

پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور فیات با استفاده از شبکه عصبی RBF

عباس روحانی^۱، سعید ظریف نشاط^۲ و محمد حسین عباسپور فرد^۳

۱- استادیار گروه ماشین‌های کشاورزی دانشکده کشاورزی دانشگاه صنعتی شاهرود

۲- نویسنده مسئول: استادیار بخش تحقیقات فنی و مهندسی کشاورزی مرکز تحقیقات کشاورزی و منابع طبیعی خراسان رضوی

۳- دانشیار گروه مهندسی ماشین‌های کشاورزی دانشکده کشاورزی دانشگاه فردوسی مشهد

تاریخ دریافت: ۱۳۹۱/۱/۲۱

تاریخ پذیرش: ۱۳۹۱/۶/۲۹

چکیده

پیش‌بینی هزینه‌های تعمیر و نگهداری تاثیر معنی داری در تصمیم‌گیری‌های اقتصادی مدیر ماشین‌های کشاورزی دارد. هدف از این تحقیق، ارزیابی قابلیت پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور با استفاده از شبکه عصبی مصنوعی^۱ RBF می‌باشد. مطالعه حاضر با استفاده از داده‌های واقعی ۱۰ تراکتور فیات موجود در کشت و صنعت آستان قدس رضوی انجام شد. پارامترهای بهینه شبکه عصبی RBF از طریق سعی و خطا بر روی داده‌های موجود انتخاب شدند. برای ارزیابی قابلیت مدل RBF در پیش‌بینی هزینه‌های تعمیر و نگهداری از مقایسه آماری پارامترهایی مانند میانگین، واریانس، توزیع آماری و نیز خط رگرسیونی بین داده‌های پیش‌بینی شده توسط شبکه عصبی RBF و مقادیر واقعی آنها استفاده شد. نتایج نشان داد که در فاز آموزش و آزمایش $p > 0/99$ می‌باشد، که نشان دهنده عدم وجود تفاوت معنی داری بین مقادیر ویژگی‌های آماری (میانگین، واریانس و توزیع آماری) مجموعه داده‌های پیش‌بینی شده هزینه‌های تعمیر و نگهداری و مقادیر واقعی آنها بود. به عبارت دیگر شبکه عصبی مصنوعی RBF به خوبی توانست مدل داده‌های هزینه‌های تعمیر و نگهداری را بیاموزد. نتایج نشان داد که شبکه عصبی آموزش دیده، دارای قابلیت بالایی در پیش‌بینی هزینه‌های تعمیر و نگهداری با خطای کم‌تر از ۰/۶۴ درصد بود. نتایج حاصل نشان می‌دهد که شبکه عصبی RBF قادر به پیش‌بینی دقیق هزینه‌های تعمیر و نگهداری تراکتور است. بنابراین، شبکه عصبی می‌تواند قابلیت تصمیم‌گیری اقتصادی مدیران ماشین را بهبود بخشد.

کلیدواژه‌ها: RBF، شبکه عصبی مصنوعی، هزینه تعمیر و نگهداری

مقدمه

مهم‌ترین تصمیم اقتصادی مدیر ماشین می‌باشد (الماسی و همکاران، ۱۳۷۸ و اسکونژاد، ۱۳۸۳). کلید موفقیت در این تصمیم‌گیری، پیش‌بینی دقیق هزینه‌های تعمیر و نگهداری می‌باشد (کیم^۴، ۱۹۸۹). هزینه‌های تعمیر و نگهداری شدت وابسته به مکان، زمان

اطلاع دقیق از هزینه‌ها نقش موثری در بسیاری از تصمیمات مدیریت ماشین‌ها ایفا می‌کند (مایفیلد و همکاران^۲، ۱۹۸۱ و روتز^۳، ۱۹۸۷). جایگزینی ماشین،

1-Radial Basic Function

2- Mayfield et al.

3 - Rotz

به تخمین هر تابع غیر خطی پیوسته می‌باشد (هی‌کین^۷، ۱۹۹۴). ویژگی دیگر شبکه عصبی، تحمل‌پذیری در مقابل خطا می‌باشد (آزاده و همکاران^۸، ۲۰۰۶). این مزایا دلایل به کارگیری شبکه عصبی در پیش‌بینی هزینه تعمیر و نگهداری تراکتور را برای ما روشن می‌سازد. در این مطالعه از شبکه RBF استفاده شد. مراحل اصلی حل هر مساله توسط شبکه عصبی شامل آموزش و آزمون می‌باشد. آموزش، فرآیند یادگیری مجموعه داده‌های ورودی به منظور تشخیص الگوهای آن توسط شبکه می‌باشد زیرا شبکه RBF از نوع با معلم می‌باشد. روش آموزش را قانون یادگیری گویند و اتصالات وزنی بین نرون‌ها از طریق قانون یادگیری در طول فاز آموزش اصلاح می‌شوند. اساس الگوریتم‌های آموزش کمینه کردن انحراف خروجی شبکه از مقدار واقعی می‌باشند. ارزیابی قابلیت تعمیم‌پذیری شبکه آموزش دیده در شرایط کاملاً جدید توسط مجموعه داده‌های غیر از داده‌های آموزش را آزمون گویند (گویتا، ۲۰۰۳ و ولتروف^۹، ۱۹۹۵). با توجه به منابع موجود و در دسترس، تا کنون از شبکه RBF بدین منظور استفاده نشده است لذا هدف از انجام این تحقیق، نحوه و چگونگی استفاده از این شبکه عصبی به منظور پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور می‌باشد.

