

پیش بینی هزینه های نگهداری و تعمیر ماشین برداشت نیشکر فعال در ایران با استفاده از شبکه عصبی مصنوعی

ترحم مصری گندشمین¹، مهرداد صفرپور²، حسین نوید³
¹استادیار گروه مهندسی ماشین های کشاورزی، دانشگاه محقق اردبیلی
²فارغ التحصیل کارشناسی ارشد مهندسی مکانیزاسیون کشاورزی، دانشگاه تبریز
²استادیار گروه مهندسی ماشین های کشاورزی، دانشگاه تبریز
(mehrdadesafarpour@yahoo.com)

چکیده

مدیریت ماشین ها و تجهیزات سنگین وظیفه ی بسیار دشواری می باشد. یک مدیر اغلب باید تصمیم گیری های پیچیده ی اقتصادی در ارتباط با هزینه های ماشین های کشاورزی اتخاذ کند. این تصمیم گیری ها عبارتند از: مالکیت ماشین، نگهداری، تعمیرات، جایگزینی و منسوخ شدن ماشین ها [Mitchel et al., 1998]. هزینه های نگهداری و تعمیرات می تواند اثرات قابل ملاحظه ای در تصمیم گیری های اقتصادی و پیش بینی ها داشته باشد. هدف از انجام این تحقیق، پیش بینی هزینه های نگهداری و تعمیر ماشین های برداشت نیشکر مورد استفاده در کشت و صنعت دعبل خزاعی خوزستان بود. متغیر مستقل در مدل ریاضی، ساعات کارکرد تجمعی ماشین برداشت نیشکر و متغیر وابسته، هزینه های نگهداری و تعمیرات برحسب درصدی از قیمت خرید اولیه می باشد. در این راستا، گزارش های سرویس و تعمیرات موجود در دفتر فنی واحد تجهیزات مکانیکی کشت و صنعت، مربوط به 24 دستگاه ماشین برداشت نیشکر HCH 300 HEPCO در یک دوره ده ساله (1380 تا 1389) بررسی گردید. با استفاده از شبکه عصبی مصنوعی، مدل عصری برای ماشین های برداشت نیشکر بهینه شد و با استفاده از شاخص های آماری ضریب همبستگی (R) و متوسط قدرمطلق درصد خطا (MAPE) مدل به دست آمده مورد ارزیابی قرار گرفت و در نهایت مدل شبکه عصبی با تعداد 12 نرون در لایه مخفی به عنوان بهینه ترین مدل انتخاب گردید. مدل عصبی به دست آمده با ضریب همبستگی 0/99385 در فاز آزمایش و 0/99516 در فاز آموزش توانست تمام هزینه های ماشین های برداشت نیشکر مورد مطالعه را با دقت بسیار بالایی تخمین بزند.

کلمات کلیدی: هزینه نگهداری و تعمیرات، شبکه عصبی مصنوعی، متوسط قدر مطلق درصد خطا

مقدمه

موفقیت یک مدیر در گرو تصمیمات اقتصادی و رساندن شرکت به سود بیشتر است. کلید موفقیت در هر حرفه و فعالیت پیش بینی است و پیش بینی مبتنی است بر آنالیز سیستم حاکم بر روابط زیرمجموعه های سیستم. در یک سیستم کشاورزی مکانیزه، ماشین یکی از مهمترین اقلام سرمایه ای محسوب می شود که مهمترین هزینه مدیریتی آن هزینه های نگهداری و تعمیر می باشد [روحانی، 1388]. مکانیزاسیون کشاورزی در شاخه مدیریت ماشین ها وظیفه ارائه راهکارهایی برای بهبود نحوه ی کارکرد و استفاده صحیح از ماشین ها را بر عهده دارد. مهمترین وظیفه مدیریت ماشین ها کاهش هزینه و بکارگیری مؤثر منابع است. اطلاع دقیق از هزینه ها، نقش اصلی را در بسیاری از تصمیمات مطلوب مدیریت ماشین ها ایفا می نماید [مصری گندشمین و کریمی، 1389]. از آنجائیکه تصمیم گیری جایگزینی به عنوان مهم ترین عامل مدیریتی ماشین های مزرعه به اطلاع از هزینه های آینده نیازمند است، بنابراین داشتن ابزارهای پیش بینی کننده دقیق ضروری به نظر می رسد [Telsang, 2005]. پیش بینی هزینه های نگهداری

