

کاربرد شبکه های عصبی هوشمند کاهش ضایعات و از بین بردن گلوگاه ها در کارخانجات قطعه سازی خودرو

مدیریت فرآیند

فصلنامه

اطلاع رسانی، آموزشی و پژوهشی
پاییز و زمستان ۸۵

نویسندگان:

دکتر الهیار داغبندان

استادیار دانشکده فنی دانشگاه گیلان

مریم پورنصیر

دانشجوی کارشناسی ارشد مدیریت صنعتی

رمضانعلی مباشر امینی

کارشناس ارشد گروه مدیریت دانشگاه گیلان

چکیده

در این مقاله مدلی برای کاهش ضایعات و از بین بردن گلوگاه در خط تولید یک کارخانه وابسته به صنعت خودروسازی و به توازن رساندن خط تولید مربوط به آن ارائه شده است. با توجه به اینکه در حال حاضر صنعت خودرو از حساسیت ویژه ای برخوردار می باشد، رعایت استانداردهای بین المللی برای اجزا و قطعات هنگام ساخت، ضرورت انتخاب دقیق ماشین آلات و استفاده صحیح از آنها و سیستم کنترل صحیح در تمامی مراحل تولید را لازم می دارد. امروزه با توجه به این که شبکه های عصبی مصنوعی اهمیت ویژه ای در مدلسازی پیدا کرده اند، در تحقیق مورد نظر دو مدل رگرسیون و شبکه های عصبی مصنوعی مورد بررسی قرار گرفته اند و نحوه کاربرد و قدرت پیش بینی آنها با توجه به داده های واقعی و آزمایشگاهی بدست آمده توسط نگارندگان مقاله با یکدیگر مورد مقایسه قرار گرفته است همچنین در این مقاله سعی شده است با شناسایی دقیق علل موثر بر ایجاد ضایعات، مدلی جهت کاهش دور ریز قطعات ارائه گردد و از این طریق خط تولید متوازن گردد. در پایان، نتایج تحقیق که حاکی از آنست که شبکه های عصبی از نوع GMDH به طور معنی داری پیش بینی های دقیق تری را در مقایسه با مدل رگرسیون ارائه می دهد، آورده شده است.

کلید واژه:

پیش بینی، شبکه های عصبی مصنوعی، ضایعات، رگرسیون، صنعت قطعه سازی.

مقدمه

امروزه سعی و تلاش هر صنعتگر ایرانی اینست که از منابع موجود اعم از مادی و انسانی به طور بهینه ای استفاده شود، به گونه ای که این فرآیند کمترین دورریز و ضایعات را داشته باشد. به طرق مختلفی ضایعات را تعریف کرده اند که ماهیت تعاریف همواره یک شعاع موضوعی را می رساند؛ ضایعات عبارتست از: آن مقدار اولیه که در طی مراحل مختلف ساخت، به کالای قابل مصرف تبدیل نشده و برای مصرف احتمالی مجدد نیاز به عملیات

خاصی داشته، یا اینکه از دور خارج شود [۱]. معضل ضایعات در صنعت هنگامی بارزتر است که فرآیند تولید طولانی تر باشد که در اینصورت با ضایعات پیچیده تری روبرو خواهیم بود. وجود گلوگاه در هر صنعتی در کاهش میزان خروجی و افزایش کالاهای در جریان ساخت تأثیر چشمگیری دارد. با توجه به اینکه زمان بندی به عنوان عنصر تخصیص منابع به فعالیتها به گونه ای که از خاتمه این فعالیتها در یک زمان قابل قبول اطمینان حاصل شود تعریف شده است [۲]. عدم زمانبندی دقیق، مانع بزرگی در سر

راه تحویل به موقع سفارشات و عدم برنامه ریزی دقیق در این مرحله خواهد بود. حال با این پیش فرض که هرگاه بتوان کیفیت خروجی هر مرحله تولید را پیش بینی کرد، می توان مقدار ضایعات را نیز قبل از بوجود آمدن آنها تعیین نمود، استفاده از روشی که بتواند سیستم موجود را شناسایی و مدل نماید می تواند نقش بسیار مهمی در کاهش تولیدات نا مرغوب و با کیفیت زیر سطح استاندارد برای ادامه مراحل تولید داشته باشد.