مواد و روش‌ها

داده‌های هزینه‌های تعمیر و نگهداری:

برای انجام این مطالعه از داده‌های مربوط به هزینه تعمیر و نگهداری ماهانه ۱۰ تراکتور فیات ۴۴۵ 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

و سیاست‌های مدیریتی می‌باشد؛ لذا پیش‌بینی دقیق چنین هزینه‌هایی بسیار مشکل است (میشل^۱، ۱۹۹۸).

انجمن مهندسين کشاورزی آمریکا برای اولین بار مدل‌های رگرسیونی برای پیش‌بینی هزینه‌های تعمیر و نگهداری ماشین‌های کشاورزی ارائه داد (باورز و هانت^۲، ۱۹۷۰). روتز مدلی توانی را جهت برآورد هزینه‌های تعمیر و نگهداری تراکتور پیشنهاد کرد (روتز، ۱۹۸۷). فولس مدلی را بر پایه مدل توانی روتز پیشنهاد کرد؛ با این تفاوت که پارامتر جدیدی را برای لحاظ نمودن تاثیر سیاست‌های مدیریتی و مهارت کاربر در تخمین هزینه‌های تعمیر و نگهداری تراکتور به مدل اضافه نمود (روحانی و همکاران^۳، ۲۰۱۱). تا کنون تمام مدل‌های ریاضی پیشنهاد شده برای پیش‌بینی هزینه‌های تعمیر و نگهداری بر اساس مدل رگرسیونی روتز بنا شده‌اند. در این مقاله عملکرد شبکه‌های عصبی مصنوعی RBF بعنوان یک روش جایگزین برای پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور ارزیابی می‌شود.

ساختار شبکه عصبی مصنوعی مشابه سیستم عصبی بیولوژی مغز انسان است (گویتا و همکاران^۴، ۲۰۰۳). امروز شبکه‌های عصبی در بسیاری از زمینه‌ها از جمله طبقه‌بندی، تشخیص الگو، پیش‌بینی و مدل‌سازی فرآیند به کار گرفته می‌شود. مزیت شبکه عصبی یادگیری مستقیم از روی داده‌ها بدون نیاز به برآورد مشخصات آماری آنها است (وکیل باغمیشه^۵، ۲۰۰۲). 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 از ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه می‌باشد (تورسیلا و همکاران^۶، ۲۰۰۴). شبکه عصبی قادر

- 1- Mitchel
- 2- Bowers and Hunt
- 3 - Rohani *et al.*
- 4- Gupta *et al.*
- 5 - Vakil-Baghmisheh
- 6- Torrecilla *et al.*

7-Haykin

8 -Azadeh *et al.*

9- Veelenturf

پیش پردازش داده‌ها: در ابتدا به طور تصادفی داده‌های موجود را به دو دسته مجموعه آموزش با ۱۱۵ عضو (۶۰ درصد کل داده‌ها) و مجموعه آزمون 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 (زنگ و فو^۲، ۱۹۹۸). قبل از به کارگیری داده‌های خام اولیه در آموزش و آزمون شبکه باید آنها را نرمالیزه کنیم زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد مناسبی داشته باشد و همچنین به دلیل دامنه تغییرت خروجی تابع فعالیت سیگموئیدی [۰ ۱] به کار گرفته شده در لایه میانی این امری ضروری به نظر می‌رسد. در غیر این صورت شبکه در طول فاز آموزش همگرا نخواهد شد و نتایج مطلوبی تولید نخواهد شد (آزاده و همکاران، ۲۰۰۶). زمانی که از تابع فعالیت سیگموئیدی استفاده می‌شود، بهترین دامنه تبدیل داده‌ها [۰/۱ ۰/۹] می‌باشد (وکیل باغمیشه، ۲۰۰۲). از نرمالیزاسیون خطی (معادله ۲) و نرمالیزاسیون غیر خطی (معادله ۳) برای تبدیل داده‌ها استفاده شد:

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \times 0.8 + 0.1 \quad (2)$$

$$x_n = \frac{\log(x) - \log(x_{\min})}{\log(x_{\max}) - \log(x_{\min})} \times 0.8 + 0.1 \quad (3)$$

در اینجا x داده خام اولیه، x_n داده نرمالیزه شده، x_{\min} و x_{\max} به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه می‌باشد. برای هر مجموعه داده این روش‌ها ارزیابی شد و بهترین آنها بر اساس عملکرد شبکه انتخاب شدند.

