

# بهینه‌سازی تواتر بازرسی نگهداری ماشین آلات بوسیله شبکه عصبی مصنوعی

دکتر نظام‌الدین فقیه<sup>۱</sup> - دکتر داود کریمی<sup>۲</sup>

## چکیده مقاله

برای کاهش هزینه‌ها و زمان خوابیدگی ماشین‌آلات صنعتی، یکی از مهمترین اقدامات جهت پیشگیری از خرابی، بازرسی نگهداری است. بر مبنای محاسبات آماری با انطباق میزان شکست ( $\lambda$ )، مدت خرابی ( $\theta$ ) و زمان بازرسی ( $\eta$ ) با تابع توزیع نمایی نسبت به حداقل نمودن مجموع زمان‌های خوابیدگی بوسیله تعیین تعداد بازرسی ( $n$ ) اقدام می‌شود.

$$n = -\lambda(\theta) \ln \left( \frac{\eta}{\theta} \right)$$

$\lambda(\theta)$  میزان شکست بدون انجام هرگونه بازرسی نگهداری است. با توجه به اهمیت و حساسیت برخی صنایع، تعیین تعداد بازرسی با قابلیت اطمینان معین ضرورت می‌یابد که با استفاده از محاسبات آماری از رابطه زیر بدست می‌آید.

$$\frac{n}{\lambda(\theta)} + \ln \left( \frac{n}{\lambda(\theta)} \right) = -\ln (-\ln R(n))$$

روش‌های جایگزین برای انجام این کار با استفاده از شبکه‌های عصبی مصنوعی

عبارتند از:

۱- شناسایی الگو

۲- بهینه‌سازی

استفاده از توانایی شناسایی الگوی شبکه عصبی MLP به معنی یادگیری رفتار سیستم و تعمیم عملکرد گذشته به آینده در دوره عادی عمر ماشین و زمان بندی بازرسی نگهداری بر مبنای این عملکرد می باشد. تابع معیار این شبکه  $J_1 = (n^d - n)^2$  است که در آن  $n^d$  تعداد بازرسی واقعی یا محاسبه شده توسط روش آماری در واحد زمان و  $n$  تعداد بازرسی قابل محاسبه بوسیله شبکه عصبی است، به طوری که تابع معیار  $J_1$  حداقل شود.

در این مقاله با استفاده از توانایی بهینه سازی شبکه عصبی و برای حداقل کردن مجموع زمان خوابیدگی ماشین از تابع معیار  $J_2 = (T_{(n)}^d - T_{(n)})^2$  استفاده می شود و سرانجام برای حداقل کردن مجموع زمان خوابیدگی همراه با حداکثر کردن قابلیت اطمینان، نسبت به حداقل کردن تابع معیار  $J_3 = (T_{(n)}^d - T_{(n)})^2 + (1 + R_{(n)})$  توسط شبکه عصبی اقدام می گردد. کسب نتایج جامع و ملموس به صورت ترکیب بهینه زمان خوابیدگی (که با تعداد بازرسی رابطه معکوس دارد) و قابلیت اطمینان (که با تعداد بازرسی رابطه مستقیم دارد) برتری نسبی روش جدید را به منضم ظهور می رساند.

## واژه های کلیدی

تواتر بازرسی نگهداری<sup>۱</sup> - شبکه عصبی مصنوعی<sup>۲</sup> - زمان خوابیدگی<sup>۳</sup>.

## مقدمه

در ماشین آلات صنعتی یا سیستم های تولیدی دارای عملیات پیوسته که خرابی هر یک از عناصر آن موجب خوابیدگی کل سیستم می شود، بازرسی نگهداری بواسطه کاستن از هزینه های مربوط به زمان تشخیص و رفع عیب دستگاه یا سیستم، اهمیت زیادی دارد. این بازرسی ها همچنین می تواند قابلیت اطمینان ماشین یا سیستم را افزایش دهد (Bahrami, 1998: 250).