در روشهای آماری و محاسباتی جهت پیش بینی از تکنیکهای مختلفی استفاده می شود که بسته به طبیعت عامل مورد نظرو همچنین میزان دقت و حساسیت لازم در پیش بینی می توان از این روشها استفاده کرد. در دهه های اخیر از روشهای هوشمند خصوصاً راه حلهای مبتنی بر شبکه های عصبی جهت پیش بینی و بهینه سازی استفاده شده است. شبکه های عصبی توان بالقوه ای برای حل مسائلی دارند که در آن تعداد زیادی از عوامل به صورت علت و معلولی به یکدیگر وابسته اند. از لحاظ تئوری جهت مدلسازی سیستم لازم است که ارتباط ریاضی بین داده های ورودی و خروجی مشخص باشند، یافتن چنین مدل‌های ریاضی با توجه به درک سیستم ها بسیار مشکل و تقریباً غیرممکن است. شبکه های عصبی در کنترل و شناسایی سیستم های پیچیده غیر خطی از قابلیت بالایی برخوردارند. در میان روش های موجود، الگوریتم دسته بندی گروهی داده های عددی که به اختصار GMDH خوانده می شود نیز سیستمی خود سامانده است که در آن مدل های پیچیده بر پایه داده های چندگانه اولیه ورودی و خروجی شکل می گیرد [۳]. در این مقاله با توجه به اهمیت نقش پیش بینی در برنامه ریزی تولید و همچنین توانایی بالای شبکه های عصبی مصنوعی در این امر، سعی شده است پس از مقایسه قدرت پیش بینی دو روش شبکه های عصبی و رگرسیون، مدلی جهت کنترل عوامل موثر بر ضایعات ارائه گردد.

۱. شبکه های عصبی مصنوعی

کار علمی روی شبکه های عصبی مصنوعی که در این مقاله به اختصار به آنها شبکه های عصبی گفته خواهد شد، از آنجا آغاز گردید که دانشمندان دانستند، مغز به گونه ای متفاوت از کامپیوترهای دیجیتال سنتی محاسبات را انجام می دهد. تلاش برای درک مغز به تحقیقات رومن کاجال بر می گردد، او نرون را

به عنوان جزء ساختاری مغز معرفی نمود. مغز انسان از میلیونها عنصر پردازشگر منفرد به نام نرون که به شدت به هم پیوسته هستند تشکیل شده است [۴]. مغز انسان بسیار پیچیده و غیر خطی بوده و مانند یک کامپیوتر موازی عمل می کند و به طور معمول عملیات شناسایی و درک را در ۱۰۰ تا ۲۰۰ میلی ثانیه انجام می دهد [۵]. تاریخچه شبکه های عصبی به سال ۱۹۴۳ و مقاله مک کالوک و پیتس بر می گردد، که در آن مدل نرون و ارتباط شبکه های عصبی با برخی از سیستم های منطقی انجام گرفت [۶]. در کلی ترین حالت، یک شبکه عصبی ماشینی است که برای مدل کردن روشی که توسط آن مغز کار خاص را انجام می دهد، طراحی شده است [۸].

در یک تقسیم بندی می توان شبکه های عصبی را به دو دسته تقسیم بندی نمود؛ شبکه های عصبی که در آن ها وزنها و ارتباطی بین نرونها طی یک فرآیند یادگیری (آموزش) تغییر می کند تا اینکه شبکه در نهایت به خوبی سیستم مورد بررسی را شبیه سازی کرده و مساله مورد بحث را حل نماید و شبکه های عصبی که ساختار آنها ثابت بوده و حالت دینامیکی دارند، به عبارتی وزن های شبکه در ابتدا از روی صورت مساله مورد بحث تعیین شده و سپس سیستم از یک شرط اولیه شروع به کار می کند تا به حالت ماندگار برسد [۹]. از قابلیت های شبکه های عصبی می توان به توانایی مدلسازی با سیستم های غیرخطی و پیچیده، قابلیت آموزش با استفاده از داده های آموزشی و تعلیم، توانایی تحمل آسیب و ترمیم و قابلیت تصمیم و کار به صورت یک تراشه اشاره داشت [۱۰ و ۱۱ و ۱۲].

در دهه گذشته تکنیکهای شبکه های عصبی به عنوان یک روش متکی بر داده به بلوغ رسیده اند و افق کاملاً جدیدی را در عرصه تشخیص خطا و پیش بینی به وجود آورده اند [۱۳]. از دیگر کاربردهای مختلف شبکه های عصبی به عنوان نمونه می توان به الگو شناسی، هویت شناسی، طبقه بندی، شناسایی صوت و تصویر و سیستمهای کنترلی اشاره نمود. در مقاله مورد نظر بر توانایی شبکه های عصبی در مدلسازی و پیش بینی تأکید شده است.