شبکه عصبی RBF:

ساختار شبکه RBF با یک لایه مخفی در شکل ۱ نشان داده شده است. شبکه RBF با دریافت بردار ورودی

(مجموع هزینه تعمیرات، روغن و سوخت) و سال خرید و ساخت هر تراکتور می‌باشند.

استاندارسازی هزینه‌ها: به دلیل متفاوت بودن هزینه‌های تعمیر و نگهداری و نیز تا حدودی قیمت خرید اولیه تراکتورهای مورد مطالعه، تمام این هزینه‌ها پس از کم کردن تاثیر تورم بر پایه سال ۱۳۸۲ توسط رابطه (۱) استاندارد سازی شد (میشل، ۱۹۹۸).

$$CCI_t = \frac{\sum_0^t C_t}{PP_0} \times 100 \quad (1)$$

در اینجا CCI_t شاخص هزینه تجمعی در زمان t ، C_t هزینه تعمیر و نگهداری در زمان t و PP_0 قیمت خرید اولیه تراکتور. شاخص‌های تجمعی به صورت 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_{rm}) محاسبه شدند. به دلیل آن که CCI_{rm} برابر با مجموع سه شاخص هزینه اولی است، تنها شاخص‌های هزینه تعمیر، روغن و سوخت بعنوان خروجی شبکه عصبی لحاظ شد.

طول عمر تراکتور: عمر تراکتور اساسی‌ترین جزء مدل سازی 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 را که تراکتور به طور فیزیکی کار کرده است نشان می‌دهد و نیز تغییرات بسیار زیاد هزینه‌های تعمیر و نگهداری را بخوبی در طول زمان تعدیل می‌کند. تعداد ساعات کارکرد هر تراکتور بر اساس تعداد تعویض ماهیانه روغن موتور محاسبه گردید. برای دستیابی به عملکرد بهتر شبکه عصبی، CHU بر حسب صد ساعت محاسبه شد.

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

$$u_{mj}(n+1) = u_{mj}(n) - \eta_3 \frac{\partial E}{\partial u_{mj}} \quad (6)$$

$$v_{im}(n+1) = v_{im}(n) - \eta_2 \frac{\partial E}{\partial v_{im}} \quad (7)$$

$$\sigma_m^2(n+1) = \sigma_m^2(n) - \eta_1 \frac{\partial E}{\partial \sigma_m^2} \quad (8)$$

$$j=1, \dots, l_3, \quad m=1, \dots, l_2, \quad i=1, \dots, l_1$$

در اینجا u_{mj} اتصال وزنی بین گره‌های j و m ، v_{im} اتصال وزنی بین گره‌های i و m و σ_m پارامتر پراکندگی برای گره‌های m می‌باشند. مقادیر اولیه این وزن‌های u_{mj} به طور تصادفی از دامنه مقادیر $[-0.1, 0.1]$ انتخاب می‌شود. l_1 ، l_2 و l_3 به ترتیب تعداد نرون‌ها در لایه ورودی، لایه مخفی و لایه خروجی می‌باشند. η_1 ، η_2 و η_3 به ترتیب آهنگ‌های یادگیری برای σ_m ، v_{im} و u_{mj} هستند و مقادیر آنها در فاصله $[0, 1]$ قرار دارند و n شماره تکرار الگوریتم ($n=1, \dots, N$) زمانی الگوریتم متوقف می‌شود که TSSE کوچکتر از مقدار آستانه (0.0001) مقدار آستانه در نظر گرفته شده برای مطالعه حاضر) باشد. جزئیات بیشتر این الگوریتم را می‌توان در وکیل-باغمیشه و پاوسیک (۲۰۰۳ و ۲۰۰۴) مشاهده کرد.