و تعمیرات ماشین ها در واحدهای مکانیزه ی کشاورزی از چند جنبه حائز اهمیت است؛ اول این که ماشین یکی از مهم ترین کالاهای سرمایه ای در کشاورزی محسوب می شود و سنجش دقیق سودآوری آن با لحاظ کردن اقلام هزینه امکان پذیر است. دوم این که برای تعیین نقطه ی سربه سر جهت جایگزینی ماشین کار کرده با ماشین نولازم است که عمر مفید ماشین ها با بررسی روند تغییرات هزینه های مزبور تعیین گردد و سوم این که با این پیش بینی می توان علل افزایش نامطلوب این هزینه ها را در صورت ایجاد، بررسی و مرتفع نمود [الماسی و یگانه، 1381]. برای داشتن یک مدل استاندارد، پارامترهای مدل باید مستقل از تغییر قیمت ها در اثر تورم و طراحی ماشین باشد. مطالعاتی که در این زمینه انجام شده نشان می دهد که بهترین واحد در این زمینه، روند و شیب تغییرات هزینه های نگهداری و تعمیرات بر حسب ساعات استفاده از ماشین می باشد. [Wahby and AL-Suhaibani, 1995]. در سال های اخیر پیشرفت قابل توجه ای در عرصه کامپیوتر و نرم افزار صورت گرفته است که یکی از مناسب ترین روش ها، شبکه عصبی مصنوعی می باشد. یکی از کاربردهای شبکه های عصبی همانند رگرسیون تقریب توابع چند متغیره و یافتن ارتباط میان متغیرهای مستقل و وابسته می باشد. با این تفاوت که شبکه های عصبی در مقایسه با روش های آماری پارامتریک هیچ پیش فرضی در مورد توزیع داده ها ندارند و از این نظر نسبت به تبیین متغیرهای وابسته از مزیت نسبی نسبت به روش های آماری برخوردار می باشند [مصری گندشمین و کریمی، 1389]. شبکه عصبی مصنوعی به دلیل داشتن ویژگی های خاص مانند یادگیری مستقیم از روی مثال های واقعی، بی نیازی به برآوردهای آماری داده های اولیه و از همه مهمتر برای این زمینه خاص تعیین روابط غیرخطی با مرتبه بالا بین متغیرهای موجود [وکیل باغمیشه، 2002] می تواند به عنوان یک جایگزین برای روش رگرسیون در پیش بینی هزینه ها باشد. هدف از این پژوهش انتخاب بهترین مدل پیش بینی هزینه های نگهداری و تعمیرات ماشین های برداشت نیشکر فعال در کشت و صنعت دعبل خزاعی با استفاده از شبکه عصبی مصنوعی می باشد.

