

رگرسیون برای پیش‌بینی هزینه‌های تعمیر و نگهداری ماشین‌های کشاورزی ارائه داد (پاورز و هانت ۱۹۷۰). می‌توان گفت بنیان گذار پیش‌بینی هزینه‌های تعمیر و نگهداری توسط مدل‌های رگرسیونی، روتز (۱۹۸۷) و فوئس (۱۹۹۹) هستند. در این مقاله سعی بر آن است که علاوه بر عملی ساختن شبکه عصبی بعنوان یک روش جایگزین برای پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور، مناسب‌ترین الگوریتم آموزش شبکه از بین دو الگوریتم BB و BDLRF انتخاب کنیم. شبکه عصبی پردازشگری است متشکل از واحدهای ساده پردازش‌کننده با ساختار سوزی (جورابیان و همکاران ۱۳۸۲ و منهاج ۱۳۸۶). ساختار ANN مشابه سیستم عصبی بیولوژی مغز انسان است و علی‌رغم ساختارها و الگوهای آموزش مختلف اصولاً تمام آنها کار مشابهی انجام می‌دهند و آن نگاهت برداری است (وکیل-باغییشه ۲۰۰۲). شبکه عصبی باید بتواند بطور نسبتاً دقیقی درون‌یابی و بطور محلی بیرون‌یابی نماید (منهاج ۱۳۸۶ و گوپتا و همکاران ۲۰۰۲). مزیت اصلی شبکه عصبی یادگیری مستقیم از روی داده‌ها بدون نیاز به برآورد مشخصات آماری آنها است (وکیل باغییشه ۲۰۰۲). شبکه عصبی بدون داشتن هیچ دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن

در اینجا CCI_k شاخص هزینه تجمعی در زمان t ، C_k هزینه تعمیر و نگهداری در زمان t و PP_k قیمت خرید اولیه تراکتور. این شاخص در طول عمر تقویمی تراکتور همراه روند افزایشی یا ثابت دارد.

تورم

همانطور که می‌دانیم شرایط اقتصادی همراه در حال تغییر و تحول است. در این حالت برای ردیابی جریان هزینه‌ها در طول زمان نیاز به تعدیل کردن اثر تورم است. در مورد مسئله مطالعه شده با در نظر گرفتن سال خرید بعنوان سال پایه و قبل از محاسبه شاخص هزینه تجمعی، اثر تورم بر هزینه‌ها را بطریق زیر کم کردیم:

$$C_k = C_k \times (1 + I_{go})^{n-k}, \quad k = 1, 2, \dots, n \quad [۲]$$

در اینجا C_k و C_k به ترتیب هزینه مربوط به ماه k و هزینه تعدیل شده در ماه k ، I_{go} متوسط نرخ تورم سالانه و n کل عمر تراکتور بر حسب ماه. بعد از استاندارد کردن هزینه‌ها و تعدیل اثر تورم بر آنها، شاخص‌های تجمعی بصورت شاخص هزینه تعمیراتی تجمعی (CCI_{repair})، شاخص هزینه روغن تجمعی (CCI_{oil})، شاخص هزینه سوخت تجمعی (CCI_{fuel}) و شاخص هزینه تعمیر و نگهداری تجمعی (CCI_{m}) محاسبه می‌شود. این شاخص‌ها بعنوان خروجی شبکه عصبی استفاده می‌شود.

طول عمر تراکتور

عمر تراکتور اساسی‌ترین جزء مدل‌سازی هزینه‌های تعمیر و نگهداری می‌باشد و ورودی شبکه عصبی را تشکیل می‌دهد. ساعات کارکرد تجمعی (CHU^1)، مناسب‌ترین تعریفی است که می‌توان از عمر تراکتور داشت (میشل ۱۹۹۸). CHU تعداد ساعاتی که تراکتور بطور فیزیکی کار کرده است را نشان می‌دهد و

رابطه بین مجموعه از ورودی‌ها و خروجی‌ها است (تورسیلا و همکاران ۲۰۰۴ و کوال و همکاران ۲۰۰۵). شبکه عصبی قادر به تخمین هر تابع غیر خطی پیوسته است (هیگین ۱۹۹۴). این مزایا دلایل بکارگیری شبکه عصبی در پیش‌بینی هزینه تعمیر و نگهداری تراکتور را برای ما روشن می‌سازد.

