

پیش بینی هزینه های تعمیر و نگهداری تراکتور جاندر با استفاده از دو ساختار متفاوت شبکه عصبی MLP

ایرج رنجبر - محمدحسین عباسپور فرد* - یحیی عجب شیرچی - عباس روحانی^۱

تاریخ دریافت: ۸۷/۸/۲۰

تاریخ پذیرش: ۸۷/۱۲/۱۹

چکیده

جایگزینی تراکتور یکی از تصمیمات مهم مدیر ماشین های کشاورزی می باشد. یکی از فاکتورهای بسیار اساسی در این تصمیم گیری، پیش بینی دقیق هزینه های تعمیر و نگهداری می باشد. هدف از این تحقیق، ارزیابی قابلیت پیش بینی هزینه های تعمیر و نگهداری تراکتور با استفاده از ساختار شبکه عصبی مصنوعی MLP^۲ می باشد. در ابتدا شبکه های جداگانه برای هر یک از اجزاء هزینه های تعمیر و نگهداری و سپس یک شبکه برای پیش بینی همزمان آنها طراحی شد. از داده های واقعی ۲۸ تراکتور جاندر موجود در کشت و صنعت آستان قدس رضوی در این مطالعه استفاده شده است. نتایج حاصل نشان می دهد که هر دو نوع شبکه عصبی قادر به پیش بینی دقیق هزینه های تعمیر و نگهداری تراکتور است. همچنین پیش بینی عناصر هزینه تعمیر و نگهداری تراکتور با یک شبکه منجر به نتایج عملکردی بهتری نسبت به بکارگیری شبکه های جداگانه برای پیش بینی هر یک از اجزاء هزینه شده است. بنابراین، شبکه عصبی می تواند قابلیت تصمیم گیری اقتصادی مدیران ماشین را بهبود بخشد.

واژه های کلیدی: شبکه عصبی پرسپترون، تعمیر و نگهداری، تراکتور، پیش بینی هزینه

مقدمه

اقتصادی مدیر ماشین می باشد (۲۰۱). کلید موفقیت در این تصمیم گیری، پیش بینی دقیق هزینه های تعمیر و نگهداری می باشد (۱۱). پیش بینی اقتصادی، کشف الگوی تغییراتی داده های موجود است (۸). هزینه های تعمیر و نگهداری بشدت وابسته به مکان، زمان و سیاست های مدیریتی می باشد. لذا پیش بینی دقیق چنین هزینه های بسیار مشکل می باشد (۱۳). انجمن مهندسين کشاورزی امریکا برای اولین بار مدل های رگرسیونی برای پیش بینی هزینه های تعمیر و نگهداری ارائه داد (۴). روتز مدلی توانی را جهت برآورد این هزینه ها پیشنهاد کرد (۱۵). فولس مدلی را پیشنهاد کرد که در آن پارامتر جدیدی برای لحاظ نمودن

تراکتور یکی از ابزارهای تعیین کننده برای انجام به موقع عملیات زراعی می باشد (۶). تصمیمات اقتصادی با هدف رسیدن به بیشترین سود یکی از عوامل تعیین کننده در موفقیت مدیر می باشد (۱۴). اطلاع دقیق از هزینه ها نقش اصلی در بسیاری از تصمیمات مطلوب مدیریت ماشین ها ایفا می کند (۱۲ و ۱۵). جایگزینی ماشین، مهمترین تصمیم

۱- به ترتیب دانشیار گروه ماشین های کشاورزی دانشگاه تبریز، دانشیار گروه ماشین های کشاورزی دانشگاه فردوسی مشهد، دانشیار و دانشجوی دکتری رشته مکانیزاسیون گروه ماشین های کشاورزی کشاورزی دانشگاه تبریز

* - نویسنده مسئول: hossein_abbaspour@yahoo.co.uk Email:

استانداردسازی، پیش پردازش داده‌های هزینه تعمیر و نگهداری، تقسیم‌بندی آنها و همچنین الگوریتم BDLRF در آموزش شبکه عصبی ارائه خواهد شد و در ادامه نحوه تنظیم پارامترهای شبکه و در انتها عملکرد شبکه عصبی MLP در پیش‌بینی هزینه تعمیر و نگهداری تراکتور به کمک تحلیل آماری توضیح داده خواهد شد.

