

به کارگیری ابزارهای هوش محاسباتی به منظور پیش‌بینی مصرف فولاد خام کشور

سیدا توبت (کارشناس ارشد)

مهدي خاشعی * (استاد دار)

مهدي بيجاري (استاد)

دانشکده هندسي صنایع، دانشگاه صنعتي اصفهان

تصمیم‌گیری یکی از ارکان اساسی مدیریت و عامل مهمی در شکوفایی سازمان هاست. این اهمیت تا جایی است که مدیران به دنبال به کارگیری ابزارهای کارآمد به منظور بهبود کیفیت تصمیمات خود هستند. صنعت فولاد نیز، یکی از صنایع زیربنایی کشور، از این قاعده مستثنی نیست و شایسته‌ی توجهی عمیق است. در این مقاله سعی شده است تا با به کارگیری روش‌های علمی، مدلی به منظور مدیریت مصرف فولاد خام کشور ارائه شود. پژوهشی موضوع نشان می‌دهد که به دلیل سطح بالای پیچیدگی و ابهام موجود در ابزارهای مالی حصول نتایج دقیق در پیش‌بینی مصرف بهویه در افق‌های بلندمدت دشوار است. از این رو در این مقاله به منظور مدل سازی هم‌زمان پیچیدگی‌ها و عدم قطعیت‌های موجود در داده‌ها، ترکیبی از مدل‌های هوشمند و محاسبات نرم به کار گرفته شده است. نتایج حاصل از این بررسی‌ها بیان‌گر کارایی مدل‌های هوشمند نرم نسبت به مدل‌های کلاسیک نرم و نیز برتری مدل‌های هوشمند سخت در مقابل مدل‌های کلاسیک سخت هستند.

s.torbat@in.iut.ac.ir
khashei@cc.iut.ac.ir
bijari@cc.iut.ac.ir

وازگان کلیدی: پیش‌بینی سری‌های زمانی، مصرف فولاد خام، انتخاب متغیر، ابزارهای هوش محاسباتی، محاسبات نرم.

۱. مقدمه

اصنایع اتخاذی و بهبود عملکرد سازمان، آگاهی از شرایط حال و آینده این صنعت و شناسایی عوامل مؤثر بر شرایط مذکور و ارائه پیش‌بینی‌های دقیق از این عوامل است. همچنین ظهور تغییرات فناوری و جهانی شدن تجارت و بازارهای مالی باعث شده است توانایی در پیش‌بینی دقیق تر و سریع‌تر الگوهای موجود، به خصوص پیش‌بینی مدل‌هایی با روابط غیرخطی کاملاً پیچیده در سطوح بالای اختلال در حفظ توان رقابتی شرکت‌ها اهمیت بیشتری پیدا کند. از این‌رو در سایه‌ی این گونه از تغییرات در محیط‌های تجاری و مالی، آگاهی از شرایط بازار، قیمت و میزان مصرف و تولید محصولات، حتی در آینده‌ی نزدیک نیز کمک شایانی به یک واحد تولیدی و بنگاه اقتصادی برای برنامه‌ریزی تولید و اتخاذ تصمیم‌های لازم برای توسعه یا تکمیل طرفیت‌های تولیدی خواهد کرد.

یکی از چالش‌هایی که همواره فرازی مدیران و کارشناسان صنعت فولاد فرار دارد، ارائه رهیافت‌های منطقی در راستای ایجاد هماهنگی بین عرضه و تقاضا به عنوان شاخص‌هایی مهم و مؤثر در جهت سودآوری و ارائه پیش‌بینی‌های دقیق از آنها به منظور نیل به اهداف سازمانی است. همچنین با توجه به این نکته‌ی اساسی که پیش‌بینی یک عنصر کلیدی در تصمیم‌گیری مدیران محسوب می‌شود، مدیران ارشد در سال‌های اخیر بیش از پیش نیاز به مدل‌های پیش‌بینی با قابلیت انعطاف‌پذیری بیشتر را احساس می‌نمایند.^[۱]