دستگاه هایی که دارای عناصر مختلف و پیچیده باشند و از کار افتادگی هر عنصر مستقل از سایر عناصر باشد و موجب از کار افتادگی کل دستگاه بشود، دارای زمان شکست ثابت

بوده<sup>۱</sup> و زمان‌های از کار افتادگی آنها از تابع توزیع نمایی تبعیت می‌نماید (فقیه، ۱۳۷۵: ۶۰).  
 تحت شرایط و مفروضات فوق، تعداد بازرسی برای حداقل کردن مجموع زمان خوابیدگی  
 $(T_{(n)} = \lambda_{(n)}\theta + n\eta)$  به طوری که،  $\lambda_{(n)}$  میزان شکست،  $\theta$  متوسط زمان تعمیر،  $\eta$  متوسط  
 زمان بازرسی باشد و از تابع توزیع نمایی پیروی نماید، از رابطه زیر بدست می‌آید (فقیه،  
 ۱۳۷۵: ۱۴۷):

$$n = -\lambda_{(o)} \ln \left( \frac{\eta}{\theta} \right)$$

در رابطه بالا،  $\lambda_{(o)}$  نرخ (میزان) شکست بدون وجود هرگونه بازرسی می‌باشد.  
 برای بدست آوردن قابلیت اطمینان ماشین یا سیستم مورد بازرسی از رابطه (فقیه، ۱۳۷۵:  
 ۱۵۱):

$$\frac{n}{\lambda_{(o)}} + \ln \left( \frac{n}{\lambda_{(o)}} \right) = -\ln(-\ln R_{(n)})$$

استفاده می‌کنیم. جدول شماره ۱ نتایج و محاسبات مربوط به داده‌های واقعی ماشین‌افزار  
 H-S را به روش آماری نشان می‌دهد.

جدول شماره ۱ - نتایج و محاسبات مرحله اول مربوط به روش آماری با استفاده از داده‌های

واقعی مربوط به ماشین H-S

با استفاده از میانگین داده‌های مربوط به ماشین H-S، مقادیر نرخ شکست بدون انجام بازرسی نگهداری ۲ بار در ماه ( $\lambda(0) = 2$ )، متوسط زمان بازرسی نگهداری  $\eta$  برابر  $0/0125$  ماه و متوسط مدت تعمیر  $\theta$  برابر  $0/5$  ماه بوده است، بنابراین با استفاده از رابطه:

$$n = -\lambda(0) \ln \left( \frac{\eta}{\theta} \right)$$

$$n = -2 \ln \left( \frac{0.0125}{0.05} \right) = 2.77$$

حداقل زمان خوابیدگی محاسبه می‌شود.

$$\text{MinT}(n) = \lambda(n)\theta + n\eta =$$

$$= 1(0/05) + 2/77(0/0125) = 0/085 \quad \text{ماه}$$

$$\text{MinT}(n) = 0/085 \times 160 = 13/5 \quad \text{ساعت}$$

قابلیت اطمینان ماشین H-S از رابطه زیر:

$$\frac{n}{\lambda(0)} + \ln \left( \frac{n}{\lambda(0)} \right) = -\ln(-\ln R(n))$$

قابل محاسبه است که قابلیت اطمینان دستگاه حدود  $0/53$  بدست آمد. اگر

قابلیت اطمینان مورد انتظار  $0/90$  باشد، با استفاده از رابطه فوق، ماشین باید

به طور متوسط  $3/42$  بار در ماه مورد بازرسی قرار گیرد.

روش جایگزین برای روش آماری متداول فوق، با استفاده از شبکه عصبی مصنوعی

MLP<sup>۱</sup> و با بهره‌گیری از توانایی‌های شناسایی الگو و بهینه‌سازی شبکه عصبی می‌باشد.

## شناسایی الگو

با استفاده از شبکه پرسپترون دو لایه با لایه میانی دارای تابع محرک زیگموئید و لایه خروجی دارای تابع محرک خطی مثبت و با داده‌های واقعی مربوط به ماشین H-S نتایج زیر بدست آمد:

جدول شماره ۲ - نتایج و محاسبات مرحله دوم مربوط به تعداد بازرسی و مجموع زمان خوابیدگی