مواد و روش‌ها

داده‌های هزینه‌های تعمیر و نگهداری: برای انجام این مطالعه از داده‌های هزینه تعمیر و نگهداری ماهانه ۲۸ تراکتور جان‌دیر ۳۱۴۰ در طی سال‌های ۱۳۸۲-۱۳۶۷ از شرکت کشت و صنعت آستان قدس رضوی در استان خراسان رضوی استفاده شد. این داده‌ها شامل هزینه تعمیرات، هزینه روغن، هزینه سوخت و سال خرید و ساخت هر تراکتور می‌باشند.

استانداردسازی هزینه‌ها: بدلیل متفاوت بودن هزینه‌های تعمیر و نگهداری و نیز تا حدودی قیمت خرید اولیه تراکتورهای مورد مطالعه، تمام این هزینه‌ها را توسط شاخص زیر استانداردسازی شد (۱۳).

$$CCI_t = \frac{\sum C_t}{PP_0} \times 100 \quad (1)$$

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. در اینجا با در نظر گرفتن سال خرید بعنوان سال پایه و قبل از محاسبه شاخص هزینه تجمعی، اثر تورم بر هزینه‌ها تعدیل شدند. بعد از این مرحله، شاخص‌های تجمعی بصورت شاخص هزینه تعمیراتی تجمعی (CCI_{repair})، شاخص هزینه روغن تجمعی (CCI_{oil})، شاخص هزینه سوخت تجمعی (CCI_{fuel}) محاسبه می‌شود. این شاخص‌ها بعنوان خروجی شبکه عصبی لحاظ شدند.

طول عمر تراکتور: عمر تراکتور اساسی‌ترین جزء

مدلسازی هزینه‌های تعمیر و نگهداری می‌باشد و ورودی

تاثیر سیاست‌های مدیریتی و مهارت کاربر در تخمین هزینه‌های تعمیر و نگهداری به مدل اضافه کرد (۵). تا کنون تمام مدل‌های ریاضی پیشنهاد شده براساس مدل رگرسیونی روتر بنا شده‌اند. اما در عمل بندرت مدیران رغبتی به استفاده از مدل‌های ریاضی نشان می‌دهند. در این مقاله شبکه عصبی بعنوان یک روش جایگزین برای پیش‌بینی هزینه‌های تعمیر و نگهداری ارزیابی می‌شود.

ساختار شبکه عصبی مصنوعی مشابه سیستم عصبی بیولوژی مغز انسان است (۷). مزیت شبکه عصبی یادگیری مستقیم از روی داده‌ها بدون نیاز به برآورد مشخصات آماری آنها است (۱۸). شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و 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 (۱۰ و ۱۶). شبکه عصبی قادر به تخمین هر تابع غیر خطی پیوسته می‌باشد (۹). ویژگی دیگر شبکه عصبی، تحمل پذیری در مقابل خطا می‌باشد (۳). این مزایا دلایل بکارگیری شبکه عصبی در پیش‌بینی هزینه تعمیر و نگهداری تراکتور را برای ما روشن می‌سازد. در این مطالعه از شبکه چند لایه پرسپترون (MLP) استفاده شد. الگوریتم پس انتشار^۱ معمولترین روش آموزش شبکه می‌باشد ولی در این مطالعه از الگوریتم پس انتشار با نرخ کاهش^۲ (BDLRF)، نوع اصلاح شده الگوریتم اصلی پس انتشار (۱۷)، استفاده شد. اساس این دو الگوریتم کمینه کردن محاسبه انحراف خروجی شبکه از خروجی واقعی می‌باشند. ارزیابی شایستگی شبکه آموزش دیده در شرایط کاملاً جدید توسط مجموعه داده‌های غیر از داده‌های آموزش انجام می‌گیرد (۷ و ۲۰).

مقاله از دو بخش کلی تشکیل شده است. در ابتدا نحوه

1 - Back propagation

2- Backpropagation with declining learning-rate factor (BDLRF)

شبکه عصبی پرسپترون چندلایه: اگر تعداد نرون‌های لایه مخفی و نیز داده‌های آموزش بمقدار کافی باشد آنگاه MLP بطور واقعی می‌تواند هر تابع را تقریب بزند (۱۰). 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 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 الگوریتم پس انتشار با نرخ یادگیری کاهششی (BDLRF^۲) استفاده شد. مزیت این الگوریتم در مقابل با الگوریتم پس انتشار اصلی (BB^۳) بعنوان یک الگوریتم رایج در آموزش MLP شامل سهولت در تنظیم پارامترهای یادگیری، کاهش زمان یادگیری و بهبود رفتار شبکه در طول آموزش می‌باشد. کد کامپیوتری این الگوریتم در محیط برنامه نویسی MATLAB تهیه شد.