نظر به این‌که مدیریت مصرف و تلاش برای استفاده‌ی بهینه در تمام کشورهای

امروزه مدیریت یکی از ارکان اساسی در اداره‌ی امور سازمان‌ها نیازمند ترکیب عوامل موجود، ایجاد هماهنگی بین آنها و در نتیجه تصمیم‌گیری‌های صحیح به منظور نیل به اهداف سازمانی است. موقفیت مدیریت برای مقابله با شرایط نامطمئن محیطی در سازمان‌های مدرن امروزی و در نتیجه رهبری صحیح به منظور رسیدن به اهداف مورد نظر بستگی به تصمیمات اتخاذ شده و درجه صحّت، میزان دقت و منطقی بودن آنها دارد. بدون شک تصمیم‌گیری در مفهوم نوین یکی از عمیق‌ترین واژه‌ها و مهم‌ترین ابزارهای موجود در علم مدیریت است. تصمیم‌گیری چارچوبی برای عملکرد کارکنان سازمان فراهم می‌سازد و از این‌رو نقشی پر اهمیت در مدیریت صنایع و سازمان‌ها ایفا می‌کند.

صنعت فولاد نیز به عنوان یکی از صنایع مهم و زیربنایی کشور از این قاعده مستثنی نیست و به دلیل دارا بودن ارتباطات گستره با سایر بخش‌های اقتصاد و تأثیرگذاری بر آنها نیازمند اتخاذ تصمیمات هوشمندانه است و از این‌حیث بسیار حائز اهمیت می‌باشد. این اهمیت تا جایی است که مدیران و کارشناسان صنعت فولاد همواره در صدد یافتن راه حل‌هایی منطقی و مستدل به منظور بهبود کیفیت تصمیمات اتخاذی خود هستند. از جمله‌ی این راه حل‌ها به منظور ارتقای کیفیت

* نویسنده مسئول

تاریخ: دریافت ۱۱/۹/۱۳۹۵، اصلاحیه ۱۱/۷/۱۳۹۶، پذیرش ۲۴/۷/۱۳۹۶

DOI:10.24200/J65.2019.7102.1705

دسته‌ی سوم شامل پژوهش‌های مبتنی بر روش‌های هوشمند است که در ادامه به توضیح هریک به تفکیک پرداخته می‌شود.

۱.۲. پژوهش‌های مبتنی بر روش‌های کلاسیک اقتصادسنجی

تاکنون چندین رویکرد به منظور پیش‌بینی مصرف و تقاضای مواد معنده‌ی پیشنهاد شده است. اولین و مهم‌ترین رویکرد سنتی استفاده از معادلات و روش‌های اقتصادسنجی است که مصرف مواد معنده‌ی به خصوص فولاد را تابعی از تولید صنعتی و دیگر پارامترهای کلان اقتصادی همچون تولید ناخالص داخلی (GDP) در نظر می‌گیرد. در جدول ۱ به اختصار به پژوهش‌های انجام شده مرتبط با پیش‌بینی مصرف فولاد با استفاده از روش‌های کلاسیک اقتصادسنجی اشاره شده است.

۲.۱. پژوهش‌های مبتنی بر نظریه‌ی شدت استفاده

دوین رویکرد برای پیش‌بینی مصرف فلزات، روش شدت استفاده است. شدت استفاده در واقع مقدار مصرف ماده به ازای هر واحد تولید ناخالص داخلی است. در این روش محاسبه‌ی مصرف فولاد با استفاده از ترکیب برونز رای تولید ناخالص داخلی و شدت استفاده انجام می‌شود که از جدول داده ستانده استخراج می‌شود. این روش از اوایل دهه‌ی ۷۰ میلادی، از طریق مطالعات مالنباوم^[۱۰] مورد توجه قرار گرفت.