با استفاده از نرم‌افزار Brain-Maker

داده‌های مربوط به ماشین H-S نشان می‌داد که به طور متوسط ۱/۵ بار در ماه بازرسی نگهداری انجام شده است، به همین جهت برای شناسایی الگو توسط MLP جهت تعمیم آن به آینده، مقدار معلم (خروجی سیستم) برابر متوسط تعداد بازرسی واقعی است و داده‌های مربوط به میزان شکست، مدت تعمیر و مدت بازرسی به عنوان ورودی‌های سیستم مورد استفاده قرار می‌گیرد. با نرخ یادگیری ۰/۵ و تفرانس ۰/۰۵ مقدار  $n$  دقیقاً ۱/۵ بدست آمد. با استفاده از مقادیر ورودی که منجر به جواب خروجی ( $n = 1/5$ ) گردیده بود زمان خوابیدگی محاسبه گردید:

$$T(n) = \lambda(n)\theta + n\eta$$

$$= 2(0/025) + 1/5(0/025) = 0/085$$

ماه

$$T(n) = 14$$

ساعت

در این آزمایش با اینکه زمان خوابیدگی بسیار نزدیک به آزمایش مرحله ۱ بدست آمد ولی زمان خوابیدگی تعمیر آن نصف روش قبلی و زمان بازرسی آن دو برابر زمان بازرسی آزمایش مرحله اول بود.

در مرحله سوم با اضافه کردن قابلیت اطمینان به شبکه و با استفاده از نرم‌افزار

Brain-Maker نتایج جدول شماره ۳ بدست آمد.

جدول شماره ۳ - محاسبات و نتایج مرحله سوم: اضافه کردن قابلیت اطمینان به شبکه

با اضافه کردن قابلیت اطمینان به عنوان ورودی شبکه MLP، نسبت به ورودی‌های مرحله دوم و تعیین دامنه تغییرات آن متناسب با تغییرات  $n$ ، به صورت زیر:

$$1/6 \leq n \leq 3/42$$

$$0/54 \leq R \leq 0/90$$

با استفاده از داده‌های تجربی قبلی و با تعداد ۴، ۵، ۶، ۷، ۸، ۹، و ۱۰ نرون در لایه میانی آزمایش صورت گرفت و بهترین نتیجه با ۵ نرون به شرح زیر بدست آمد:

تعداد بازرسی ۳/۱۸ بار در ماه، قابلیت اطمینان ۰/۸۹۵، میزان شکست

۱/۶ بار در ماه، طول مدت خرابی ۰/۰۲۹ و زمان هر بازرسی ۰/۰۲۳ ماه.

$$T(n) = \lambda (3.818)\theta + 3.18\eta \quad \text{زمان خوابیدگی:}$$

$$T(n) = (1.6) (\%29) + (3.181)(\%23) = 0.1196 \quad \text{ماه}$$

$$T(n) = 19 \quad \text{ساعت}$$

با توجه به تعداد کم داده‌های واقعی (تنها کمتر از ۵۰ داده واقعی که متعلق به حدود ۳ سال بود برای میزان شکست، زمان خرابی و زمان بازرسی از ماشین خودکار H-S وجود داشت)، با استفاده از میانگین آنها نسبت به تولید داده‌های تصادفی با استفاده از تابع توزیع نمایی منفی اقدام شد و مجموع زمان خوابیدگی به شرح جدول شماره ۴ محاسبه گردید.

جدول شماره ۴ - محاسبات و نتایج مرحله چهارم با استفاده از داده‌های تصادفی

با استفاده از میانگین داده‌های واقعی مربوط به ماشین H-S، برای میزان شکست ( $\lambda$ ) یک بار در ماه، زمان خرابی ( $\theta$ ) برابر ۰.۵٪ ماه و زمان بازرسی ( $\eta$ ) برابر ۰/۰۱۲۵ ماه و در دامنه‌های مناسب قابلیت اطمینان (R) و تعداد بازرسی ( $n$ )، با توابع توزیع نمایی منفی، اعداد تصادفی تولید شد و با استفاده از نرم‌افزار Brain-Maker و شبکه عصبی MLP با تابع محرک لایه میانی زیگموئید، نتایج زیر بدست آمد:

میزان شکست ۱/۹ در هر ماه، مدت تعمیر ۰/۰۱۷ ماه، تعداد بازرسی ۳/۳۲ بار در ماه، مدت بازرسی نگهداری ۰/۰۱۷ ماه.  
مقدار کل خوابیدگی:

$$T(n) = 1/9 \times 0/017 + 3/32 \times 0/017 = 0/098 \quad \text{ماه}$$

$$T(n) = 14/24 \quad \text{ساعت}$$

با اینکه مجموع زمان خوابیدگی به حداقل بدست آمده از روش متداول بسیار نزدیک است ولی مساوی بودن زمان تعمیر اصلاحی و بازرسی نگهداری، قابل تأمل است.