اهداف این مطالعه شامل ارزیابی قابلیت شبکه عصبی MLP^۱ در پیش‌بینی هزینه تعمیر و نگهداری تراکتور و نیز مقایسه عملکرد دو الگوریتم BB^۲ و BDLRF^۳ در آموزش شبکه MLP برای این کاربرد خاص است.

مواد و روش‌ها

داده‌های هزینه‌های تعمیر و نگهداری

برای به انجام رساندن این مطالعه از داده‌های مربوط به هزینه تعمیر و نگهداری ماهانه ۱۷ تراکتور مسی فرگوسن در طی سال‌های ۱۳۸۲-۱۳۶۷ از شرکت مؤسسه کشت و صنعت آستان قدس رضوی در استان خراسان رضوی استفاده شد. این داده‌ها شامل هزینه تعمیرات (هزینه قطعات یدکی و دستمزد تعمیرات)، هزینه روغن (هزینه روانسازها و فیلترهای روغن)، هزینه سوخت (هزینه گازوئیل و فیلترهای سوخت)، هزینه تعمیر و نگهداری (مجموع هزینه تعمیرات، روغن و سوخت) و سال خرید و ساخت هر تراکتور می‌باشند. استاندارد سازی هزینه‌ها

به دلیل متفاوت بودن هزینه‌های تعمیر و نگهداری و نیز تا حدودی قیمت خرید اولیه تراکتورهای مورد مطالعه، تمام این هزینه‌ها را توسط شاخص زیر استاندارد سازی شد (میشل ۱۹۹۸).

$$CCI_k = \frac{\sum C_k}{PP_k} \times 100 \quad [۳]$$

^۱Multilayer Perceptron (MLP)

^۲Basic Back-propagation (BB)

^۳Back-propagation with Declining Learning Rate Factor (BDLRF)

^۱Cumulative hours of usage (CHU)

کافی باشد آنگاه MLP بطور واقعی می‌تواند هر تابع را با هر دقت دلخواه تقریب بزند (کوال و همکاران ۲۰۰۵). این شبکه ابزار ارزشمندی در جهت پیدا کردن روابط بین متغیرهای است که ما دارای دانش کمی یا بدون دانش از روابط بین آنها هستیم. 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 انتخاب پارامترهای صحیح شبکه بمنظور دستیابی به خروجی واقعی Z^q که تا جای ممکن نزدیک به خروجی مطلوب d^q متناظر با خود باشد. برای آموزش شبکه از دو الگوریتم پس انتشار اصلی (BB) و الگوریتم پس انتشار با نرخ یادگیری کاهش (BDLRF) استفاده شد. کد کامپیوتری این الگوریتم‌ها در محیط برنامه نویسی MATLAB تهیه شد.

الگوریتم BB

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

$$TSSE = \sum_q \sum_t (d_t^q - z_t^q)^2, \quad q = 1, \dots, Q \quad [۳]$$

d_t^q و z_t^q به ترتیب t امین عنصر از بردارهای خروجی مطلوب و واقعی از q امین ورودی است. یادگیری شبکه در دو فاز پیش انتشار و پس انتشار اتفاق می‌افتد. در فاز پیش انتشار بردار ورودی به شبکه داده می‌شود و خروجی‌های شبکه بصورت لایه به لایه بصورت لایه خروجی محاسبه می‌شود:

$$\begin{cases} net_j = \sum_i x_i w_{ij} \\ y_j = \frac{1}{1 + e^{-net_j}} \end{cases}, \quad j = 1, \dots, J_2 \quad [۵]$$

$$\begin{cases} net_k = \sum_j y_j v_{jk} \\ z_k = \frac{1}{1 + e^{-net_k}} \end{cases}, \quad k = 1, \dots, J_3 \quad [۶]$$