۱.۱. الگوریتم شبکه های عصبی

GMDH روش دسته بندی گروهی داده های عددی یک فن آوری آموزش آماری جهت غلبه بر ضعفهای آماری و شبکه های عصبی است. آنچه الگوریتم GMDH را به عنوان

یک روش هیوریستیک معرفی می کند ساختن مدل‌هایی برای سیستم های پیچیده از نوع رگرسیون با درجات بالا می باشد که دارای مزایایی نسبت به مدل سازی کلاسیک است. اولین بار الگوریتم GMDH توسط یک دانشمند اکرایی به نام ایواخنینکو معرفی گردید. دانشجویان زیادی در دوره های دکتری در کشورهای مختلف به این موضوع پرداخته اند و رساله ها و مقالات متعددی نیز در این مورد نگاشته شده است.

به طور کلی دو دیدگاه اصلی در معرفی و شناخت شبکه های عصبی وجود دارد [۱۴]. در دیدگاه اول؛ شبکه های عصبی را می توان علمی قلمداد نمود که دارای انواع مختلف ساختار شبکه ای بوده و از توانایی بالایی در شناسایی و مدل سازی برخوردار است پایه و اساس این دیدگاه، آموزش شبکه های عصبی است. در دیدگاه دوم؛ شبکه های عصبی به عنوان یک ابزار علمی برای پیاده سازی و تفهیم الگوریتمها قرار می گیرند و یا به عبارتی در این دیدگاه شبکه های عصبی، فلورچارتی برای الگوریتمهای پیچیده ریاضی می باشد. در مورد شبکه های عصبی GMDH با دیدگاه دوم باید به قضیه نگرینست. به طور کلی الگوریتم GMDH را نیز می توان از دو نظر متفاوت مورد بحث و بررسی قرار داد؛ در قسمت اول این الگوریتم را بر اساس مبنای ریاضی آن و در قسمت دوم بر اساس تئوری و آنالیز مدل سازی سیستم معرفی کرد.

بر مبنای ریاضی الگوریتم GMDH، بر اساس تجزیه سری توابع ولترا به چند جمله ایهای دو متغیره درجه دوم پایه ریزی شده است.

$$G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i x_j + a_4 x_i^2 + a_5 x_i x_j$$

در این تجزیه، سری ولترا به مجموعه ای از معادلات باز گشتی زنجیره ای تبدیل می گردد، به گونه ای که مجدداً با جایگذاری جبری هر یک از روابط بازگشتی در یکدیگر سری ولترا برقرار گردد. الگوریتم GMDH در قسمت دوم بر اساس تئوری و آنالیز مدل سازی سیستم هاست، این مدل سازی بر اساس دو قاعده کلی بنا می گردد [۱۵ و ۴].

۱. سیستم های پیچیده ای را که شامل m متغیر ورودی و یک

$$C_m^2 = \frac{m(m-1)}{2}$$

خروجی باشند را می توان به تعداد

سیستم جزئی^۲ ساده ای که دارای دو ورودی و یک خروجی است تجزیه نمود البته خروجی تمامی سیستم های جزئی، یکسان و همانند خروجی سیستم اصلی در نظر گرفته می شود.

۲. برای ترکیب دو سیستم جزئی در قالب یک سیستم واحد و تشکیل سیستم جزئی جدید دیگری که متغیرهای هر دو سیستم قبلی را در بر می گیرد، کافیست که خروجی و یا مقادیر تخمین زده هر دو مدل بدست آمده را به ازای n نمونه ورودی مجدداً مدل کنیم. الگوریتم GMDH با به کار بستن این دو قاعده در دستور کار خود عمل مدل سازی را انجام می دهد هدفی را که همواره در پروسه ترکیب مدل های بوجود آمده مدنظر است، دست یافتن به مدل هایی می باشد که تقریباً تمامی متغیرهای سیستم در آن نمایان و نقش داشته باشند، هدف دیگر رسیدن به مدلی می باشد که میزان خطای خروجی آن نسبت به سایر مدل های محاسبه شده در مراحل قبل کمتر باشد [۱۲].