## بهینه‌سازی

همانطور که قبلاً در ارائه نتایج مراحل ۲، ۳ و ۴ توضیح داده شد، در شناسایی الگو بوسیله شبکه عصبی MLP با تابع محرک زیگموئید در لایه میانی، بهینه سازی (حداقل کردن زمان خوابیدگی) صورت نمی‌گیرد و در برخی مواقع مجموع زمان خوابیدگی بدست آمده از شبکه عصبی تفاوت غیر قابل اغماض با روش آماری دارد.

برای رفع این مشکل پس از مطالعات و بررسی‌های زیاد، این نتیجه بدست آمد که بجای تابع معیار:

$$J_1 = \frac{1}{2} (n^d - n)^2$$

که شبکه عصبی در مراحل ۲، ۳ و ۴ آن را حداقل کرد، تابع معیاری گذاشته شود تا زمان خوابیدگی (جمع زمان‌های تعمیرات اصلاحی و بازرسی‌های نگهداری) را حداقل نماید. بنابراین

این، با استفاده از تابع معیار زیر:

$$J_2 = \frac{1}{2} (T^d_{(n)} - T_{(n)})^2$$

می توان مجموع زمان های خوابیدگی را حداقل نمود.

نتایج استفاده از شبکه عصبی MLP با تابع معیار مذکور در جدول شماره ۵ مشاهده

می شود.

جدول شماره ۵- محاسبات و نتایج مرحله پنجم: حداقل کردن زمان خوابیدگی به وسیله شبکه MLP

با استفاده از برنامه ای خاص که برای شبکه MLP با MATLAB نوشته شد، و با ۹۰۰۰ تکرار که در هر ۱۰۰۰ تکرار شبکه آموزش می بیند، نتایج زیر بدست آمد:

حداقل زمان خوابیدگی شبکه عصبی بر حسب ماه  $\text{Min } T(n) = 0.0386$

حداقل زمان خوابیدگی شبکه عصبی بر حسب ساعت

$$\text{Min}T(n)=0.0386*160=6.16$$

حداقل زمان خوابیدگی روش آماری بر حسب ساعت

$$\text{Min } T(n)^d = 0.0258*160 = 4.13$$

تعداد بازرسی بدست آمده از شبکه عصبی  $N = 2$

تعداد بازرسی بدست آمده از روش آماری  $N^d = 2/123 \approx 2$

حداکثر قابلیت اطمینان بدست آمده از شبکه عصبی  $\text{Max}R = 88/6$

قابلیت اطمینان بدست آمده به روش آماری  $R = 0/70$

پس از طراحی مدل مرحله ۵ و بهینه سازی زمان های خوابیدگی، همانند بخش اول از مرحله اول (استفاده از روابط آماری برای حداقل کردن زمان خوابیدگی) اطلاع و کنترلی بر قابلیت اطمینان ماشین یا دستگاه مورد نگهداری وجود نداشت و می بایست پس از بدست



$$\frac{n}{\lambda(\circ)} + \ln \frac{n}{\lambda(\circ)} = -\ln(-\ln \lambda)$$

در مرحله بعد قابلیت اطمینان محاسبه می‌گردد.

برای حل این مشکل تابع معیار مورد استفاده در مرحله ۵ به شکل زیر توسعه داده شد.

$$J_3 = \frac{1}{2} (T^d(n) - T(n))^2 + (1 - R(n))$$

استفاده از تابع معیار فوق در شبکه MLP موجب می‌شود که به طور همزمان، زمان‌های

خوابیدگی حداقل و قابلیت اطمینان حداکثر گردد.