نیز تغییرات بسیار زیاد هزینه‌های تعمیر و نگهداری را بطوری در طول زمان تعدیل می‌کند. تعداد ساعات کارکرد هر تراکتور بر اساس تعداد تعویض ماهیانه روغن موتور محاسبه گردید. برای رسیدن به عملکرد بهتر مدل‌بندی این هزینه‌ها توسط شبکه عصبی، CHU بر حسب صد ساعت محاسبه شد.

آماده‌سازی داده‌ها

در ابتدا بطور تصادفی داده‌های موجود را به دو دسته مجموعه آموزش با ۱۱۵ عضو (۶۰ درصد کل داده‌ها) و مجموعه تست با ۷۷ عضو (۴۰ درصد کل داده‌ها) تقسیم‌بندی شد. البته اگر این تقسیم‌بندی منجر به نتایج مطلوب نشود، می‌توان این مرحله را مجدداً تکرار کرد (زانگ و فو ۱۹۹۸). مرحله بعدی از آماده‌سازی داده‌ها، نرمالیزه کردن آنها است تا مجموعه داده‌های آموزش و تست دارای توزیع آماری تقریباً یکسان شوند. همچنین باید این تبدیل در دامنه تغییرات مناسبی انجام شود تا شبکه به نقطه بهینه همگرا شود و از آنجا که تابع فعالیت انتخاب شده برای نرون‌های شبکه سیگموئید است لذا بهترین دامنه تبدیل داده‌ها [۰/۱ - ۰/۹] است (وکیل-باغچه‌باز ۲۰۰۲). از نرمالیزاسیون خطی برای تبدیل داده‌ها استفاده شد:

$$X_n = \frac{X - X_{min}}{X_{max} - X_{min}} \times (r_{max} - r_{min}) + r_{min} \quad [۷]$$

در اینجا X داده خام اولیه، X_n داده نرمالیزه شده، X_{min} و X_{max} به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه و r_{min} و r_{max} به ترتیب حد بالای و پایینی دامنه تغییرات داده‌های تبدیل شده است.

شبکه عصبی پرسپترون چندلایه

رایجترین شبکه مورد استفاده در تقریب تابع، شبکه پرسپترون چند لایه (MLP) است. این شبکه متعلق به کلاس شبکه‌های عصبی با معلم می‌باشد. اگر تعداد نرون‌های لایه مخفی و نیز داده‌های آموزش بمقدار