۱.۲. شبکه های عصبی GMDH

شبکه های عصبی GMDH جلوه ای از الگوریتم GMDH می باشد که به فرم و ساختار شبکه ای بیان شده است. شبکه عصبی GMDH، شبکه ای خود سامانده و یک سویه می باشد که از چند لایه و هر لایه نیز از چندین نرون تشکیل یافته است، تمامی نرونها از یک ساختار مشابهی برخوردارند. وزن ها (w) بر اساس روشهای تجزیه مقادیر منفرد (SVD)^۳ و حل معادلات متعامد (SNE)^۴ به عنوان مقادیر مشخص و ثابت در داخل هر نرون جایگذاری می شود. ویژگی بارزی که در این نوع از شبکه ها مشاهده می گردد، حاکی از آنست که نرونها مرحله قبلی و یا لایه قبلی (m)، عامل و یا مولد تولید نرونها جدید به تعداد C_m^2 می باشند از میان نرونها تولید شده لزوماً بایستی تعدادی از آنها حذف گردند تا بدین وسیله از واگرایی شبکه جلوگیری به عمل آید، اصطلاحاً به اینگونه نرونها، نرون مرده گفته می شود [۱۶].

یکی از مسائل مهمی که در شبکه های عصبی مصنوعی چند لایه مطرح می گردد طراحی ساختار شبکه است در این طراحی بایستی تعداد لایه ها و نیز ساختار درونی از قبیل تعداد وزنها و مقادیر اولیه آنها و همچنین تابع تحریک هر نرون به صورت مناسب انتخاب گردند تا یک نگاشت مناسب و ایده آل میان داده های ورودی و خروجی برقرار شود. یکی از اهداف از شبکه های عصبی GMDH جلوگیری از رشد واگرایی شبکه و نیز

مرتبط کردن شکل و ساختار شبکه به یک یا چند پارامتر عددی می باشد. به گونه ای که با تغییر این پارامتر ساختار شبکه نیز تغییر کند.

جهت برقراری ارتباط بهینه میان تعداد لایه ها و تعداد نرون ها به سه روش اشاره می گردد [۱۷]:

روش اول : طرح ساختار شکل گرفته بر اساس افزایش فشارانتخاب^۵ (I. S. P)

روش دوم : طرح ساختار از پیش تعیین شده (P.S.D) ۶

روش سوم : طرح ساختار هدایت شده بر اساس خطا (E.D.S) ۷
باتوجه به برتریهای مدل I.S.P نسبت به دو مدل دیگر با توجه به داده های این تحقیق به توضیح بیشتر این مدل می پردازیم.

۲.۲ تدارکات الکترونیکی

از نظر فناوری الکترونیکی عقب مانده و هم اکنون باید تلاش های خود را سرعت ببخشد تا فناوری را کسب کند و به کمک آن بتواند ارسال کالاها را به صورت الکترونیکی یکپارچه کند. به مشتریان کمک کند از میزان موجودی کالادر انبارها با خبر شود. جنبه های با ارزش حمل و نقل را به کار گیرد یا با یکپارچه کردن کالاها در هزینه ها صرفه جویی کند.

تدارکات الکترونیکی دارای وضعیت خوبی نیست بگونه ای که:

۱. جغرافیای تدارکات الکترونیک هنوز بسیار پراکنده است.
۲. نقش ارائه دهندگان طرف ثالث از حالت تاکتیکی در حال ورود به حالت راهبردی (استراتژیک) است.
۳. مبادلات تدارکاتی در حال ورود از حاشیه مدیریت به متن آن است.

۲.۲ طرح ساختار شکل گرفته براساس افزایش فشار انتخاب (I.S.P)

در این روش سعی شده است که تعداد لایه ها و نیز تعداد نرونها به صورت کاملاً خودکار و بهینه تعیین گردد. لذا الگوریتمی را که برای این منظور در نظر گرفتیم بدین گونه عمل می کند که برای هر لایه، خطای مبنایی را مشخص می کنیم سپس خطای مبنا را با خطای هر نرون مقایسه کرده در صورتی که از آن کمتر باشد، نرون مربوطه به عنوان نرون برنده انتخاب شده و در ساختار اصلی شبکه باقی می

ماند در غیر اینصورت نرون مرده از ساختار حذف می گردد. در لایه های بعدی نیز تمامی مراحل فوق را تکرار می کنیم با این تفاوت که با پیشرفت لایه ها مقدار عددی تعداد نرونهای مورد بررسی کاهش می یابد. در واقع با عبور از هر لایه تعداد نرونیهای را که قرار است از آنها میانگین گرفته شود تحت فشار متغیر انتخاب، محدود می گردد. متعاقباً فشار انتخاب نیز با پیشرفت لایه ها به میزان α افزایش می یابد.