نتایج استفاده از شبکه عصبی MLP با تابع معیار  $J_3$  در جدول شماره ۶ درج گردیده

است:

جدول شماره ۶ - محاسبات و نتایج مرحله ششم: حداقل کردن زمان خوابیدگی به همراه حداکثر کردن قابلیت اطمینان

در آزمایشات دیگری که با برنامه نوشته شده توسط MATLAB انجام شد، نتایج

زیر بدست آمد:

الف - بوسیله شبکه با حدود ۱۰۰۰ تکرار

$$\text{Min } T(n) = ۰/۳۷۹ \times ۱۶۰ = ۶/۱$$

مجموع زمان خوابیدگی بر حسب ساعت

$$\text{MAX } R = ۰/۷۲۵$$

قابلیت اطمینان

$$N = ۱/۹ \approx ۲$$

تعداد بازرسی

ب - بوسیله شبکه عصبی با حدود ۹۰۰۰ تکرار  $۰/۵۷۷ \times ۱۶۰ - ۹/۲$

$$\text{Max } R = ۰/۹۷$$

قابلیت اطمینان

$$N = ۴$$

تعداد بازرسی

ج - نتیجه محاسبات با روش آماری

$$T(n)d = ۰/۲۶۷ \times ۱۶۰ = ۴/۳$$

مجموع زمان خوابیدگی بر حسب ساعت

$$R = ۰/۷۰$$

قابلیت اطمینان

## تحلیل نتایج

همانطور که قبلاً ذکر گردید یکی از اهداف این مقاله توسعه و کاربرد روش جدید برای بهینه سازی نگهداری ماشین آلات است. به همین منظور در ابتدا سعی بر آن بود که با استفاده از توانایی شبکه عصبی در شناسایی الگو، نسبت به یادگیری رفتار یک سیستم واقعی (ماشین افزار صنعتی) توسط شبکه MLP اقدام شود و با استفاده از پارامترهای تنظیم شده شبکه مذکور و مقدار نزدیک به مقدار معلم، از نتایج این یادگیری در زمان بندی بازرسی ها در آینده استفاده گردد. نتایج مراحل ۶ گانه نشان داد که:

۱- شبکه های عصبی می توانند (با تنظیم پارامترهای خود) رفتار یک ماشین واقعی را در زمینه دریافت ورودی های یک سیستم نگهداری  $(\lambda, \theta, \eta, R)$  و نیز ارائه تعداد بازرسی مطلوب، یاد بگیرند.

۲- در مواردی که رفتار سیستم واقعی (ماشین آلات صنعتی) با هیچیک از توابع چگالی احتمال انطباق نمی یابد، طبقه بندی و شناسایی الگو توسط شبکه عصبی MLP ابزار نیرومندی است که می تواند برای تعمیم رفتار گذشته سیستم (در صورتی که شرایط ماشین مخصوصاً دوره عمر عادی دستگاه تغییر نکند) به آینده برای زمان بندی بازرسی ها مورد استفاده قرار گیرد.

۳- در اعمال قابلیت اطمینان  $(R)$  به عنوان ورودی شبکه، اگر چه در غالب اوقات نتایج قابل قبول است ولی هیچ دلیل منطقی مبنی بر وجود رابطه علی بین قابلیت اطمینان و تعداد بازرسی ها در شبکه در دست نیست.

۴- در برخی موارد از جمله نتایج جداول ۲، ۴ و ۵ نشان می دهد که زمان تعمیر اصلاحی و یا زمان بازرسی و یا مجموع آنها به زمان بهینه روش متداول نزدیک نیست و اگر چه شبکه عصبی MLP با تابع معیار  $J_1 = \frac{1}{2} (n^d - n)^2$  در شناسایی الگوی ماشین توفیق داشته ولی در برخی از موارد در بدست آوردن حداقل زمان خوابیدگی ناکام بوده است.

۵- می توان ادعا کرد که شبکه عصبی MLP با تابع معیار  $J_1 = \frac{1}{2} (n^d - n)^2$ ، به کمک و با

ترکیب<sup>۱</sup> روش آماری - ریاضی و شبکه عصبی در برنامه‌ریزی نگهداری و تعمیرات می‌توان به نتایج بهتری، دست یافت.