X_q ، بردار خروجی Z_q برای هر q ($q=1, \dots, Q$) تولید خواهد کرد. هدف اتخاذ پارامترهای صحیح شبکه به منظور دستیابی به خروجی واقعی Z_q که تا جای ممکن نزدیک به خروجی مطلوب d_q متناظر با خود باشد. برای آموزش شبکه از الگوریتم پس انتشار با نرخ یادگیری کاهشی ($BDLRF^1$) استفاده شد. مزیت این الگوریتم شامل سهولت در تنظیم پارامترهای یادگیری شبکه به سبب پایین آوردن حساسیت شبکه به مقادیر آهنگ‌های یادگیری، کاهش زمان یادگیری از طریق پایین آوردن تعداد تکرارهای مورد نیاز برای یادگیری و بهبود رفتار شبکه در طول آموزش می‌باشد. کد کامپیوتری این الگوریتم در محیط برنامه نویسی MATLAB تهیه شد. الگوریتم BDLRF: این الگوریتم نسخه اصلاح شده الگوریتم پس انتشار اصلی می‌باشد (وکیل باغمیشه و پاوسیک^۲، ۲۰۰۳). این الگوریتم آموزش با آهنگ یادگیری نسبتاً بزرگ شروع می‌کند و قبل از آنکه شبکه ناپایدار و یا همگرایی آن کند شود، هر T تکرار ($T \leq 5$) آهنگ یادگیری از طریق تصاعد حسابی به صورت $3 \leq$ یکنواخت کاهش داده می‌شود تا زمانی که این پارامترها به X درصد (5%) مقادیر اولیه خودشان برسند. پارامتر یادگیری (η) را با استفاده از معادله ۴ کاهش داده شد:

$$\eta_n = \eta_0 + (x-1) \frac{n\eta_0 T}{Q-n_1} \quad (4)$$

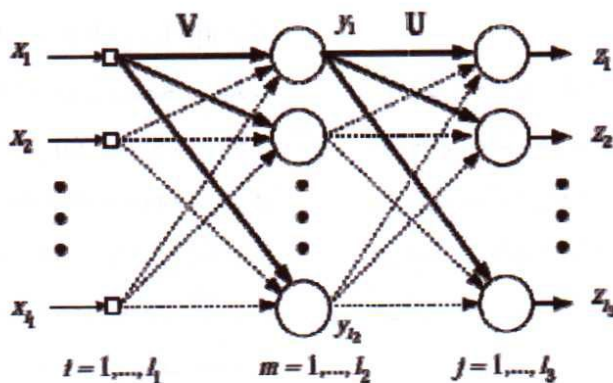
در اینجا n_1 ، η_n و η_0 به ترتیب نقطه شروع BDLRF، آهنگ یادگیری در n امین جمله از تصاعد حسابی و مقدار اولیه آهنگ یادگیری می‌باشند. تابع هزینه بکار رفته در این الگوریتم مجموع کل مربعات خطا (TSSE^۳) می‌باشد و بصورت زیر محاسبه می‌شود:

$$TSSE = \sum_q \sum_k (d_k^q - z_k^q)^2 \quad q=1, \dots, Q \quad (5)$$

1- Back propagation with declining learning-rate factor

2 - Vakil-Baghmisheh and Pavešic

3- Total sum-squared error



شکل ۱- ساختار شبکه RBF با یک لایه مخفی (وکیل باغمیشه، ۲۰۰۴)

و معیارهای ارزیابی عملکرد شبکه عصبی: برای ارزیابی قابلیت شبکه عصبی RBF در پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور از معیارهای متوسط قدرمطلق درصد خطا ($MAPE^1$)، ریشه متوسط مربعات خطا ($RMSE^2$) و ضریب تبیین معادله خطی رگرسیونی بین مقادیر پیش‌بینی شده توسط شبکه عصبی و مقادیر واقعی آنها استفاده شدند (روحانی، ۲۰۱۱).

معیارهای ارزیابی عملکرد شبکه عصبی $CCI_{fuel} = f(CHU)$ و $CCI_{oil} = f(CHU)$ و $CCI_{repair} = f(CHU)$ تنظیم پارامترهای شبکه: لایه ورودی در شبکه شامل ۲ نرون می‌باشد زیرا ورودی‌های شبکه شامل عامل بایاس و ساعات کارکرد جمع می‌باشند. لایه خروجی تنها شامل یک نرون است که آن می‌تواند نشان دهنده هر یک از سه شاخص هزینه تعمیر، روغن و سوخت باشد. تعیین توپولوژی بهینه، تعداد نرون‌ها در لایه مخفی، بستگی به نوع مسأله دارد. اگر تعداد نرون‌ها در لایه مخفی کافی نباشد، شبکه قادر به یادگیری خوب نخواهد بود. عملکرد شبکه با افزایش تعداد نرون‌ها در لایه مخفی بهبود می‌یابد ولی در تعداد بسیار زیاد آن مسأله بیش برآزشی^۳ به وجود خواهد آمد که این امر منجر به تضعیف ویژگی تعمیم پذیری شبکه می‌شود (وانگ و الهاگ^۴، ۲۰۰۷). با در نظر گرفتن این موضوع و از طریق آزمون و خطا بر اساس معیارهای عملکردی بهترین توپولوژی هر شبکه انتخاب شد. این فرآیند برای تعداد نرون‌های لایه مخفی ۲ تا تعداد کل داده‌های استفاده شده در مجموعه آموزش انجام شد. بهترین نتایج برای هر سه شاخص هزینه در تعداد کل داده‌های استفاده شده در مجموعه آموزش نرون در لایه مخفی برای تمام شبکه‌های شاخص هزینه تعمیر، روغن، سوخت بدست آمد. بعد از بدست آوردن توپولوژی‌های بهینه برای هر