مواد و روشها

اطلاعات مورد نیاز در انجام این مطالعه شامل هزینه لوازم یدکی، دستمزد تعمیراتی، هزینه روغن و هزینه سوخت مصرفی برای ماشین های برداشت نیشکر فعال در شرکت کشت و صنعت دعبل خزاعی خوزستان طی یک دوره زمانی ده ساله (1380 تا 1389) جمع آوری شده است. این کشت و صنعت دارای تعداد 24 دستگاه ماشین برداشت نیشکر می باشد که هر یک از این ماشین ها دارای یک کد اختصاصی می باشند که بر طبق آن، پرونده ای جهت ثبت هزینه های نگهداری و تعمیرات وجود دارد که به شیوه ی جالبی در دفتر واحد فنی تجهیزات مکانیکی شرکت ثبت شده و قابل دسترسی و مطالعه می باشند. این گزارش ها، در دو گروه گزارش سرویس و گزارش تعمیرات تنظیم شده که دارای اطلاعات کاملی نظیر تاریخ انجام سرویس های تعویض روغن موتور، تعویض روغن گیربکس، تعویض روغن هیدرولیک، گریس کاری ها و همچنین تاریخ انجام تعمیرات، نوع تعمیر انجام شده، روغن و قطعات مصرفی و زمان ورود و خروج ماشین برداشت نیشکر از تعمیرگاه می باشد. برای محاسبه ساعات کارکرد سالانه ماشین هر چند ساعات کارکرد ماشین های برداشت نیشکر در بعضی دوره ها ثبت شده است اما از آن جا که در این سال ها استمراری در ثبت داده ها وجود نداشته است از این رو بهترین روش جهت محاسبه ساعات کارکرد ماشین برداشت نیشکر از طریق داده های موجود برای روغن موتور مصرفی است. در واحد تجهیزات مکانیکی کشت و صنعت تعویض روغن برای ماشین های برداشت نیشکر در فواصل 80 ساعته صورت می گیرد. بنابراین هر بار تعویض روغن موتور معادل 80 ساعت کار ماشین برداشت نیشکر در نظر گرفته شد. و از آنجا که حجم مخزن روغن 42 لیتر می باشد، مقدار روغن مصرفی در یک سال را بر حجم مخزن روغن موتور تقسیم نموده و آنگاه با

ضرب کردن عدد به دست آمده در 80، تعداد ساعات کارکرد سالیانه هر ماشین با دقت قابل قبولی تخمین زده شد. برای تعیین بهترین مدل ریاضی جهت پیش بینی هزینه های نگهداری و تعمیر ماشین برداشت نیشکر، ساعات کارکرد تجمعی برای هر سال با جمع کردن ساعات کارکرد هر سال با سال قبل به دست آمد و به عنوان متغیر مستقل (ورودی سیستم) در نظر گرفته شد. هزینه های نگهداری و تعمیرات که برابر با مجموع هزینه های تعمیرات، هزینه های روغن و هزینه های سوخت می باشد، برای هر یک از ماشین های برداشت نیشکر و برای هر سال محاسبه گردید، سپس هزینه های نگهداری و تعمیر تجمعی به صورت درصدی از قیمت اولیه با جمع کردن هزینه های نگهداری و تعمیر هر سال با سال قبل و تقسیم آن به قیمت اولیه محاسبه و به عنوان متغیر وابسته (خروجی سیستم) در نظر گرفته شد. برای حذف اثر تورم، تمام هزینه ها بر حسب سال پایه یعنی 1389 تبدیل گردید.

پردازش داده ها: از تعداد کل داده های موجود شاخص هزینه های نگهداری و تعمیر ماشین های برداشت نیشکر در محدوده ساعات کارکرد تجمعی مورد مطالعه، 70 درصد داده ها (168 داده) برای فاز آموزش شبکه و 30 درصد داده ها (72 داده) نیز برای فاز آزمایش شبکه استفاده گردید. چنانچه این تقسیم بندی منجر به نتایج مطلوبی نگردد می توان این مرحله را تکرار نمود [Zhang and Fuh, 1998]. یکی از مهمترین شاخص های مدل سازی بهینه شبکه عصبی جلوگیری از بیش آموزش¹ شبکه است [منهاج، 1381]. برای این منظور در فاز آموزش و بعد از تصحیح وزن ها، تعدادی از داده های فاز آزمایش را که شبکه یاد نگرفته است به شبکه اعمال و خطای متوسط مجذور مربعات شبکه برآورد گردید. قبل از به کارگیری داده های خام اولیه، آن ها باید نرمال گردند، زیرا الگوریتم یادگیری همراه با داده های خام نمی تواند عملکرد مناسبی داشته باشد و در غیر این صورت شبکه در طول فاز آموزش همگرا نخواهد شد و نتایج مطلوب حاصل نمی گردد. به منظور بهبود الگوریتم یادگیری از نرمالیزاسیون خطی برای تبدیل داده ها استفاده شد (مصری گندشمین، 1388).

$$t_s = \frac{t_u - t_{u,min}}{t_{u,max} - t_{u,min}} (t_{s,max} - t_{s,min}) + t_{s,min} \quad (1)$$

در اینجا t_s داده های نرمال شده، t_u داده های خام اولیه، $t_{u,min}$ مقدار کمینه داده های اولیه، $t_{u,max}$ مقدار بیشینه داده های اولیه، $t_{s,min}$ حد پایینی دامنه تغییرات داده های تبدیل شده و $t_{s,max}$ حد پایینی و حد بالایی دامنه تغییرات داده های تبدیل شده می باشند.