۶- با توجه به نقایص مراحل ۲، ۳ و ۴، در مرحله ۵ با تابع معیار  $J_1 = \frac{1}{2}(T(n)^d - T(n))^2$  می‌توان حداقل زمان خوابیدگی ماشین را بدست آورد. این شبکه عصبی کاری شبیه مرحله ۱ (روش متداول) انجام می‌دهد لذا برای تکمیل آن و رسیدن به قابلیت اطمینان معین (با تعیین تعداد بازرسی‌ها) باید از روش‌های آماری استفاده کرد.

۷- استفاده از شبکه‌های عصبی MLP برای بهینه‌سازی در مرحله قبل بوسیله توسعه یک معماری و تابع معیار خاص در حقیقت نوعی مدلسازی بود که انجام گرفت. برای تکمیل مرحله قبل نسبت به توسعه مجدد مدل با استفاده از تابع معیار:

$$J_3 = \frac{1}{2} (T(n)^d - T(n))^2 + (1 - R(n))$$

اقدام می‌گردد که در حقیقت با این اقدام دو بهینه‌سازی همزمان انجام می‌گیرد، یعنی هم زمان خوابیدگی حداقل و هم قابلیت اطمینان حداکثر می‌شود.

۸- از آنجا که در ماشین آلات و صنایع مختلف، قابلیت‌های اطمینان متفاوتی مورد نیاز است، می‌توان وزن‌های مختلفی را که اهمیت قابلیت اطمینان یا زمان خوابیدگی را نشان می‌دهد (زیرا قابلیت اطمینان بیشتر موجب خوابیدگی بیشتر می‌شود) به هر یک از دو عنصر  $J_3$  اختصاص داد. مثلاً برای قابلیت اطمینان یک ماشین‌افزار خودکار که در صورت خوابیدن آن یک خط تولید می‌خوابد، می‌توان به عنصر دوم  $J_3$  ضریب  $(a_2)$  بیشتری داد و یا برای یک ماشین که جایگزین دارد و خوابیدن آن لطمه‌ای به خط تولید نمی‌زند به عنصر اول  $J_3$  ضریب  $(a_1)$  بیشتری داد، با این کار تابع معیار فوق انعطاف لازم را برای استفاده در حل مسائل مختلف پیدا می‌کند، بنابراین:

$$J_4 = a_1 (T(n)^d - T(n))^2 + a_2 (1 - R(n))$$

می تواند به عنوان تابع معیار شبکه عصبی MLP به مدیران صنایع مختلف برای زمان بندی نگهداری ماشین آلات کمک کند.

۹- مدل توسعه یافته فوق نسبت به روش متداول و شناسایی الگو برای تصمیم گیری های مربوط به برنامه ریزی نگهداری، روش کاراتری را ارائه می کند.

۱۰- روش اخیر اگر چه همانند روش شناسایی الگو وابسته به روش های آماری و ریاضی نیست ولی با استفاده از دستاوردها و منطق علوم آمار و ریاضی شکل گرفته است و می توان ادعا کرد که در ترکیب با روش های آماری و ریاضی به مدیران کمک می کند، بهتر تصمیم بگیرند.

## منابع و مآخذ

- ۱- بیلینتون، روی (۱۳۷۹): ارزیابی اطمینان؛ ترجمه محسن رضائیان، انتشارات دانشگاه صنعتی امیرکبیر.
- ۲- جاردین (۱۳۷۸): استراتژی تعمیرات و نگهداری؛ ترجمه محمد حسین سلیمی نمین، دانشگاه صنعتی امیرکبیر.
- ۳- جهانسوز، جهانبخش (۱۳۷۹): «سیستم بهینه نگهداری و تعمیرات»، مجله روش؛ سال نهم، شماره ۵۵.
- ۴- حاج شیرمحمدی، علی (۱۳۷۳): برنامه ریزی نگهداری و تعمیرات؛ انتشارات غزال.
- ۵- رلواین، ر. درانگ و ب. اولسون (۱۳۷۵): راهنمای جامع هوش مصنوعی؛ ترجمه ساعد صیاد و دیگران.
- ۶- سیدحسینی، سیدمحمد (۱۳۷۶): برنامه ریزی سیستماتیک نظام نگهداری و تعمیرات؛ سازمان مدیریت صنعتی.
- ۷- شیرزاد، خسرو (۱۳۷۳): نگاهداشت صنعتی؛ چاپ بهمن.