مراحل اصلی این روش را می توان بطور خلاصه به صورت زیر بیان نمود [۳ و ۱۷]:

۱- فرض کنید که $M_1 = m$ تعداد نرون های لایه ورودی با تعداد مؤلفه های بردار ورودی،

باشد. به عبارت $Vec.ofVar = \{x_1, x_2, \dots, x_m\}$

دیگر m تعداد متغیرهای ورودی سیستم می باشد. لذا با قرار دادن $k=1$ در اولین لایه میانی، مقادیر ورودی الگوریتم (α, SP_1) را مشخص می کنیم.

$$\frac{M_k(M_k - 1)}{2}$$

۲- تعداد نرون در لایه k ام را با استفاده از روش های کمترین مربعات خطا از قبیل SVD و SNE ایجاد می کنیم.

۳- با قرار دادن $SP_k = SP_{k-1} - \alpha$ در رابطه زیر

$$V = INT \left[SP_k \times \frac{M_k(M_k - 1)}{2} \right]$$

تعداد نرونهای مورد بررسی (V) را مشخص کرده و سپس با قرار دادن V در رابطه زیر

$$r^{-2} = \left[\sum_{j=1}^v \frac{r_j^2}{V} \right]$$

خطای مبنایی $\left(r^{-2} \right)$ را برای لایه k ام محاسبه می کنیم، که

به موجب آن می توانیم β_k نرون از میان


نرونیهای که $\frac{M_k(M_k - 1)}{2}$ $\left(r_j^2 \right)$ آنها کمتر از

شد) مرحله تراشکاری بر روی فورج انجام پذیرفته و در انتها صافی سطح قطعه خروجی که در این مرحله به آن بالپین گفته می شود، همراه با سایر عوامل بالا ثبت گردید. نمونه گیری بارها توسط نگارندگان مقاله با تغییر عوامل موثر، اندازه گیری و ثبت گردید و نتایج حاصله توسط مدل‌های شبکه عصبی و رگرسیون مدله شده تا بهترین تنظیمات دستگاه با داشتن بهترین خروجی یا (خروجی مورد نظر) حاصل گردد.

۴. مدل سازی و مقایسه نتایج به روشهای GMDH

برای نمایش توانایی شبکه های عصبی از نوع GMDH در زمینه پیش بینی پارامتر خروجی در حالتی که پارامترهای ورودی تغییر می کنند، نمونه‌های ورودی و خروجی جدول (۱) را به دو قسمت تقسیم می کنیم. مجموعه اول، مجموعه ای است که فقط مدل سازی بر روی آن انجام می شود و مجموعه دوم صرفاً برای پیش بینی به کار می رود و در مدل سازی استفاده نشده است. در اینجا مجموعه اول شامل ۵۰ نمونه اول و مجموعه دوم شامل ۱۹ نمونه آخر می باشد.

روابط بین پارامترهای ورودی در تعیین خروجی مورد نظر به کمک نرم افزار MATLAB ۷.۰ و جعبه ابزار شبکه عصبی به دست آمده است. در نهایت ساختار شبکه برتر به صورت زیر نمایش داده می شود.



ساختار شبکه در روش ISP ۲ لایه، $\text{Threshold} = 0.085$

در این ساختار از ورودی اول که سختی فورج بود با توجه به بازه انتخابی در نمونه ها، توسط شبکه صرف نظر گردید و تنها با ۳ ورودی مدل سازی انجام پذیرفت. با توجه به این مدل هرگاه سختی فورج در بازه مورد نظر قرار گرفته باشد می توان با سایر

مقدار r^{-2} (معیار محاسبه شده برای هر لایه) می باشد را انتخاب نمود.

۴- در صورتیکه $M \neq 1$ باشد با قرار دادن $K=K+1$ و $M_k = \beta_{k-1}$ به مرحله ۲ بازگشته و کل مراحل را مجدداً دنبال می کنیم، در غیر این صورت ($M_k = 1$) به روند الگوریتم پایان می دهیم.