معیار ارزیابی عملکرد شبکه: برای ارزیابی توانمندی شبکه در پیش بینی هزینه های نگهداری و تعمیر ماشین های برداشت نیشکر از معیارهای ضریب همبستگی خطی بین داده های واقعی و داده های پیش بینی شده توسط شبکه (R)، متوسط قدرمطلق درصد خطا² (MAPE)، ریشه متوسط مربعات خطا (RMSE) و ضریب تبیین معادله خطی رگرسیونی (R^2) استفاده شد.

$$R = \sqrt{\frac{(\sum_{j=1}^n (d_j - \bar{d})(p_j - \bar{p}))^2}{\sum_{j=1}^n (d_j - \bar{d})^2 \times \sum_{j=1}^n (p_j - \bar{p})^2}} \quad (2)$$

$$MAPE = \frac{1}{nm} \sum_{j=1}^n \sum_{i=1}^m \left| \frac{d_{ji} - p_{ji}}{d_{ji}} \right| \times 100 \quad (3)$$

¹Overfitting

²Mean Absolute Percentage Error

$$RMSE = \sqrt{\frac{\sum_{j=1}^n \sum_{i=1}^m (d_{ji} - p_{ji})^2}{nm}} \quad (4)$$

$$R^2 = \frac{(\sum_{j=1}^n (d_j - \bar{d})(p_j - \bar{p}))^2}{\sum_{j=1}^n (d_j - \bar{d})^2 \cdot \sum_{j=1}^n (p_j - \bar{p})^2} \quad (5)$$

که در اینجا d_{ji} : مؤلفه i ام از خروجی واقعی مربوط به الگوی j ، m ، p_{ji} : مؤلفه i ام از خروجی پیش بینی شده توسط شبکه مربوط به الگوی j ، \bar{d} و \bar{p} : به ترتیب متوسط خروجی های واقعی و پیش بینی شده توسط شبکه n و m : به ترتیب تعداد الگوها و تعداد متغیرهای خروجی می باشند [مصری گندشمین، 1388].

تعیین مدل شبکه عصبی: در این مطالعه، از رایج ترین شبکه عصبی به نام شبکه پرسپترون چندلایه³ استفاده شد. بیشترین کاربرد شبکه پرسپترون در تقریب توابع است. در این سیستم متغیرهای مستقل یا توضیحی به عنوان ورودی شبکه و متغیرهای وابسته به عنوان خروجی شبکه مدل می شود. برای یادگیری شبکه از الگوریتم یادگیری پس انتشار خطا⁴ استفاده شد [Gupta et al., 2003].

توپولوژی شبکه: توپولوژی شبکه عصبی ناظر بر تعداد لایه های نهان، تعداد نرون ها در لایه ورودی، تعداد نرون ها در لایه نهان، تعداد نرون ها در لایه خروجی، ترتیب فعال سازی نرون ها و جریان داده از نقطه ی ورود به خروجی شبکه است. تعداد نرون ها در لایه ورودی و لایه خروجی به تعداد متغیرهای ورودی و خروجی موثر در نظر بستگی دارد [صفرپور، 1390].