پ الگوریتم BDLRF: این الگوریتم آموزش با آهنگ یادگیری (η) و عامل ممتوم (α) ثابت و نسبتا بزرگ شروع می‌کند و قبل از آنکه شبکه ناپایدار و یا همگرایی آن کند شود، هر T تکرار ($3 \leq T \leq 5$)، η و α را از طریق تصاعد حسابی بصورت یکنواخت کاهش داده می‌شود تا زمانیکه این پارامترها به x درصد (۵٪) مقادیر اولیه خودشان برسند. η و بطور مشابه α را با استفاده از فرمول زیر کاهش داده شد (۱۷):

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

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.

شبکه عصبی را تشکیل می‌دهد. ساعات کارکرد جمعی (CHU^۱)، مناسب‌ترین تعریفی است که می‌توان از عمر تراکتور داشت (۱۳). 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.

پیش پردازش داده‌ها: در ابتدا بطور تصادفی داده‌ها 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 مجددا تکرار کرد (۲۱). قبل از بکارگیری داده‌های خام اولیه در آموزش و تست شبکه باید آنها را نرمالیزه کنیم زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد مناسبی داشته باشد و در غیر اینصورت شبکه در طول فاز آموزش همگرا نخواهد شد و نتایج مطلوب تولید نخواهد شد (۳). زمانیکه از تابع فعالیت سیگموئیدی استفاده می‌شود، بهترین دامنه تبدیل داده‌ها $[0/1, 0/9]$ می‌باشد (۱۸). از نرمالیزاسیون خطی (معادله ۲) و نرمالیزاسیون غیر خطی (معادله ۳) برای تبدیل داده‌ها استفاده شد:

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

$$(3)$$


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

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

2- Backpropagation with declining learning-rate factor

3 - Basic backpropagation

1- Cumulative hours of usage(CHU)



شکل (۱) ساختار شبکه MLP با یک لایه مخفی (وکیل-باغمیشه ۲۰۰۲)

می توان در وکیل-باغمیشه و پائوسیک (۲۰۰۳) مشاهده کرد. معیارهای ارزیابی عملکرد شبکه عصبی: برای ارزیابی قابلیت شبکه MLP در پیش بینی هزینه ها از معیارهای متوسط قدرمطلق درصد خطا (MAPE^۲)، ریشه متوسط مربعات خطا (RMSE^۳) و ضریب تبیین معادله خطی رگرسیونی بین مقادیر پیش بینی شده توسط شبکه عصبی و مقادیر واقعی آنها استفاده شدند.

$$RMSE = \sqrt{\frac{\sum_{j=1}^n \sum_{i=1}^m (d_{ji} - p_{ji})^2}{nm}} \quad (۸)$$

$$MAPE = \frac{1}{nm} \sum_{j=1}^n \sum_{i=1}^m \left| \frac{d_{ji} - p_{ji}}{d_{ji}} \right| \times 100 \quad (۹)$$

در اینجا d_{ji} مؤلفه i ام از خروجی واقعی مربوط به پترن j ام، p_{ji} مؤلفه i ام از خروجی پیش بینی شده توسط شبکه مربوط به پترن j ام و n و m به ترتیب تعداد پترن ها و تعداد متغیرهای خروجی هستند.

نتایج و بحث

در ابتدا برای پیدا کردن هر یک از روابط $CCI_{oil} = f(CHU)$ ، $CCI_{repair} = f(CHU)$ و $CCI_{fuel} = f(CHU)$ شبکه های عصبی جداگانه طراحی

تابع هزینه بکار رفته در این الگوریتم مجموع کل مربعات خطا (TSSE^۱) می باشد:

$$TSSE = \sum_q \sum_k (d_k^q - z_k^q)^2, \quad q = 1, \dots, Q \quad (۵)$$

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 زیر محاسبه می شوند.

$$u_{jk}(n+1) = u_{jk}(n) - \eta \times \frac{\partial E}{\partial u_{jk}} + \alpha (u_{jk}(n) - u_{jk}(n-1)) \quad (۶)$$

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

$$w_{ij}(n+1) = w_{ij}(n) - \eta \times \frac{\partial E}{\partial w_{ij}} + \alpha (w_{ij}(n) - w_{ij}(n-1)) \quad (۷)$$

در اینجا w_{ij} اتصال وزنی بین گره های i و j ، u_{jk} اتصال 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. η و α به ترتیب آهنگ یادگیری و فاکتور ممتوم هستند و مقادیر آنها در فاصله $[0, 1]$ قرار دارند و n شماره تکرار الگوریتم ($n = 1, \dots, N$). زمانی الگوریتم متوقف می شود که TSSE کوچکتر از مقدار آستانه (۰/۰۰۰۱) باشد. جزئیات بیشتر این الگوریتم را