در بررسی‌های مالنباوم فرض براین است که شدت استفاده‌ی فولاد در اقتصاد به شکل U معکوس است. یعنی در مراحل توسعه‌ی اقتصادی، در ابتدا شدت مصرف فولاد در اقتصاد افزایش می‌یابد، اما با رشد اقتصادی به تدریج شدت مصرف کاهش می‌یابد. فرض مذکور براین اساس استوار است که ترکیب کالاهای و خدمات تولید شده در اقتصاد و به تبع آن میزان استفاده از مواد معنده‌ی، با رشد اقتصادی تغییر می‌کند. با رشد اقتصادی سهم بخش‌هایی که مواد معنده‌ی مصرف می‌کنند، همچون بخش خدمات، افزایش می‌یابد. در جدول ۲ به اختصار به پژوهش‌های انجام شده مرتبط با پیش‌بینی مصرف فولاد مبتنی بر نظریه‌ی شدت استفاده اشاره شده است.

۳. پژوهش‌های مبتنی بر روش‌های هوشمند

همان‌طور که پیش‌تر ذکر شد دسته‌ی دیگر از روش‌ها که به منظور پیش‌بینی تقاضا به کار گرفته می‌شوند، روش‌های هوشمند هستند. اما تعداد اندکی از پژوهش‌های صورت گرفته در این حوزه از روش‌ها و مدل‌های هوشمند بهره جسته‌اند که در جدول ۳ به برخی از آنها اشاره شده است.

۳. هوش محاسباتی و محاسبات نرم

در پژوهش‌های پیشین، روش‌های متفاوتی برای مدل‌سازی کلاسیک سیستم‌های مورد مطالعه ارائه شده است. این گونه از مدل‌ها به دو دسته‌ی مدل‌های آماری و مدل‌های هوشمند تقسیم می‌شوند. مدل‌های آماری اگرچه مانند مدل‌های هوشمند توانایی یادگیری را ندارند و همچنین در شرایط خاص قابلیت به کار گیری دارند، جواب حاصل از آنها برای دسته مسائلی خاص بهینه و ایده‌آل خواهد بود. این دسته از مدل‌ها به شرط آنکه ساختارهای موجود در سیستم تحت مطالعه کاملاً خطی باشند، می‌توانند آنها را به صورت بهینه مدل‌سازی کنند. اما اگر شرط خطی بودن سیستم‌های تحت مطالعه برقرار نباشد، دیگر هیچ یک از خصوصیات منحصر به فرد و دقت پیشینه‌ی مدل‌های آماری باقی نخواهد ماند. به عبارت دیگر، محدودیت خطی بودن

پیشرفت‌های دنیا یکی از مهم‌ترین عوامل پیشرفت صنعتی پایدار است، در این مقاله با به کارگیری روش‌های مستدل و رویکردهای کارا و ساختاریافته مسئله‌ی مدیریت مصرف فولاد از دیدگاه متفاوتی تجزیه و تحلیل شده و روند آتی میزان مصرف فولاد خام کشور پیش‌بینی شده است.

با توجه به این که امروزه پیشرفت سریع فناوری‌ها و ایجاد مشخصه‌های جدید اطلاعاتی مسائل و چالش‌هایی با ماهیت کاملاً پیچیده فارروی تصمیم‌گیرندگان و برنامه‌ریزان قرار می‌دهد، بهبود کیفیت تصمیم‌گیری‌ها با اتخاذ راهبردهای مناسب و به هنگام امکان‌پذیر خواهد بود. بدین منظور ابزارهای هوش محاسباتی همچون شبکه‌های عصبی مصنوعی به عنوان رهیافتی منطقی و علمی برای مدل‌سازی پیچیدگی‌های موجود در بازارهای مالی و مرتفع ساختن محدودیت‌های ذاتی موجود در مدل‌سازی‌های کلاسیک به کار گرفته شده است.^[۱۱] اما این‌گونه روش‌ها به دلیل استفاده از منطق کلاسیک در فرایند‌های مدل‌سازی، عملکرد چندان مناسبی در رویارویی با ابهامات و عدم قطعیت‌ها ندارند. ابزارهای محاسبات نرم، برخلاف روش‌های کلاسیک و محاسبات سخت ابزارهای مناسب‌تری در مدل‌سازی ابهامات و عدم قطعیت‌های موجود در سیستم مورد مطالعه هستند، اما در حالت کلی عملکرد مناسبی برای مدل‌سازی مسائل پیچیدگی‌ای دنیای واقعی ندارند. براین اساس می‌توان این‌طور نتیجه‌گیری کرد که شاید استفاده هم‌زمان از این دو ابزار و در کنار هم گذاردن آنها، در حالت کلی راه حل مناسبی برای استفاده از مزایای منحصر به فرد آنها و مرتفع ساختن محدودیت‌های هریک از آنها باشد.