معیارهای ارزیابی عملکرد شبکه عصبی: برای ارزیابی قابلیت شبکه عصبی RBF در پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور از معیارهای متوسط قدرمطلق درصد خطا ($MAPE^1$)، ریشه متوسط مربعات خطا ($RMSE^2$) و ضریب تبیین معادله خطی رگرسیونی بین مقادیر پیش‌بینی شده توسط شبکه عصبی و مقادیر واقعی آنها استفاده شدند (روحانی، ۲۰۱۱).

$$RMSE = \sqrt{\frac{\sum_{j=1}^n \sum_{i=1}^m (d_{ji} - p_{ji})^2}{nm}} \quad (9)$$

$$MAPE = \frac{1}{nm} \sum_{j=1}^n \sum_{i=1}^m \left| \frac{d_{ji} - p_{ji}}{d_{ji}} \right| \times 100 \quad (10)$$

در اینجا d_{ji} مؤلفه i ام از خروجی واقعی مربوط به پترن j ام، p_{ji} مؤلفه i ام از خروجی پیش‌بینی شده توسط شبکه مربوط به پترن j ام، \bar{d} و \bar{p} به ترتیب متوسط خروجی‌های واقعی و پیش‌بینی شده توسط شبکه و n و m به ترتیب تعداد پترن‌ها و تعداد متغیرهای خروجی هستند.

نتایج و بحث

برای پیدا کردن هر یک از روابط $CCI_{oil} = f(CHU)$ ، $CCI_{repair} = f(CHU)$

3 - Over-fitting
4 - Wang and Elhag


1 - Mean absolute percentage error
2 - Root mean squared error

برای داشتن عملکرد بهتر، تقسیم داده به دو مجموعه آموزش و آزمون در هر مورد می‌تواند متفاوت از هم باشند. تفاوت زیادی بین ویژگیهای آماری مقادیر پیش‌بینی شده و مقادیر واقعی آنها برای شبکه عصبی آموزش دیده ملاحظه نمی‌شود. بر اساس این نتایج می‌توان ادعا کرد که شبکه‌های عصبی با موفقیت آموزش دیده‌اند؛ زیرا در غیر این صورت باید تفاوت بین مقادیر واقعی شاخص هزینه‌ها و مقادیر پیش‌بینی شده آنها در مجموعه آزمون زیاد باشد. همچنین به دلیل نزدیک بودن بسیار زیاد مقادیر میانگین، مجموع و کشیدگی می‌توان نتیجه گرفت که داده‌های واقعی و پیش‌بینی شده مشابه هم هستند.

برای اثبات ادعای ما در مورد قابل اطمینان بودن شبکه‌های عصبی آموزش دیده برای پیش‌بینی هزینه‌های تعمیر و نگهداری این نوع تراکتور، 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 ۹۵ درصد به کمک پارامتر p آزمون گردید. به ترتیب برای مقایسه میانگین، واریانس و توزیع آماری از آزمون F ، t و کولموگروف-اسمیرنو استفاده شد. جدول ۲ مقادیر p محاسبه شده برای هر سه شاخص هزینه به کمک شبکه عصبی RBF را نشان می‌دهد. این نتایج نشان می‌دهند که میانگین، واریانس و توزیع آماری مقادیر واقعی و پیش‌بینی شده هر سه شاخص هزینه توسط هر شبکه عصبی اختلاف معنی‌داری با هم ندارند. بنابراین شبکه عصبی RBF دارای قابلیت بالایی برای پیش‌بینی هزینه‌های تعمیر و نگهداری می‌باشد.

شبکه، باید مقادیر بهینه پارامترهای یادگیری (η_1, η_2) و η_3 را به دست آورد. مقادیر بهینه پارامترهای نیز از طریق آزمون و خطا انتخاب شدند. عملکرد شبکه برای تمام ترکیبات مقادیر آهنگ یادگیری و عامل ممتوم در بازه تغییراتی [۰/۹۹] برای η ها با هم مقایسه شدند. نتایج نشان می‌دهند که بهترین عملکرد شبکه‌های منفرد در $\eta_1 = \eta_2 = 10^{-6}$ و $\eta_3 = 0/95$ بدست می‌آید. ۱۰۰۰ تعداد بهینه تکرارهای مورد نیاز شبکه‌های شاخص هزینه تعمیر، روغن، سوخت همراه با نقطه شروع (η_1) در ۵ به دست آمد. مقایسه نتایج به کارگیری دو روش نرمالیزاسیون برای هر شبکه نشان داد که نرمالیزاسیون خطی موجب عملکرد بهتری می‌شود؛ لذا از این روش جهت نرمال کردن داده‌ها استفاده شد.