۳. شرح مسأله

تحقیق مورد نظر در شرکت جلوبندی خودرو ایران لاهیجان و بر روی دستگاه کپی تراش کنترل عددی از نوع NC انجام پذیرفته است. دستگاه طی دو مرحله خشن کاری و نازک کاری که توأمان توسط دستگاه مورد نظر و بر روی قطعه فورج انجام می پذیرد خروجی به نام بالپین خواهد داشت. مرغوبیت بالپین به صافی سطح آن مرتبط است و باید استانداردهای تعریف شده ای را دارا باشد. قطعات خروجی از کپی تراش وارد دستگاهی به نام پولیش رزوه می گردد تا مراحل صیقلی نمودن و از بین بردن ناصافی مرحله قبل در این مرحله کامل گردد. با توجه به اینکه صافی مطلوب برای ورود به مرحله پولیش رزوه مقداری کمتر از ۴ رافنس (R) است مرحله دیگری در میان این دو مرحله تعبیه گردید تا ناصافی را به حد مورد پذیرش برای دستگاه پولیش رزوه برساند. این مرحله کاری به صورت گلوگاه درآمده و علاوه بر اینکه سبب به موقع نرساندن بالپین به قسمت مونتاژ می گردد، هزینه قابل توجه ای را نیز به شرکت مورد نظر تحمیل می نماید.

با بررسی مجدد خط تولید و شناسایی عوامل تأثیر گذار بر این نارسایی، موارد زیر شناسایی شد:

سختی (H) ۹: میزان مقاومت فورج در برابر تغییر شکل، شعاع اینسرت (I) ۱۰: شعاع نوک ابزاری که توسط آن از سطح فورج براده برداری انجام می پذیرد،

سرعت اسپندل (S) ۱۱: سرعتی که قطعه کار حرکت می کند و سرعت فید (F) ۱۲: سرعت ابزار برش که توسط آن از سطح قطعه کار براده برداری انجام می پذیرد.

در ابتدا با تعیین سختی فورج قبل از ورود به کپی تراش و اندازه گیری شعاع نوک اینسرت و قرار دادن سرعت اسپندل و فید بر روی مقادیر مورد نظر (که در مراحل مختلف تغییر داده خواهد

عوامل از جمله سرعت فید و سرعت اسپندل که توسط اپراتور قابل تنظیم است به کنترل سیستم پرداخت و خروجی مورد نظر را بدست آورد، که می تواند دقت پیش بینی در مدلسازی رانیز افزایش دهد.

در این تحقیق مدلسازی رگرسیون نیز به موازات توسط نرم افزار ۶.۰ MINITAB انجام پذیرفت که معادله حاصل شده از آن عبارتست از:

$$R = -1.80 + 0.0135H + 8.5I - 0.00308S + 1.33F$$

در انتها نتایج حاصل از پیش بینی شبکه عصبی GMDH و رگرسیون و مقادیر درصد خطا در این دو مدل ارائه شده است.

جدول ۱: مقایسه خطاهای مدل های شبکه عصبی و رگرسیون

داده واقعی (y_i)	مقدار پیش بینی در مدل شبکه عصبی (\hat{y}_i) ISP	مقدار پیش بینی در مدل رگرسیون (\hat{y}_i)	مقدار درصد خطا در مدل رگرسیون	مقدار درصد خطا در مدل شبکه عصبی ISP
۵,۳	۴,۲۳۴۹	۴,۶۳۲۰	۱۲,۶۰	۲۰,۰۹۵۴
۱۰,۰۸	۸,۹۱۴۶	۶,۷۱۸۰	۳۳,۳۵	۱۱,۵۶۱۷
۹,۷۶	۵,۶۹۶۲	۵,۸۴۶۵	۶۶,۹۳	۴۱,۶۳۷۱
۳,۶۹	۴,۳۱۹۱	۴,۹۰۷۵	-۳۲,۹۹	-۱۷,۰۴۸۶
۳,۲۷	۳,۹۷۲۵	۴,۳۵۸۵	-۳۳,۲۸	-۲۱,۴۸۴۳
۳,۶	۳,۸۵۲۹	۳,۸۶	-۷,۲۲	-۷,۰۲۴۳
۷,۳۶	۸,۵۲۵۸	۶,۵۵۳۵	۱۰,۹۵	-۱۵,۸۳۹۲
۶,۴۵	۸,۵۲۵۸	۶,۵۱۳۰	-۰,۹۷	-۳۲,۱۸۲۴
۳,۷۲	۴,۱۱۷۹	۴,۶۷۸۵	-۲۵,۷۶	-۱۰,۶۹۵۹
۴,۷۹	۴,۶۱۹	۳,۸۳۲۵	۱۹,۹۸	۳,۵۶۹۹
۴,۸۹	۵,۷۸۷۱	۵,۸۹۱۵	-۲۰,۴۸	-۱۸,۳۴۵۶