تحلیل آماری فاز تست

بعد از آنکه وزن‌های شبکه در طول فاز آموزش محاسبه گردید، فاز تست شبکه شروع می‌شود. در فاز تست از همان توپولوژی و نیز وزن‌های تنظیم شده در طول فاز آموزش استفاده شد. هدف از این مرحله ارزیابی ویژگی تعمیم‌پذیری و شایستگی شبکه عصبی آموزش دیده است. بنابراین ما شبکه را با استفاده از مجموعه داده‌های غیر از مجموعه داده‌های آموزش (مجموعه داده‌های تست) ارزیابی کردیم. جدول ۲ برخی از ویژگی‌های آماری داده‌های بکارگرفته شده در فاز تست و نیز مقادیر پیش‌بینی شده آنها را توسط هر دو الگوریتم آموزش نشان می‌دهد. تفاوت بین مقادیر میانگین، واریانس، انحراف معیار، کشیدگی، بیشینه و مجموع داده‌های واقعی و داده‌های پیش‌بینی شده برای تمام شاخص‌های هزینه کمتر از ۱/۵ درصد می‌باشد. تنها تفاوت بین مقادیر کمینه‌ها قابل ملاحظه است ولی از آنجا که این تنها یک نقطه از مجموعه تست می‌باشد لذا نمی‌توان بر اساس آن درباره قابلیت شبکه آموزش تفاوت کرد. این تفاوت‌ها در فاز تست کمی بالا می‌باشند زیرا این داده‌ها برای شبکه MLP کاملاً تازگی دارند. از طرف دیگر بدلیل مشابه بودن مقادیر میانگین، مجموع و کشیدگی می‌توان نتیجه گرفت هر دو سری داده‌های واقعی و پیش‌بینی شده توسط شبکه مشابه و بسیار نزدیک به هم هستند بنابراین می‌توان گفت شبکه‌های عصبی بخوبی داده‌های مجموعه آموزش را یاد گرفته است. برای نشان دادن صحت این ادعا اختلاف بین داده‌های واقعی و داده‌های پیش‌بینی شده را از نقطه نظر آماری با هم مقایسه می‌کنیم. در اینجا فرضیه صفر دلالت بر یکسان بودن هر دو سری داده دارد. برای تست این فرضیه از محاسبه مقدار p در سطح احتمال ۹۵ درصد استفاده شد. بنابراین اگر p محاسبه شده بزرگتر از ۰/۰۵ باشد، فرضیه صفر قابل قبول است. مقادیر p محاسبه شده برای سه نوع مقایسه آماری میانگین، واریانس و توزیع آماری در جدول ۲ نشان داده شده

(هیکین ۱۹۹۴). یک لایه مخفی برای تمام شبکه‌های عصبی انتخاب شد.

تنظیم پارامترهای شبکه

از آنجا که ورودی شبکه شامل عامل بایاس و ساعات کارکرد جسمی و خروجی شبکه شامل یکی از شاخص‌های هزینه تعمیم‌دهنداری بودند. لذا لایه ورودی و لایه خروجی به ترتیب شامل ۲ و یک نرون هستند. اما برای تعیین مناسب‌ترین توپولوژی شبکه (تعداد نرون‌ها در لایه مخفی) از روش آزمون و خطا استفاده شد. در طول آزمون آهنگ یادگیری، عامل منتوم و تعداد تکرارها (0.01 ، 0.001 و 0.0001) را ثابت نگه داشته شد. این فرآیند برای هر مجموعه داده چندین مرتبه تکرار شد. در نهایت بهترین نتایج با تعداد نرون‌های ۵، ۶، ۵، ۶ در لایه مخفی به ترتیب برای شاخص‌های CCI_{opt} ، CCI_{opt} ، CCI_{opt} و CCI_{opt} حاصل شد.

مقادیر بهینه پارامترهای η و ξ نیز از طریق آزمون و خطا انتخاب شدند. عملکرد هر شبکه برای تمام ترکیبات مقادیر آهنگ یادگیری و عامل منتوم در بازه تغییراتی $[0.01/0.99]$ برای η و $[0.0001/0.99]$ برای ξ با هم مقایسه شدند. نتایج نشان می‌دهند که بهترین عملکرد در سطح ثابت ۰/۹۵ برای تمام شاخص‌های هزینه تعمیم‌دهنداری بدست می‌آید. بنابراین زمانی که از الگوریتم BDLRF استفاده می‌شود تنها نیاز به کاهش آهنگ یادگیری در طول آموزش هستیم. مقادیر اولیه آهنگ یادگیری (η_0) برای هر دو نوع الگوریتم آموزش و نیز مقادیر نهایی آهنگ یادگیری (η_r) و نقطه شروع الگوریتم BDLRF در جدول ۱ نشان داده شده است. همانطور که ملاحظه می‌شود نرخ اولیه یادگیری BDLRF بیشتر از BB است. این باعث کاهش سریع خطا در ابتدای آموزش ولی بعد از آن نرخ یادگیری بطور یکنواخت تا η_r کاهش می‌یابد.