نتایج و بحث

تنظیم پارامترهای شبکه: 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 می باشد [روحانی، 1388] به همین دلیل یک لایه نهان برای شبکه عصبی انتخاب شد. از آنجائی که ورودی شبکه شامل عامل مدت زمان مورد مطالعه و ساعات کارکرد تجمعی و خروجی شبکه شامل هزینه های نگهداری و تعمیرات تجمعی بر حسب قیمت اولیه می باشد، لایه ورودی و لایه خروجی به ترتیب شامل 2 و 1 نرون می باشد زیرا ورودی شبکه شامل عامل زمان (در این مطالعه مدت ده سال به عنوان زمان در نظر گرفته شد) و ساعات کارکرد تجمعی و خروجی شبکه هزینه نگهداری و تعمیر تجمعی بر حسب قیمت اولیه خرید می باشد. برای تعیین تعداد بهینه ی نرون در لایه نهان از روش آزمون و خطا استفاده گردید، این فرآیند برای تعداد نرون های لایه نهان 2 تا 15 انجام پذیرفت. در نهایت مشاهده گردید مدل شبکه عصبی با تعداد 12 نرون در لایه نهان، دارای کمترین متوسط قدر مطلق خطا در فاز آزمایش و فاز آموزش می باشد. همچنین ضریب همبستگی خطی بین داده های واقعی و داده های پیش بینی شده توسط شبکه در این تعداد نرون به نسبت بالا می باشد. به همین دلیل شبکه عصبی با تعداد 12 نرون در لایه نهان به عنوان بهینه ترین مدل انتخاب گردید (جداول 1 و 2).

³Multi Layer Perceptron

⁴Basic Backpropagation (BBP)

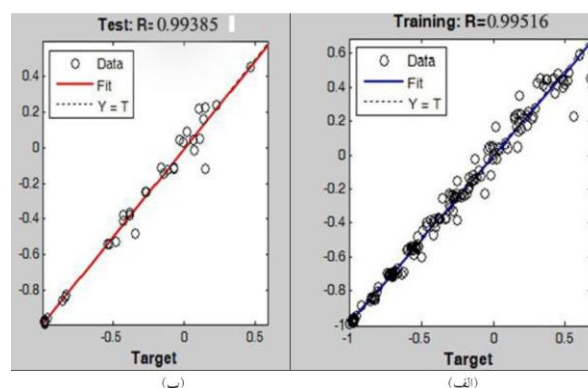
جدول 1- تغییرات عملکرد شبکه عصبی MLP برای پیش بینی هزینه های نگهداری و تعمیر ماشین برداشت نیشکر در ارتباط با تعداد نرون های لایه نهان در فاز آزمایش

معیار	تعداد نرون در لایه مخفی													
	2	3	4	5	6	7	8	9	10	11	12	13	14	15
MAPE	1598.4	5.8757	4.9564	5.9490	3.7932	4.8720	4.9071	3.8210	4.8510	4.7179	3.6747	4.6292	3.9781	4.7595
RMSE	0.3074	0.4985	0.5376	0.5834	0.7122	0.4721	0.8025	0.4751	0.7496	0.8709	0.4026	0.5801	0.4930	0.5403
R	0.99723	0.99228	0.99102	0.98996	0.98724	0.99398	0.98495	0.99298	0.98467	0.97633	0.99385	0.99311	0.99472	0.99589
R ²	0.9945	0.9846	0.9821	0.9800	9746.0	9880/0	0.9701	0.9860	0.9696	0.9532	0.9877	0.9863	0.9895	0.9918

جدول 2- تغییرات عملکرد شبکه عصبی MLP برای پیش بینی هزینه های نگهداری و تعمیر ماشین برداشت نیشکر در ارتباط با تعداد نرون های لایه نهان در فاز آموزش

معیار	تعداد نرون در لایه مخفی													
	2	3	4	5	6	7	8	9	10	11	12	13	14	15
MAPE	4.7988	5.1699	4.1266	4.2065	4.2442	3.9766	4.0162	4.5242	5.3077	4.2084	3.7837	4.2125	4.3349	3.9899
RMSE	0.5532	0.5906	0.5152	0.5480	0.4433	0.5265	0.4836	0.4785	0.5079	0.4590	0.4385	0.5820	0.4716	0.5573
R	0.99038	0.99065	0.99205	0.99097	0.99434	0.99165	0.99242	0.99309	0.9930	0.99444	0.99516	0.98982	0.99388	0.99113
R ²	0.9808	0.9814	0.9842	0.9820	0.9887	0.9834	0.9849	0.9862	0.9860	0.9889	0.9903	0.9798	0.9878	0.9823

با توجه به نتایج به دست آمده، ضریب همبستگی تخمینی مدل شبکه عصبی و داده های واقعی هزینه نگهداری و تعمیرات در فاز آزمایش برابر با 0/99385 و در فاز آموزش برابر با 0/99516 برآورد گردید (شکل 1).