ادامه جدول ۱: مقایسه خطاهای مدل های شبکه عصبی و رگرسیون

مقدار درصد خطا در مدل شبکه عصبی ISP	مقدار درصد خطا در مدل رگرسیون	مقدار پیش بینی در مدل رگرسیون (\hat{y}_t)	مقدار پیش بینی در مدل شبکه عصبی ISP (\hat{y}_t)	داده واقعی (y_t)
۴,۴۴۲	-۷,۱۵	۴,۵۶۵	۴,۰۷۰۷	۴,۲۶
۱۵,۰۵۷۶	۰,۷۹	۴,۹۷۸۵	۴,۲۶۴۱	۵,۰۲
۸,۹۰۴	-۳,۷۱	۴,۶۹۸۵	۴,۱۲۶۶	۴,۵۲
۱۳,۸۶۶۱	۰,۳۲	۵,۳۵۲۵	۴,۶۲۵۴	۵,۳۷
-۴,۶۲۴	-۱۳,۹۰	۴,۳۲۸۵	۳,۹۷۵۷	۳,۸
-۵,۵۷۶۴	-۵,۴۴	۵,۸۵۲۰	۵,۸۵۹۵	۵,۵۵
۵,۲۵۲۴	-۵,۸۸	۵,۱۹۵۵	۴,۶۰۴۷	۴,۸۶
۲,۶۸۹۵	۷,۳۵	۵,۴۵۶۵	۵,۷۳۱۶	۵,۸۹
۴,۴۴۲	-۷,۱۵	۴,۵۶۵	۴,۰۷۰۷	۴,۲۶
۱۵,۰۵۷۶	۰,۷۹	۴,۹۷۸۵	۴,۲۶۴۱	۵,۰۲

با بکارگیری MAPE مقادیر خطا را برای دو مدل رگرسیون و شبکه های عصبی محاسبه گردید.

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{et}{y_t} \right|}{n} = \frac{\sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|}{n}$$

مدل پیش بینی	شبکه های عصبی	رگرسیون
MAPE	۱۳,۶٪	۱۶,۲۶٪

با توجه به نتایج جداول بالا کلیه معیارها نشان دهنده برتری شبکه عصبی GMDH نسبت به مدل رگرسیون است

نتیجه گیری

نتایج بدست آمده از تحقیق مورد نظر حاکی از قدرت نسبتاً بالای شبکه های عصبی از نوع GMDH در مدل سازی در مقابل رگرسیون جهت پیش بینی در خط تولید کارخانه مورد مطالعه بوده است. در مدل سازی توسط روش شبکه های عصبی GMDH در مقایسه با روشهای دیگر مدل سازی بدون داشتن اطلاعات خاصی از سیستم مورد شناسایی و همچنین بدون تعیین مقادیر اولیه وزنها امکان پذیر می باشد در الگوریتم سایر شبکه ها تعیین مقادیر اولیه پارامترهای شبکه عصبی حائز اهمیت می

باشد در سایر مدلها انتخاب اولیه نادرست پارامترهای شبکه منجر به گیر افتادن در آغاز راه شبکه در نقاط کمینه محلی در فضای برداری پارامترهای شبکه می گردد که این خود موجب می گردد که شبکه خیلی زودتر از معمول به موضعی بیفتد که منحنی یادگیری آن برای تعداد زیادی از دفعات تکرار تغییر نکند، حال آنکه این مشکل هرگز در شبکه های عصبی GMDH اتفاق نمی افتد. از جمله ضعفهای عمده در شبکه های عصبی، پدیده *over fitting* است که این پدیده هنگامی بروز می کند که تعداد لایه ها و نرونها افزایش یافته و سیستم ظاهراً دقت قابل توجهی را از خود نشان می دهد که این انطباق در نتایج مدل سازی با مقادیر واقعی در GMDH منجر به افزایش خطا در پیش بینی می گردد. همچنین نباید فراموش نمود که؛ هرچه دامنه پارامترهای ورودی وسیع تر و آزمایشات انجام گرفته به صورتی باشد که نمونه ها در بازه مورد نظر قرار گرفته باشند، شبکه اطلاعات کاملتری در مورد فرایند مورد نظر داشته و می تواند پیش بینی بهتر و دقیق تری داشته باشد.