مقایسه الگوریتم‌های آموزش

عملکرد دو الگوریتم آموزش BB و BDLRF مورد استفاده در آموزش هر شبکه MLP برای مدل کردن شاخص‌های هزینه تجمعی تعمیر و نگهداری در جدول ۴ آورده شده است. در این مطالعه و برای تراکتور فرگوسن، مقایسه نتایج نشان می‌دهد که هر دو الگوریتم قابلیت برآوردهای دقیق در محدوده ساعات کارکرد تجمعی دارند. اما از نظر معیارهای عملکردی MAPE، RMSE و TSSE فاز آموزش و تست الگوریتم آموزش BDLRF دارای عملکرد بهتری نسبت به الگوریتم آموزش BB است. زیرا این الگوریتم منجر به درصد خطای کمتر (MAPE و RMSE کمتر) در زمان آموزش کوتاه‌تری (Q کوچکتر) شده است. با در نظر گرفتن تمام نتایج حاصل از این دو الگوریتم می‌توان گفت که BDLRF علاوه بر داشتن مزایای BB شامل برتریهای از قبیل سهولت تنظیم پارامترهای یادگیری شبکه به سبب پایین آمدن حساسیت شبکه به مقادیر آهنگ یادگیری و عامل ممنوع، کاهش زمان یادگیری از طریق پایین آمدن تعداد تکرارهای مورد نیاز برای یادگیری، بهبود رفتار شبکه در طول آموزش می‌باشد. این نتایج منطبق بر یافته‌های وکیل-غضیبه (۲۰۰۱ و ۲۰۰۲) است.

است. از آزمون‌های F و t و کولموگورو-اسمیرنو^۳ به ترتیب برای مقایسه میانگین‌ها، واریانس و توزیع آساری دو سری داده‌های واقعی و پیش‌بینی شده استفاده شد. نتایج نشان می‌دهند مقدار p در تمام موارد بزرگتر از ۰/۰۵ است. لذا فرضیه صفر را نمی‌توان در هیچ موردی رد کرد. بنابراین میانگین، واریانس و توزیع آساری هر دو سری داده با می‌توان مشابه در نظر گرفت (جدول ۴). شکل‌های ۲ تا ۵ شاخص‌های هزینه تجمعی واقعی در مقابل شاخص‌های هزینه پیش‌بینی شده توسط شبکه عصبی با بکارگیری دو نوع الگوریتم آموزش BB و BDLRF را نشان می‌دهند. همانطور که مشاهده می‌شود شرایط تطبیق بین همه شاخص‌های هزینه تعمیر و نگهداری پیش‌بینی شده و شاخص‌های واقعی برای هر دو الگوریتم آموزش بسیار بالا می‌باشد ($R^2=0.999$). بنابراین شبکه آموزش دیده دارای عملکرد بسیار قابل قبولی است و می‌توان چنین شبکه را با اطمینان برای پیش‌بینی هزینه‌های تعمیر و نگهداری بکار برد. بهترین نتیجه براساس این اشکال وقتی بدست می‌آید که معادله خطی مابین OCI واقعی و OCI پیش‌بینی شده توسط شبکه دارای کمترین عرض از میانه (نزدیک به صفر) و شیب نزدیک به یک باشد ($\hat{dV} \approx 1/100$ و $\hat{pV} \approx 1/100$). این اشکال نشان می‌دهند شاخص‌های هزینه تجمعی تعمیر و نگهداری پیش‌بینی شده توسط الگوریتم آموزش BB در مقایسه با شاخص‌های هزینه تجمعی تعمیر و نگهداری پیش‌بینی شده توسط الگوریتم آموزش BDLRF به‌ویژه با شاخص‌های هزینه تجمعی تعمیر و نگهداری واقعی فیت نشده‌اند. معادلات خطی رگرسیونی حاصله بین دو پارامتر \hat{pV} و \hat{dV} برای چهار شاخص هزینه تعمیر و نگهداری توسط الگوریتم آموزش BDLRF دارای شیب‌های نزدیکتر به یک و عرض از میانه‌های کوچکتر در مقایسه با الگوریتم آموزش BB است.