تحلیل آماری: بعد از آنکه وزن‌های شبکه (اتصالات بین نرونها) در طول فاز آموزش محاسبه گردید، فاز آزمون شبکه آغاز می‌شود. در فاز آزمون از همان توپولوژی و نیز وزن‌های تنظیم شده در طول فاز آموزش استفاده شد. هدف از این مرحله ارزیابی ویژگی تعمیم‌پذیری شبکه عصبی آموزش دیده است. بنابراین ما شبکه را با استفاده از مجموعه داده‌های غیر از مجموعه داده‌های آموزش (مجموعه داده‌های آزمون) ارزیابی شد. در اینجا تنها به آوردن نتایج حاصل از ارزیابی شبکه‌های عصبی آموزش دیده اکتفا گردید؛ زیرا معتبر بودن این نتایج دال بر موفقیت آمیز بودن فاز آموزش برای هر شبکه مورد بررسی می‌باشد. جدول ۱ برخی ویژگی‌های آماری داده‌های استفاده شده در فاز آزمون همراه با مقادیر پیش‌بینی شده آنها توسط شبکه‌های عصبی RBF برای شاخص هزینه تعمیر، روغن و سوخت در نشان می‌دهد. بر اساس زانگ و فو (۱۹۹۸)



شکل ۲- ساختار شبکه RBF برای پیش‌بینی هزینه‌های تعمیر و نگهداری

جدول ۱- ویژگی‌های آماری مقادیر واقعی و پیش‌بینی شده شاخص‌های هزینه توسط شبکه عصبی در فاز آزمون

ویژگی‌های آماری								شاخص
sum	Ske	kur	max	min	std	Var	av	هزینه
۵۰۸۵/۱	-۰/۰۲	۱/۶۱	۱۳۵/۵	۰/۵۸	۴۳/۷	۱۹۱۲/۳	۶۶/۰۴	dv
۵۰۸۳/۹	-۰/۰۲	۱/۶۱	۱۳۴/۶	۰/۶۶	۴۳/۶	۱۹۰۷/۱	۶۶/۰۲	CCI_{repair}
۶۷۵/۷	-۰/۲۷	۱/۷۵	۱۷/۳	۰/۰۵	۴/۹	۲۴/۲	۸/۷۸	dv
۶۷۵/۳	-۰/۲۷	۱/۷۳	۱۷/۰۰	۰/۳۷	۴/۸	۲۳/۹	۸/۷۷	CCI_{oil}
۱۹۰/۸	۱/۰۳	۲/۸۳	۹/۵	۰/۰۰	۲/۸	۸/۰	۲/۴۸	dv
۱۸۹/۹	۱/۰۴	۲/۸۵	۹/۳	۰/۰۱	۲/۸	۷/۹	۲/۴۷	CCI_{fuel}

توضیحات: av: میانگین var: واریانس std: انحراف معیار min: کمینه max: بیشینه kur: کشیدگی

ske: چولگی sum: مجموع dv: مقادیر واقعی داده‌ها pv: مقادیر پیش‌بینی شده توسط شبکه عصبی RBF

جدول ۲- مقایسه آماری مقادیر واقعی و پیش‌بینی شده شاخص‌های هزینه تعمیر و نگهداری در فاز آزمون

نوع تحلیل آماری			شاخص
مقایسه توزیع	مقایسه واریانس	مقایسه میانگین	هزینه
۱/۰۰۰	۰/۹۹۹	۱/۰۰۰	CCI_{repair}
۱/۰۰۰	۰/۹۶۳	۰/۹۹۵	CCI_{oil}
۰/۹۷۹	۰/۹۷۸	۰/۹۷۹	CCI_{fuel}

عرض از مبدا (نزدیک به صفر) و شیب نزدیک به یک باشد ($pv=1/1000 dv+0/1000$). کاملاً واضح است که ضرایب تبیین بین داده‌های واقعی و پیش‌بینی شده بسیار بالا می‌باشند ($R^2=0/999$). همچنین معادله خطی رگرسیونی ما بین آنها دارای شیب‌های نزدیک به واحد و عرض از مبداهای کوچکی هستند، بنابراین می‌توان به چنین شبکه‌های اطمینان داشت. ضریب تبیین داده‌های

جدول ۳ ضرایب تبیین و همچنین رابطه خطی رگرسیونی بین شاخص‌های هزینه تجمعی واقعی در مقابل شاخص‌های هزینه پیش‌بینی شده توسط شبکه عصبی را نشان می‌دهد. بهترین نتایج براساس این دو معیار وقتی به دست می‌آید که معادله خطی ما بین شاخص هزینه واقعی و شاخص هزینه پیش‌بینی شده توسط شبکه عصبی علاوه بر داشتن ضرایب تبیین بالا دارای کم‌ترین

ظریف نشاط و همکاران.... پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور فیات....