منابع:

- [۱۲] منہاج، محمد باقر؛ "هوش محاسباتی مبانی شبکه های عصبی"، مرکز نشر دانشگاه صنعتی امیر کبیر، جلد اول، ۱۳۷۹
- [۱۳] Zhou He, J., Hva Zhou, Z., Ri Yin, X., and Fuchen, S., "Using Neural Networks for fault Diagnosis", proceedings of the IEEE-INNS – ENNS International Joint conference on Networks, Como, Italy, ۲۰۰۰. Vol. ۵, pp. ۲۱۷-۲۲۰, ۲۰۰۰.
- [۱۴] Darvizeh, A., Nariman – Zaeleh, N., and Gharababaei, H., "GMDH- Type Neural Network modeling of Explosive Cutting Process of plate Using Singular value Decomposition", ESM'۲۰۰۱, Prague, June ۲۰۰۱.
- [۱۵] Dolenko, S.A., Orlov, Y.V., and persiantev, I.G., "Practical Implementation and Use of Group Method of Data Handling (GMDH): prospects and problems", proc. ACEDC' ۹۶, university of Plymouth, Uk, ۱۹۹۶.
- [۱۶] Lemke, F. "Knowledge Extraction from Data Using Self-organizing modeling Technologies"; ESE. Am. ۹۷. Conferences ۱۹۹۷.
- [۱۷] Nariman – Zadeh, N., Darvizeh, A., Felezi, M.E., and Gharababaei, H., "Polynomial modelling explosive compaction process of metallic powders using GMDH-type neural networks and singular value decomposition", Iop Journal, modelling Simul, mater. Sci. Eng, vol ۱۰, no ۶, pp. ۷۲۷-۷۴۴, ۲۰۰۲.

پی نوشت

- ^۱ Group Method of Data Handling
^۲ Partial System
^۳ Singular Value Decomposition
^۴ Solving Normal Equation
^۵ Increasing Selection Pressure
^۶ Error Driven Structural
^۸ Roughness
^۹ Hardness
^{۱۰} Insert
^{۱۱} Spindle speed
^{۱۲} Feed speed

- [۱] صابری حقایق، رحمت علی؛ "مفاهیم کلی ضایعات"، مجله روش، شماره ۸۶، سال سیزدهم.
- [۲] Dempster, M., Lentstra, J., and Kan, R., "Deterministic and stochastic Scheduling: introduction", proceedings of the NATO Advanced Study and Research institute on Theoretical Approaches to Scheduling Problems, D. Reidel Publishing Company: ۳-۱۴, ۱۹۸۱.
- [۳] Nariman- Zadeh, N., Darvizeh, A., Ahmad-Zadeh, R., "Evolutionary Design of GMDH-Type Neural Networks Using Singular value Decomposition for the Modeling of Process Parameters of Explosive Cutting Process", First International Conference on Inductive Modeling, ICIM' ۲۰۰۲, Lviv Ukraine, May ۲۰-۲۵, ۲۰۰۲.
- [۴] Vasechkina, EF. and Yarin, V.D., "Evolving Polynomial neural network by means of genetic algorithm: some application examples", complexity International, Vol. ۹, ۲۰۰۱.
- [۵] Haykin, S., Neural Networks, Macmillan college publishing company, ۱۹۹۴.
- [۶] Lippman, R. P., "An Introduction to computing with Neural Nets", IEEE, ASSP Magazine, Vol. ۴ April ۱۹۸۷, pp. ۴-۲۲.
- [۷] Hush, D.R. and Horn, B., G., "Progress in Supervised Neural Networks, What's New since Lippmann?" IEEE, Transaction Signal Processing Magazine, pp. ۸-۳۳, Jun. ۱۹۹۳.
- [۸] Haykin, s., "Feel Forward Neural Networks: an Introduction", www .media .wiley .com /product data/excerpt/ ۱۹/۰۴۷/۳۴۹/۰۴۷/۳۴۹۱۱۹.pdf.
- [۹] Hopfield, J., "Neural Networks and physical system with Emergent Collective Computational Abilities", proceeding of the National Academy of science USA, ۷۹, pp. ۲۵۵۴-۲۵۵۸, ۱۹۸۲.
- [۱۰] Hakin.s., Neural Networks; A comprehensive Foundation, prentice- Hall, ۱۹۹۹.
- [۱۱] Yang, Y.R., sun, C., and Mizutani, E., Nero Fuzzy and Soft computing, prentice- Hall, ۱۹۹۷.