- ۹- فقیه، نظام‌الدین (۱۳۷۵)؛ مهندسی تعمیرات و نگهداری؛ انتشارات نوید شیراز.
- ۱۰- منہاج، محمدباقر و نوید سیفی پور (۱۳۷۷)؛ هوش محاسباتی؛ جلد ۲: کاربرد هوش محاسبات در کنترل، چاپ اول، مرکز نشر پروفیسور حسابی.
- ۱۱- منہاج، محمدباقر (۱۳۷۹)؛ هوش محاسباتی؛ جلد ۱: مبانی شبکه‌های عصبی، چاپ دوم، مرکز نشر پروفیسور حسابی.
- ۱۲- سیفی پور، نوید و سیدکمال‌الدین نوروش؛ «تخمین و پیش‌بینی غیرخطی به کمک شبکه‌های عصبی»، مقاله در دست چاپ.
- ۱۳- وایت (۱۳۷۷)؛ نگهداری و تعمیرات؛ ترجمه گروه مهندسی صنایع، جهاد دانشگاهی دانشگاه صنعتی شریف.

14- Alexander, Ypma, Ronald Ligteringen & Marina Skurikhina; *Machine Diagnostic by Neural Networks*.

15- Bahrami, Kyumars & W. H. Mathew (1998); "Optimum Inspection Frequency Manufacturing Systems", *International Journal of Quality & Reliability Management*; Vol. 15, No. 3, pp. 250-258.

16- Berry, M., J. A. Michel & Gordon Linoff (1997); *Data Mining Techniques*; John Wiley and Sons, Inc.

17- Bharat, A. Jain & Barin N. Nag (1997); "Performance Evaluation of Neural Network Decision Models", *Journal of Management Information Systems*; Vol. 14, pp. 201-218.

18- Borgonovo, E., M. Marsegura & E. Zio (2000); "A Montecarlo Methodological Approach to Plant Availability Modeling with Maintenance, Aging and Obs Olesence", *Reliability Engineering and System Safety*; No. 67, pp. 61-73.

19- Cornelius, T. Leondes (1998); *Control and Dynamic Systems*; Academic Press.

20- Dhillon, B. S. (1999); *Engineering Maintainability*; Gulf Publishing Company

- Engineering*; McGraw-Hill.
- 22- Geitzer, Frank L., Lars J. Kangas & Tracy Reeve; "An Artificial Neural Systems for Diagnosing Gas Turbine Fuel Fault"; *Internet*: [<http://www.emsl.pnl.gov:2080/proj/neuron/>people/kangas/html>].
- 23- Geitzer, Frank L., Lars J. Kangas & Tracy Reeve; "Turbine Engine Diagnostic Artificial Neural Networks"; *Internet*: [<http://www.emsl.pnl.gov:2080/proj/neuron/>people/kangas/html>].
- 24- Jany, J. S. R. , C. T. Jun & E. Mizutani (1997); *Neuro-Fuzzy and Soft Computing*; Prentice-Hall.
- 25- Bahrami, Kyumars, J. W. Hprice & J. Mathew (1998); "Optimum Inspection Frequency for Manufacturing Systems", *International Journal of Quality & Reliability Management*; Vol. 15, No. 3, pp. 250-258.
- 26- Levitt, Joel (1997); *The Handbook of Maintenance Management*; Industrial Press Inc.
- 27- Lotfi A. Zadeh (1992); "Fuzzy Logic Neural Networks and Soft Computing"; *one Page Course Announcement Ofcs 249*; Spring 93, University of California.
- 28- Marseguerra, M. & E. Zio (2000); "Optimization Maintenance and Repair Policies Via Combination Genetic Algorithms and Montecarlo Simulation"; *www. Elsevier. Com/Locater/Res*.
- 29- Shenoy, Dinesh & Bikash Hadury (1998); *Maintenance Resource Management*; T. J. Internaltional, Ltd.