2 - Mean absolute percentage error

3 - Root mean squared error

1 - Total sum-squared error

پارامتر در عملکرد شبکه، پیدا کردن مقادیر بهینه آنها مشکل می‌باشد (۱۷). مقادیر بهینه پارامترهای η و α نیز از طریق آزمون و خطا انتخاب شدند. عملکرد شبکه برای تمام ترکیبات مقادیر آهنگ یادگیری و عامل ممتوم در بازه تغییراتی [۰/۱۰/۹۹] برای η و [۰/۰/۹۹] برای α با هم مقایسه شدند. نتایج نشان می‌دهند که بهترین عملکرد شبکه‌های منفرد در سطح ثابت $\alpha=0/95$ بدست می‌آید. بنابراین در طول آموزش شبکه تنها پارامتر یادگیری از آهنگ کاهشی برخوردار شد. مقادیر بهینه اولیه η به ترتیب ۰/۹۵، ۰/۸، ۰/۸ و برای شبکه‌های هزینه تعمیر، روغن و سوخت بدست آمد. همچنین مقادیر بهینه اولیه $\eta=0/7$ و $\alpha=0/8$ برای شبکه کلی پیدا شد. ۱۰۰۰۰، ۱۰۰۰۰، ۸۰۰۰ و ۲۵۰۰۰۰ به ترتیب تعداد بهینه تکرارهای مورد نیاز شبکه‌های شاخص هزینه تعمیر، روغن، سوخت و شبکه کلی همراه با نقطه شروع (n_1) در ۲۰۰۰۰، ۷۰۰۰، ۶۰۰۰ و ۱۴۵۰۰۰ بدست آمد. در انتها مقادیر η به ترتیب به ۰/۴۷۵، ۰/۴ و ۰/۴ برای شبکه‌های منفرد تعمیر، روغن و سوخت رسیدند. همچنین مقادیر نهایی η و α به ترتیب به ۰/۳۵ و ۰/۴ رسیدند. ساختار شبکه کلی برای پیش‌بینی همزمان هر سه شاخص هزینه در شکل ۲ نشان داده شده است. مقایسه نتایج نشان داد که نرمالیزاسیون خطی اگرچه باعث تعداد تکرارهای کمتری می‌شود ولی در شبکه هزینه تعمیر و شبکه کلی منجر به تخمین منفی از شاخص‌های هزینه می‌شود. بنابراین نرمالیزاسیون خطی برای شبکه‌های منفرد هزینه روغن و سوخت و نرمالیزاسیون غیر خطی برای شبکه منفرد هزینه تعمیر و شبکه کلی انتخاب شدند.


تحلیل آماری: بعد از آنکه وزن‌های شبکه در طول فاز آموزش محاسبه گردید، فاز تست شبکه آغاز 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 شبکه آموزش دیده است. بنابراین ما

شد. سپس در ادامه یک شبکه برای تعیین رابطه بین CHU و سه شاخص هزینه $(CCI_{repair}, CCI_{oil}, CCI_{fuel}) = f(CHU)$ طراحی شد. در انتها نتایج حاصل از هر شبکه منفرد با شبکه کلی مقایسه شدند. 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 (۹)، یک لایه مخفی برای تمام شبکه‌های عصبی انتخاب شدند.

تنظیم پارامترهای شبکه: لایه ورودی در هر دو نوع شبکه کلی و شبکه‌های منفرد شامل ۲ نرون می‌باشد زیرا ورودی‌های شبکه شامل عامل بایاس و ساعات کارکرد تجمعی می‌باشند. لایه خروجی در شبکه‌های منفرد تنها شامل یک نرون است یعنی هر یک از سه شاخص هزینه تعمیر، روغن و سوخت. در حالیکه لایه خروجی در شبکه کلی شامل ۳ نرون است زیرا این شبکه باید بطور همزمان هر سه شاخص هزینه را پیش‌بینی نماید. اگر تعداد نرون‌ها در لایه مخفی کافی نباشد، شبکه قادر به یادگیری خوب نخواهد شد. عکس این مسئله منجر به تضعیف ویژگی تعمیم‌پذیری شبکه می‌شود (۲۲). با در نظر گرفتن این موضوع و از طریق آزمون سعی و خطا و بر اساس معیارهای عملکردی بهترین توپولوژی هر شبکه انتخاب شد. در طول آزمون آهنگ یادگیری، عامل ممتوم و تعداد تکرارها ($n_1=9500$ ، $\eta=0/5$ ، $\alpha=0/95$ و $Q=10000$) ثابت نگه داشته شد. این فرآیند برای تعداد نرون‌های لایه مخفی ۵ تا ۲۰ انجام شد. نهایتاً بهترین نتایج به ترتیب در ۶، ۷، ۷ و ۱۵ نرون در لایه مخفی برای شبکه‌های هزینه تعمیر، روغن، سوخت و شبکه کلی بدست آمد. بعد از بدست آوردن توپولوژی‌های بهینه برای هر شبکه، باید مقادیر بهینه پارامتر یادگیری (η) و عامل ممتوم (α) را بدست آورد. برای دستیابی به عملکرد بهتر و تسریع در همگرایی شبکه از عامل ممتوم استفاده شد (۱۸ و ۱۷). بدلیل اثرات متقابل این دو