رگرسیون برای تراکتور دو چرخ محرک کمتر از ۵/۲۱ درصد گزارش شده است (روحانی و همکاران، ۱۳۸۹). خطای پیش‌بینی هزینه‌های تعمیر و نگهداری با استفاده از مدل شبکه عصبی چند لایه پرسپترون برای تراکتور جان‌دیر کمتر از ۲/۶۴ درصد گزارش شده است (رنجبر و همکاران، ۱۳۸۸). خطای پیش‌بینی هزینه‌های تعمیر و نگهداری با استفاده از مدل شبکه عصبی چند لایه پرسپترون برای تراکتور دو چرخ محرک کمتر از ۲/۷۴ درصد گزارش شده است (روحانی و همکاران، ۲۰۱۱). بنابراین نتایج این تحقیق نشان داد که عملکرد شبکه عصبی RBF در مقابل شبکه عصبی چند لایه پرسپترون و نیز مدل‌های رگرسیونی برتری دارد.

واقعی و پیش‌بینی شده توسط مدل‌های رگرسیون و شبکه عصبی پرسپترون چند لایه نیز بالا گزارش شده است (روحانی و همکاران ۲۰۱۱، رنجبر و همکاران ۱۳۸۸). عملکرد شبکه عصبی RBF طراحی شده از نظر معیارهای متوسط قدر مطلق درصد خطا (MAPE) و نیز ریشه متوسط مربعات خطا (RMSE) در دو فاز آموزش، آزمون و کل داده‌ها با هم مقایسه شده است (جدول ۴). کاملاً واضح است که مقادیر خطا در فاز آموزش، آزمون و کل بسیار کم است که این نشان از قابلیت بسیار بالای شبکه عصبی مصنوعی RBF در پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور دارد. خطای پیش‌بینی هزینه‌های تعمیر و نگهداری با استفاده از مدل‌های

جدول ۳- رابطه خطی رگرسیونی و ضریب تبیین بین داده‌های واقعی (dv) و پیش‌بینی شده (pv)

برای مجموعه داده‌های آزمون		
R ^۲	رابطه خطی رگرسیونی	شاخص هزینه
۰/۹۹۹	$pv = ۰/۹۹۹ dv + ۰/۰۱۸$	CCI_{repair}
۰/۹۹۹	$pv = ۰/۹۹۴ dv + ۰/۰۴۴$	CCI_{oil}
۰/۹۹۹	$pv = ۰/۹۹۶ dv - ۰/۰۰۳$	CCI_{fuel}

جدول ۴- عملکرد شبکه عصبی در پیش‌بینی هزینه تعمیر و نگهداری

شاخص هزینه	معیار عملکردی شبکه					
	RMSE		MAPE		فاز آموزش	
	فاز آزمون	فاز آموزش	کل	فاز آزمون		
CCI_{repair}	۰/۷۸	۰/۷۸	۰/۶۴	۰/۶۵	۰/۶۳	
CCI_{oil}	۰/۱۰	۰/۱۱	۰/۰۸	۰/۰۷	۰/۰۶	
CCI_{fuel}	۰/۰۹	۰/۰۸	۰/۰۹	۰/۰۶	۰/۰۷	

منابع

- اسکونزاد، م. م. ۱۳۸۳. اقتصاد مهندسی یا ارزیابی اقتصادی پروژه‌های صنعتی. انتشارات دانشگاه صنعتی امیرکبیر.
- الماسی، م.، لویمی، ن. و کیانی، ش. ۱۳۷۸. مبانی مکانیزاسیون کشاورزی. انتشارات حضرت معصومه.
- روحانی، ع.، رنجبر، ا.، عباسپور، م. ح.، عجب شیرچی، ی. و ولی زاده، م. ۱۳۸۹. ارزیابی مدل‌های رگرسیون در پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور. تحقیقات مهندسی کشاورزی. جلد ۱۱، صص ۸۷-۹۶