شکل 1- ضریب همبستگی بین داده های واقعی و داده های تخمین زده شده توسط شبکه عصبی برای الف- مجموعه آموزش داده شده و ب- مجموعه تست شده

مشخصات شبکه عصبی بهینه و شاخص های آماری حاصل در این مطالعه در جدول 3 آورده شده است.

جدول 3 مشخصات شبکه عصبی بهینه و شاخص های آماری تست شده

RMSE _p	R _p	RMSE _c	R _c	شاخص هزینه نگهداری و تعمیر	
				تعداد اپوک	ساختار شبکه
0/4026	0/99385	0/4385	0/99516	1000	2-12-1 ماشین برداشت نیشکر

RMSE_c و R_c: به ترتیب ریشه ی متوسط مربعات خطا و ضریب همبستگی برای داده های فاز آموزش

RMSE_p و R_p: به ترتیب ریشه ی متوسط مربعات خطا و ضریب همبستگی برای داده های فاز آزمایش

منابع

- الماسی، م. و ح. یگانه، (1381)، تعیین مدل ریاضی مناسب برای پیش بینی هزینه های تعمیر و نگهداری تراکتورهای کشاورزی مورد استفاده در کشت و صنعت نیشکر کارون، مجله علوم کشاورزی ایران، 33(4) صفحات 716-707
- روحانی ع، (1388)، تحلیل هزینه های تعمیر و نگهداری و عمر اقتصادی تراکتور با استفاده از تکنیک رگرسیون، شبکه عصبی مصنوعی و الگوریتم ژنتیک، رساله دکترای تخ صصی گروه مهندسی کشاورزی، دانشگاه تبریز
- صفروپور م، ح نوید و ت مصری گندشمین، (1390)، مدلسازی هزینه ماشین های برداشت نیشکر در شرکت کشت و صنعت دعبیل خزاعی با استفاده از شبکه ی عصبی مصنوعی، پایان نامه کارشناسی ارشد گروه مهندسی ماشین های کشاورزی، دانشگاه تبریز
- مصری گندشمین ت، (1388)، بهینه سازی افت کمباین با استفاده از سیستم های هوشمند، رساله دکترای تخصصی گروه مهندسی کشاورزی، دانشگاه تبریز
- مصری گندشمین ت و ش کریمی، (1389)، پیش بینی هزینه های نت تراکتورهای فعال در شرکت های خصوصی مکانیزاسیون استان آذربایجان غربی به روش هوشمند، ششمین کنفرانس نگهداری و تعمیرات ایران
- منهاج م ب، (1381)، مبانی شبکه های عصبی، انتشارات دانشگاه صنعتی امیرکبیر، چاپ دوم
- Gupta M M, L Jin and N Homma, (2003), Static and Dynamic Neural Networks: From Fundamentals, John Wiley & Sons, Inc., Hoboken, NewJersey, 751p
- Mitchell, Z.W, (1998), A Statistical analysis of Construction Equipment Repair Costs Using Field data & The Cumulative Cost model, PhD Thesis, Faculty of TheVirginia Polytechnic Institute and State University
- Telsang, M, (2005), Production management.S.chand& Company LTD, India, 476p
- Vakil-Baghmisheh, M.T, (2002), Farsi Character Recognition Using Artificial Neural Networks, PhD Thesis, Faculty of Electrical Engineering, University of Ljubljana.
- Wahby, M. F and S.A. AL-Suhaibani, (1995), Multi Linear models for Repair and Maintenance Costs for Combines in Saudi Arabia, Bulletin of Faculty of Agriculture.University of Cairo, 46(3): 379-390
- Zhang, Y.F., and Fuh, J.Y.H, (1998), A neural network approach for early cost estimation of packagingproducts, ComputInd Eng, 34: 433-50