^۳Kolmogorov-Smirnov

تابع مورد استفاده

- مکونزاد، م. م.، ۱۳۸۲. اقتصاد مهندسی یا ارزیابی اقتصادی پروژه‌های صنعتی. انتشارات دانشگاه صنعتی امیرکبیر.
- باسی، م.، لویسی، ن. و کیانی، ش.، ۱۳۷۸. مبانی مکانیزاسیون کشاورزی. انتشارات حضرت معصومه.
- روزی‌لار، م.، ۱۳۸۰. مدیریت تراکتور و ماشینهای کشاورزی. انتشارات دانشگاه تهران.
- بورانیان، م.، زارع ط. و استوار، ا.، ۱۳۸۲. شبکه‌های عصبی مصنوعی (ترجمه). انتشارات دانشگاه شهید چمران.
- هاج، م. ب.، ۱۳۸۶. مبانی شبکه‌های عصبی. انتشارات دانشگاه صنعتی امیرکبیر.

Bowers W and Hunt DR, 1970. Application of mathematical formula to repair cost data. Transactions of the ASAE 13: 806-809.

Fuls J, 1999. The correlation of repair and maintenance costs of agricultural machinery with operating hours management policy and operator skills for South Africa. Accessed July 2007, available at <http://www.arc.agric.za>

Girard N and Hubert B, 1999. Modeling expert knowledge with knowledge-based systems to design decision aids. The example of a knowledge-based model on grazing management. Agricultural Systems 59: 123-144.

Gupta MM, Liang J and Noriyasu H, 2003. Static and dynamic neural networks. From fundamentals to advanced theory. John Wiley & Sons, Inc., Hoboken, New Jersey.

Hanke JE and Reitsh AG 1995. Business Forecasting. Prentice-Hall, Englewood Cliffs, NJ.

Hathaway LR, 1984. FMO fundamentals of machine operation: Preventive maintenance. Third Edition. Deere & Company, Moline

Haykin S, 1994. Neural networks: A comprehensive foundation. McMillan College Publishing Company, New York.

Kaul M, Hill RL and Walthall C, 2005. Artificial neural networks for corn and soybean yield prediction. Agriculture System 85:1-18

Kim YH, 1989. A forecasting methodology for maintenance cost of long-life equipment. Doctoral thesis. University of Alabama.

Mitchell ZW, 1998. A statistical analysis of construction equipment repair costs using field data & the cumulative cost model. Doctoral thesis. Virginia Polytechnic Institute and State University.

Pascual R and Ortega JH. 2006. Optimal replacement and overhaul decisions with imperfect maintenance and warranty contracts. Reliability Engineering and System Safety 91:241-248.

Rotz CA, 1987. A standard model for repair costs of agricultural machinery. Applied Engineering in Agriculture 3:3-9.

- Torrecilla JS, Otero L and Sanz PD, 2004. A neural network approach for thermal/pressure food processing. *Food Engineering* 62:89-95.
- Vakil-Baghmisheh MT and Pavešic N, 2003. A fast simplified fuzzy ARTMAP network. *Neural Processing Letters* 17: 273-301.
- Vakil-Baghmisheh MT and Pavešic N. 2001. Back-propagation with declining learning rate. *Proceeding of the 10th Electrotechnical and Computer Science Conference, Portorož, Slovenia*. B: 297-300.
- Vakil-Baghmisheh MT, 2002. *Farsi Character Recognition Using Artificial Neural Networks*. PhD Thesis, Faculty of Electrical Engineering, University of Ljubljana.
- Zhang YF and Fuh JYH, 1998. A neural network approach for early cost estimation of packaging products. *Comput Ind Eng* 34: 433-50.