- ۴- رنجبر، ا.، عباسپور، م.ح.، عجب شیرچی، ی. و روحانی، ع. ۱۳۸۸. پیش بینی هزینه های تعمیر و نگهداری تراکتور جاندیر با استفاده از دو ساختار متفاوت شبکه عصبی MLP. اقتصاد و توسعه کشاورزی. جلد ۲۲، صص ۹۶-۸۷.
- 5- 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.
- 6- Bowers, W., and Hunt, D.R. 1970. Application of mathematical formula to repair cost data. *Transaction of American Society of Agricultural Engineering*, 13: 806-809.
- 7- Gupta, M.M., Jin, J., and Homma, N. 2003. *Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory*. John Wiley and Sons, Inc., Hoboken, New Jersey.
- 8- Hanke, J.E., and Reitsch, A.G. 1995. *Business Forecasting*. Prentice-Hall, Englewood Cliffs, NJ.
- 9- Haykin, S., 1994. *Neural networks: A comprehensive foundation*. McMillan College Publishing Company, New York.
- 10- Kim, Y.H. 1989. A forecasting methodology for maintenance cost of long-life equipment. Doctoral thesis. University of Alabama.
- 11- Mayfield, W., Hills, G.S., and Roberts, L. 1981. A New method for estimating farm machinery cost. *Transaction of American Society of Agricultural Engineering*, pp:53-55.
- 12- Mitchell, Z.W. 1998. *A Statistical Analysis of Construction Equipment Repair Costs Using Field Data & the Cumulative Cost Model*. PhD Thesis, Faculty of the Virginia, Polytechnic Institute and State University.
- 13- Rohani, A., Abbaspour-Fard, M.H., and Abdolahpour, S. 2011. Prediction of tractor repair and maintenance costs using Artificial Neural Network. *Expert Systems with Applications*, 38: 8999-9007.
- 14- Rotz, C.A. 1987. A Standard Model for Repair Costs of Agricultural Machinery. *Applied Engineering in Agriculture*, 3(1): 3-9.
- 15 - Torrecilla, J.S., Otero, L., and Sanz, P.D. 2004. A neural network approach for thermal/pressure food processing. *Food Engineering*, 62:89-95.
- 16 - Vakil-Baghmisheh, M,T. 2002. *Farsi Character Recognition Using Artificial Neural Networks*. PhD Thesis, Faculty of Electrical Engineering, University of Ljubljana.

- 17- Vakil-Baghmisheh, M.T., and Pavešic, N. 2003. A Fast simplified fuzzy ARTMAP network. *Neural Processing Letters*. 17:273-301.
- 18- Vakil-Baghmisheh, M.T., and Pavešic., N. 2004. Training RBF networks with selective backpropagation. *Neurocomputing*, 62: 39-64.
- 19- Veelenturf, L.P.J., 1995. *Analysis applications of artificial neural networks*. Simon and Schuster international group, United States of America.
- 20- Zhang, Y.F., and Fuh, J.Y.H. 1998. A neural network approach for early cost estimation of packaging products. *Computers and Industrial Engineering*, 34: 433-50.
- 21- Wang, Y.M., and 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.

Prediction of Fiat Tractor Repair and Maintenance Costs by Means of RBF Artificial Neural Network

A. Rohani¹, S. Zarifneshat^{*2} and M.H. Abbaspour Fard³

1. Assistant Professor at Water and Soil Science Department, Faculty of Agriculture, Shahroud University of Technology, Iran
2. ***Corresponding Author:** Assistant Professor of Engineering Department, Agricultural and Natural Resources Research Center of Khorasan Razavi, Iran (zarifneshat@yahoo.com)
3. Associate Professor of Agricultural Machinery, Faculty of Agriculture, Ferdowsi University of Mashahd, Iran

Received: 9 April 2012

Accepted: 19 September 2012

Abstract

The prediction of repair and maintenance costs has significant impact on decisions making of farm machinery manager. The purpose of this research was to evaluate RBF artificial neural network capability in predicting tractor repair and maintenance costs. The study was conducted using empirical data on 10 Fiat tractors from Astan Ghodse Razavi agro-industry. Optimal parameters for the RBF neural network were selected via a trial and error procedure on the available data. In order to evaluate the performance of the RBF model in the prediction of tractor repair and maintenance costs, some statistical tests, such as comparisons of the means, variance, statistical distribution as well as linear regression were used between the actual data and the prediction data using RBF neural network. Results showed that in training phase and test phase, P-value was greater than 0.99, indicating that there was no significant difference between statistical parameters such as average, variance and statistical distribution. These results suggest that RBF neural network can learn tractor repair and maintenance costs model very well. In addition, results indicated that trained RBF neural network has a high capability in predicting tractor repair and maintenance costs with errors less than 0.64 percentages. The results revealed that RBF neural network was able to predict accurately repair and maintenance costs. Therefore, neural network can improve the economic decision making capabilities of machine managers.

Keywords: RBF, Artificial neural network, Repair and Maintenance costs