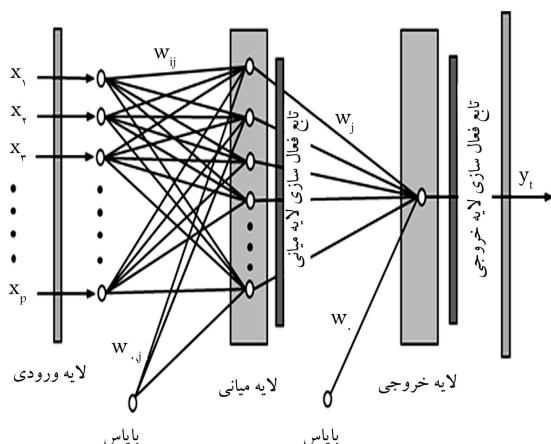
هدف این مقاله بهره‌مندی از مزایای منحصر به فرد ابزارهای هوش محاسباتی همچون شبکه‌های عصبی مصنوعی همراه با به کارگیری ابزارهای هوش محاسبات نرم به ویژه منطق فازی به منظور مدل‌سازی هم‌زمان پیچیدگی‌ها و عدم قطعیت‌های موجود در مسئله‌ی مورد مطالعه و ارائه‌ی پیش‌بینی دقیق و قابل اطمینان از میزان مصرف فولاد خام کشور در افق بلندمدت است. بدین منظور ابتدا سیستم مورد مطالعه با استفاده از مدل کلاسیک سخت نظیر رکرسیون خطی چندگانه و مدل هوشمند سخت نظیر شبکه‌های عصبی مصنوعی به طور جداگانه مدل‌بندی شده و نتایج مقایسه شده‌اند. سپس با استفاده از منطق فازی، تمام ساختارها و مدل‌های قطعی طراحی شده در مرحله‌ی قبل، تا حد امکان فازی سازی شده و به صورت مدل‌های کلاسیک نرم و هوشمند نرم با یکدیگر مقایسه شده‌اند. نتایج بیان‌گر برتری مدل هوشمند سخت بر مدل کلاسیک سخت و نیز برتری مدل هوشمند نرم بر مدل کلاسیک نرم است. بقیه‌ی قسمت‌های این مقاله به این شرح است: در بخش بعدی به پژوهش‌های پیشین مرتبط با موضوع و مربوط به پیش‌بینی مصرف فولاد خام به طور خلاصه پرداخته شده است. در بخش سوم خلاصه‌ی از روش‌های هوش محاسباتی و محاسبات نرم و نیز روش ترکیبی پیشنهادی آورده شده است. در بخش چهارم مدل‌سازی مسئله‌ی مورد نظر صورت گرفته و چهار مدل کلاسیک سخت، هوشمند سخت، کلاسیک نرم و هوشمند نرم طراحی و نتایج آنها با یکدیگر مقایسه شده‌اند. در نهایت جمع‌بندی و نتیجه‌گیری آورده شده است.

۲. بررسی پژوهش‌های پیشین

در این قسمت به پژوهش‌های پیشین در حوزه‌ی پیش‌بینی مصرف فولاد اشاره شده است. به طور کلی در پژوهش‌های شده در این حوزه، سه دسته روش به کار گرفته شده‌اند. دسته‌ی اول شامل پژوهش‌های مبتنی بر روش‌های کلاسیک اقتصادسنجی، دسته‌ی دوم شامل پژوهش‌های مبتنی بر نظریه‌ی شدت استفاده و

جدول ۱. پژوهش‌های صورت گرفته مبتنی بر روش‌های کلاسیک اقتصادسنجی.