مقادیر واقعی آنها در دو ساختار شبکه آموزش دیده ملاحظه نمی‌شود. تفاوت بین ویژگی آماری آنها بجز کمینه کمتر از ۴ درصد می‌باشد. تنها بر اساس کمینه نمی‌توان در مورد عملکرد مدل قضاوت کرد زیرا کمینه تنها یک داده از کل داده‌های موجود است. بر اساس این نتایج می‌توان ادعا کرد که شبکه‌های عصبی با موفقیت آموزش دیده‌اند زیرا در غیر اینصورت بایست تفاوت بین مقادیر واقعی شاخص هزینه‌ها و پیش‌بینی شده آنها در مجموعه تست زیاد باشد. همچنین دلیل نزدیک بودن بسیار زیاد مقادیر میانگین، مجموع و کشیدگی می‌توان نتیجه گرفت که داده‌های واقعی و پیش‌بینی شده بسیار مشابه هم هستند.

شکل (۲) ساختار شبکه کلی MLP استفاده شده برای پیش‌بینی هزینه‌های تعمیر و نگهداری



جدول (۱) ویژگی‌های آماری مقادیر واقعی و پیش‌بینی شده شاخص‌های هزینه توسط شبکه‌های منفرد در فاز تست

ویژگی‌های آماری									شاخص هزینه
sum	ske	kur	max	min	std	var	av	dv	
۴۷۲۰	۰/۳۸۲	۱/۷۸	۱۵۹	۰/۳۰۵	۵۳/۰۸	۲۸۱۸	۶۵/۵۶	dv	
۴۷۴۹	۰/۳۸۰	۱/۸۰	۱۶۲	۰/۳۰۳	۵۳/۲۹	۲۸۴۰	۶۵/۹۶	CCI_{repair}	
۸۵۲	۰/۱۹۳	۱/۶۵	۲۶	۰/۰۸۴	۸/۴۱	۷۱	۱۱/۸۳	dv	
۸۵۱	۰/۱۹۹	۱/۶۵	۲۶	۰/۱۲۶	۸/۳۹	۷۰	۱۱/۸۲	CCI_{oil}	
۷۳۳	۰/۳۳۷	۱/۷۰	۲۳	۰/۰۹	۷/۳۵	۵۴	۱۰/۱۸	dv	
۷۳۳	۰/۳۴۰	۱/۶۹	۲۳	۰/۱۵۴	۷/۳۵	۵۴	۱۰/۱۸	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 مدل Reg: مدل رگرسیونی MLP: شبکه عصبی

واریانس و توزیع آماری از آزمون F, t و کولموگروف-اسمیرنو استفاده شد. مقادیر p محاسبه شده برای هر سه شاخص هزینه به کمک شبکه‌های منفرد و شبکه کلی در جدول ۳ نشان داده شده است. این نتایج نشان می‌دهند که میانگین، واریانس و توزیع آماری مقادیر واقعی و پیش‌بینی شده هر سه شاخص هزینه توسط هر دو ساختار شبکه

شبکه را با استفاده از مجموعه داده‌های تست ارزیابی کردیم. در اینجا تنها به آوردن نتایج حاصل از ارزیابی شبکه‌های آموزش دیده اکتفا می‌کنیم زیرا معتبر بودن این نتایج دال بر موفقیت آمیز بودن فاز آموزش برای هر شبکه می‌باشد. برخی ویژگی‌های آماری داده‌های استفاده شده در فاز تست همراه با مقادیر پیش‌بینی شده آنها توسط شبکه‌های منفرد با ساختار ۱-۶-۲ برای شاخص هزینه تعمیر و ۱-۷-۲ برای شاخص هزینه روغن و سوخت در جدول ۱ آورده شده است. این اطلاعات برای شبکه کلی با ساختار ۳-۱۵-۲ در جدول ۲ نشان داده شده است. تفاوت زیادی بین ویژگی‌های آماری مقادیر پیش‌بینی شده شاخص هزینه و