نام نویسنده	سال انتشار	راهنمایی	توضیحات
چن و همکاران [۲]	۱۹۹۱	مدل خودرگرسیون برداری	پیش‌بینی مصرف فولاد خام در چین متغیرهای تولید ناخالص داخلی، عرضه‌ی پول، سرمایه‌گذاری و قیمت
لبسون و همکاران [۳]	۱۹۹۵	مدل غیرفاسلمی توازن جزئی	پیش‌بینی مصرف فولاد خام در ژاپن، چین و آمریکای شمالی با استفاده از از شاخص‌های قیمت فولاد، تولید فولاد و عرضه روند
ایوانز و والتون [۴]	۱۹۹۷	رگرسیون خطی	بررسی ارتباط بین مصرف فولاد خام و ارزش افزوده ناخالص به عنوان شاخصی از میزان فعالیت‌های اقتصادی در انگلستان
کرامپتون [۵]	۱۹۹۹	مدل خودرگرسیون برداری بیزین	پیش‌بینی مصرف فولاد خام در آسیای جنوب شرقی با استفاده از متغیرهای تولید ناخالص داخلی، عرضه پول، سرمایه‌گذاری و قیمت
کرامپتون [۶]	۲۰۰۳	مدل خودرگرسیون برداری	پیش‌بینی مصرف فولاد خام در چین
زارع نژاد و انوری [۷]	۲۰۰۸	داده‌های پانلی	پیش‌بینی مصرف فولاد خام در ایران با استفاده از شاخص‌های ترکیب مواد محصول، ترکیب کالا از درآمد و نرخ رشد تولید ناخالص داخلی
هیو [۸]	۲۰۱۱	مدل تصحیح خطی برداری	بررسی چگونگی ارتباطات سببی بین مصرف فولاد خام و عوامل رشد اقتصادی در کره
ین و چن [۹]	۲۰۱۳	مدل خودرگرسیون برداری	بررسی تغییرات میزان تولید و مصرف فولاد با در نظر گرفتن سطح اشباع، چرخه عمر کالا، تولید ناخالص داخلی و نرخ شهرسازی



شکل ۱. ساختار کلی یک پرسپترون چندلایه.

(x_1, x_2, \dots, x_p) به صورت زیر است:

$$y_t = b_0 + \sum_{j=1}^Q w_j \cdot g(b_{j,j} + \sum_{i=1}^P w_{i,j} \cdot x_{t,i}) + \varepsilon_t \quad (1)$$

به طوری که پارامترهای مدل هستند که غالباً وزن‌های اتصالی نامیده می‌شوند، P تعداد گره‌های ورودی و Q تعداد گره‌های مخفی است.تابع سیگموئیدی اغلب به عنوان تابع فعال‌سازی لایه‌ی مخفی استفاده می‌شود.

$$g(x) = \frac{1}{1 + \exp(-x)} \quad (2)$$

این‌گونه از مدل‌ها باعث شده است آنها توانایی مدل‌سازی سیستم‌های غیرخطی را نداشته باشند. این در حالی است که اکثر سیستم‌های موجود در دنیای واقع غیرخطی هستند. بنابراین استفاده از مدل‌های خطی آماری برای مسائل تصمیم‌گیری دنیای واقعی که غالباً غیرخطی هستند، اساساً توجیه‌پذیر و منطقی نیست و نتایج رضایت‌بخشی نیز حاصل ننمی‌شود.

شبکه‌های عصبی پرسپترون چندلایه از جمله روش‌های مدل‌سازی هستند که قادر به تخمین موارد غیرخطی متعدد در داده‌ها هستند و یک چارچوب محاسبه‌ی اعطا‌پذیر برای دامنه‌ی وسیعی از مسائل غیرخطی می‌باشند. یکی از میزبانی‌های باز این‌گونه از مدل‌ها نسبت به دیگر مدل‌های غیرخطی این است که پرسپترون‌های چندلایه یک تقریب زندگی جهانی هستند که می‌توانند هر نوع تابعی را با دقت دلخواه تقریب بزنند. نقطه‌ی قوت شبکه‌های عصبی پرسپترون چندلایه در پردازش مواری اطلاعات موجود در داده‌هاست؛ این‌گونه از شبکه‌ها همچیغ‌گونه پیش‌فرصتی در مورد شکل مدل در فرایند مدل‌سازی نیاز ندارند و در حالت کلی یک مدل مبتنی بر داده تلقی می‌شوند. [۲۶]