برای اثبات ادعای ما در مورد قابل اطمینان بودن شبکه‌های آموزش دیده، داده‌های واقعی و پیش‌بینی شده را از نظر آماری با هم مقایسه می‌کنیم. 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 تست گردید به ترتیب برای مقایسه میانگین،

اختلاف معنی‌داری با هم ندارند. بنابراین هر دو ساختار دارای قابلیت بالایی برای پیش‌بینی هزینه‌ها هستند. بجز مقدار p مربوط به واریانس شاخص هزینه روغن، سایر

مقادیر p شبکه کلی بزرگتر یا مساوی شبکه‌های منفرد هستند.

جدول (۲) ویژگی‌های آماری مقادیر واقعی و پیش‌بینی شده شاخص‌های هزینه توسط شبکه کلی در فاز تست

شاخص هزینه	ویژگی‌های آماری							dv	pv	CCI
	sum	ske	kur	max	min	std	var			
	۴۸۵۷	۰/۲۳۸	۱/۶۲	۱۵۶	۰/۳۰۵	۵۲/۰۲	۲۷۰۶	۶۷/۴۶		
	۴۸۷۴	۰/۲۳۳	۱/۶۲	۱۵۷	۰/۲۸۶	۵۲/۱۶	۲۷۲۱	۶۷/۷۰		CCI_{repair}
	۸۳۲	۰/۲۵۴	۱/۶۹	۲۵	۰/۳۲۰	۷/۸۹	۶۲	۱۱/۵۶		
	۸۳۲	۰/۲۸۷	۱/۷۶	۲۶	۰/۳۱۰	۷/۹۳	۶۳	۱۱/۵۶		CCI_{oil}
	۷۰۹	۰/۳۷۹	۱/۸۹	۲۳	۰/۳۴۶	۶/۶۳	۴۴	۹/۸۵		
	۷۰۹	۰/۳۶۰	۱/۸۴	۲۲	۰/۳۳۶	۶/۶۲	۴۴	۹/۸۵		CCI_{fuel}

جدول (۳) مقایسه‌های آماری مقادیر واقعی و پیش‌بینی شده شاخص‌های هزینه تعمیر و نگهداری در فاز تست

شاخص هزینه	نوع تحلیل آماری			ساختار شبکه	مقایسه میانگین	مقایسه واریانس	مقایسه توزیع
				۲-۶-۱	۰/۹۶۴	۰/۹۷۳	۱/۰۰۰
				۲-۱۵-۳	۰/۹۷۸	۰/۹۸۲	۱/۰۰۰
				۲-۷-۱	۰/۹۹۶	۰/۹۸۷	۱/۰۰۰
				۲-۱۵-۳	۰/۹۹۹	۰/۹۶۳	۱/۰۰۰
				۲-۷-۱	۰/۹۹۸	۰/۹۷۳	۱/۰۰۰
				۲-۱۵-۳	۰/۹۹۹	۰/۹۹۵	۱/۰۰۰

کوچکی هستند، بنابراین می‌توان به چنین شبکه‌های اطمینان کرد. این نتایج نشان می‌دهند شاخص هزینه تجمعی تعمیر پیش‌بینی شده توسط شبکه منفرد با ساختار ۱-۶-۲ در مقایسه با شاخص‌های هزینه تجمعی پیش‌بینی شده توسط شبکه کلی با ساختار ۳-۱۵-۲ بخوبی با شاخص‌های هزینه تجمعی واقعی فیت نشده‌اند زیرا عرض از مبدا رابطه بین pv و dv بزرگتر و شیب دورتری نسبت به واحد دارد. ولی عکس این موضوع برای دو شاخص هزینه دیگر صادق است.

در اینجا عملکرد شبکه کلی با شبکه‌های منفرد از نظر معیارهای عملکردی در دو فاز آموزش، تست و کل داده‌ها

ضرایب تبیین و همچنین رابطه خطی رگرسیونی بین شاخص‌های هزینه تجمعی واقعی در مقابل شاخص‌های هزینه پیش‌بینی شده توسط هر دو ساختار شبکه در جدول ۴ نشان داده شده است. بهترین نتایج براساس این دو معیار وقتی بدست می‌آید که معادله خطی مابین شاخص هزینه واقعی و پیش‌بینی شده علاوه بر داشتن ضرایب تبیین بالا دارای عرض از مبدا نزدیک به صفر و شیب نزدیک به یک باشد. کاملاً واضح است که ضرایب تبیین بین داده‌های واقعی و پیش‌بینی شده توسط دو ساختار بسیار بالا می‌باشند ($R^2=0/999$). همچنین معادله خطی رگرسیونی مابین آنها دارای شیب‌های نزدیک به واحد و عرض از مبداهای

با هم مقایسه شده است (جدول ۵). بکارگیری شبکه با ساختار ۳-۱۵-۲ باعث کاهش MAPE در هر سه شاخص هزینه از ۱۰ تا ۶۰ درصد در هر یک از فازهای آموزش، تست و نیز کل داده‌ها شده است.

جدول (۴) رابطه خطی رگرسیونی و ضریب تبیین بین dv و pV برای مجموعه تست

R^2	رابطه خطی رگرسیونی	ساختار شبکه	
۰/۹۹۹	$pV=1/0.03 dv+0/167$	۲-۶-۱	CCI_{repair}
۰/۹۹۹	$pV=1/0.02 dv+0/065$	۲-۱۵-۳	
۰/۹۹۹	$pV=0/998 dv-0/016$	۲-۷-۱	
۰/۹۹۹	$pV=1/0.05 dv-0/059$	۲-۱۵-۳	CCI_{oil}
۰/۹۹۹	$pV=0/999 dv-0/003$	۲-۷-۱	
۰/۹۹۹	$pV=0/999 dv+0/008$	۲-۱۵-۳	CCI_{fuel}

سوخت از ۵۰ تا ۶۶ درصد افزایش داشته است. بنابراین در کل عملکرد شبکه کلی بر اساس معیارهای عملکردی بهتر از شبکه‌های منفرد است.

ساختار ۳-۱۵-۲ منجر به کاهش RMSE از ۲۴ تا ۳۶ درصد در شاخص هزینه تعمیر در فاز آموزش، تست و کل داده‌ها شده است ولی RMSE در شاخص هزینه روغن و

جدول (۵) مقایسه عملکرد شبکه عصبی در پیش‌بینی هزینه تعمیر و نگهداری

شاخص هزینه	ساختار شبکه	معیار عملکردی شبکه					
		RMSE			MAPE		
		کل	فاز تست	فاز آموزش	کل	فاز تست	فاز آموزش
CCI_{repair}	۲-۶-۱	۱/۵۴	۱/۴۰	۱/۳۳	۲/۶۴	۲/۷۰	۲/۶۱
	۲-۱۵-۳	۰/۹۹۷	۰/۹۶۸	۱/۰۱	۱/۹۵	۲/۱۹	۱/۸۳
	۲-۷-۱	۰/۰۸۲	۰/۰۸۳	۰/۰۸۱	۱/۹۳	۲/۶۶	۱/۵۷
CCI_{oil}	۲-۱۵-۳	۰/۲۳۵	۰/۲۴۱	۰/۲۳۱	۱/۴۴	۱/۵۲	۱/۴۰
	۲-۷-۱	۰/۰۷۴	۰/۰۷۵	۰/۰۷۳	۲/۰۵	۲/۶۸	۱/۷۴
CCI_{fuel}	۲-۱۵-۳	۰/۱۷۷	۰/۱۵۴	۰/۱۸۷	۱/۰۹	۱/۰۸	۱/۰۹

علاوه بر کاهش زمان کاربر، دقت برآوردها را نیز افزایش خواهد داد. باید خاطر نشان کرد این قابلیت به هیچ وجه در تکنیک‌های معمولی مانند رگرسیون وجود ندارد زیرا در رگرسیون تنها امکان وجود یک متغیر وابسته می‌باشد و لذا نمی‌توان بطور همزمان سه پارامتر را با یک متغیر مستقل پیش‌بینی کرد. در انتها امید است که کارهای در زمینه، پیدا کردن دامنه بهینه پارامترهای یادگیری شبکه عصبی MLP و

نتیجه‌گیری و پیشنهادات: نتایج حاصل نشان می‌دهند که شبکه عصبی قادر است با دقت نسبتاً بالای و با درصد خطای کمتر از ۲/۷ درصد هزینه‌های تعمیر و نگهداری تراکتور جاندیر مورد مطالعه را پیش‌بینی نماید (جدول ۵). اگرچه می‌توان برای پیش‌بینی هر شاخص از هزینه‌ها یک شبکه منفرد را طراحی نمود ولی بر اساس نتایج حاصله، بهتر آن است که از یک شبکه برای این هدف استفاده شود زیرا

نیز اندازه شبکه و کاربردی کردن بیشتر آن بمنظور پیش‌بینی هزینه‌های تعمیر و نگهداری سایر ماشینهای کشاورزی به انجام رسد.

منابع

- ۱- اسکونزاد، م.م.، ۱۳۸۳. اقتصاد مهندسی یا ارزیابی اقتصادی پروژه‌های صنعتی. انتشارات دانشگاه صنعتی امیرکبیر.
- ۲- الماسی، م.، لویمی، ن.، کیانی، ش.، ۱۳۷۸. مبانی مکانیزاسیون کشاورزی. انتشارات حضرت معصومه.
- 3- Azadeh, A., Ghaderi, S.F., Sohrabkhani.S., 2006. Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. Applied Mathematics and Computation.
- 4- Bowers,W., Hunt, D.R., 1970. Application of mathematical formula to repair cost data. Transactions of the ASAE. 13, 806-809.
- 5- 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 2006, available at <http://www.arc.agric.za>.
- 6- Girard, N., 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.
- 7- Gupta, M. M., Jin, J., Homma, N., 2003. Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory. John Wiley & Sons, Inc., Hoboken, New Jersey.
- 8- Hanke, J.E., Reitsh, 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- Kaul, M., Hill, R.L., Walthall, C., 2005. Artificial neural networks for corn and soybean yield prediction. Agriculture system 85:1-18.
- 11- Kim ,Y.H., 1989. A forecasting methodology for maintenance cost of long-life equipment. Doctoral thesis. University of Alabama.
- 12- Mayfield, W., Hills,G.S., Roberts, L., 1981.A New method for estimating farm machinery cost.Transaction of ASAE pp:53-55.
- 13- 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.
- 14- Pascual, R .,Ortega, J.H., 2006., Optimal replacement and overhaul decisions with imperfect maintenance and warranty contracts. Reliability Engineering and System Safety 91:241–248.
- 15- Rotz, C. A., 1987. A Standard Model for Repair Costs of Agricultural Machinery. Applied Engineering in Agriculture.3(1),3-9.
- 16- Torrecilla, J.S., Otero, L., Sanz, PD., 2004. A neural network approach for thermal/pressure food processing. Food Engineering 62:89-95.
- 17- Vakil-Baghmisheh, M. T., Pavešic, N., 2001. Back-propagation with declining learning rate. Proceeding of the 10th Electrotechnical and Computer Science Conference, Portorož, Slovenia. Vol B, 297-300.
- 18- Vakil-Baghmisheh, M. T., 2002. Farsi Character Recognition Using Artificial Neural Networks. PhD Thesis, Faculty of Electrical Engineering, University of Ljubljana.
- 19- Vakil-Baghmisheh, M. T., Pavešic, N., 2003. A Fast simplified fuzzy ARTMAP network. Neural Processing Letters. 17, 273-301.
- 20- Veelenturf, L.P.J., 1995. Analysis applications of artificial neural networks. Simon & Schuster international group, United States of America.
- 21- Zhang, Y. F., Fuh, J. Y. H., 1998. A neural network approach for early cost estimation of packaging products. Comput Ind Eng. 34, 433-50.
- 22- 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.

Prediction of John Deere tractor repair and maintenance costs by using two different structures of MLP artificial neural network

I.Ranjbar – M.H.Abbaspour* - fard – Y. Ajabshir – A. Rohani¹

Abstract

Replacement of tractor is one of the important decisions that must be made with respect to farm machinery manager. Accurate forecasting of repair and maintenance cost is one of the most critical factors for making this decision. The purpose of this research was to evaluate the capability of two structures of MLP neural network in predicting repair and maintenance costs. First, networks were designed in order to predict the components of repair and maintenance costs individually, and then a single network was designed for simultaneous prediction of all components costs. The study was conducted using actual data on 28 John Deere tractors from Astan Ghodse Razavi agro-industry. According to the obtained results, the two types of neural networks are accurately able to predict the repair and maintenance costs. Also, the prediction of repair and maintenance cost components of tractor with a single network produces a better result than using separate networks for prediction of each cost component. Therefore, neural network can be improved the economic decision making capabilities of machinery managers.

Keywords: MLP, neural network, repair and maintenance cost

*- Corresponding author Email: hossein_abbaspour@yahoo.co.uk

1 - Contribution from College of tabriz University & ferdowsi University of mashhad