پرسپترون‌های چندلایه شبکه‌هایی پیش‌رو با حداقل یک لایه‌ی مخفی هستند که جزو پرکاربردترین مدل‌های شبکه‌های عصبی به منظور مدل‌سازی های سیستم‌های غیرخطی به حساب می‌آیند. این مدل‌ها در ساده‌ترین حالت خود از سه لایه‌ی پردازش ساده‌ی اطلاعات متصل به هم تشکیل شده‌اند. پرسپترون‌های چندلایه با یک لایه‌ی مخفی معروف‌ترین و پرکاربردترین نوع از این مدل‌ها هستند. دلیل اصلی این موضوع بر این حقیقت استوار است که یک لایه‌ی مخفی در حالت کلی برای تقریب انواع تابع کافی است. ساختار کلی پرسپترون‌های چندلایه با یک لایه‌ی مخفی در شکل ۱ نشان داده شده است. رابطه‌ی بین خروجی شبکه (y_t) و ورودی‌ها

جدول ۲. پژوهش‌های صورت گرفته مبتنی بر نظریه‌ی شدت استفاده.

نام نویسنده‌گان	سال انتشار	راهبرد	توضیحات
رابرت[۱۱]	۱۹۹۰	نظریه شدت استفاده	پیش‌بینی مصرف فولاد در آمریکا با استفاده از شاخص‌های ترکیب مواد محصول، ترکیب کالا از درآمد، تولید ناخالص داخلی و خالص صادرات
فیندلی و زین[۱۲]	۱۹۹۵	نظریه شدت استفاده	پیش‌بینی مصرف فولاد خام در ژاپن با استفاده از متغیرهای درآمد ملی، جمعیت و صادرات
رابرت[۱۳]	۱۹۹۶	نظریه شدت استفاده	توسعه یک مدل جدید به منظور توصیف مصرف فلزات بوسیله‌ی شاخص‌های اقتصادی مانند تولید تولید ناخالص داخلی، تولید داخلی، خالص صادرات و مقایسه آن با روش شدت استفاده
ڑانگ[۱۴]	۱۹۹۸	نظریه شدت استفاده	پیش‌بینی مصرف فولاد در چین با در نظر گرفتن ارزش افزوده صنعت، قیمت فولاد خام، صادرات و جمعیت
شن[۱۵]	۱۹۹۸	نظریه شدت استفاده	پیش‌بینی مصرف فولاد خام در چین با استفاده از متغیر درآمد ملی
کرامپتون[۱۶]	۲۰۰۰	نظریه شدت استفاده	پیش‌بینی مصرف فولاد خام در ژاپن با در نظر گرفتن مهم‌ترین بخش‌های مصرف کننده فولاد شامل ماشین‌آلات و تجهیزات الکترونیکی و حمل و نقل، ساختمان و کالاهای فلزی
ریایاس[۱۷]	۲۰۰۶	نظریه شدت استفاده	پیش‌بینی مصرف فولاد خام در لهستان با در نظر گرفتن شاخص‌های ترکیب مواد محصول و ترکیب کالا از درآمد
وارل و اولسون[۱۸]	۲۰۰۹	نظریه شدت استفاده	بررسی رابطه بین شدت مصرف فولاد و رشد اقتصادی در چین
وارل[۱۹]	۲۰۱۴	نظریه شدت استفاده	بررسی روند تعییرات مصرف فولاد در بلندمدت با استفاده از اطلاعات مربوط به ۶۱ کشور جهان
کرامپتون[۲۰]	۲۰۱۵	نظریه شدت استفاده	بررسی روند تعییرات در میزان مصرف فولاد با استفاده از اطلاعات مربوط به کشورهای عضو سازمان همکاری و توسعه اقتصادی

جدول ۳. پژوهش‌های صورت گرفته مبتنی بر روش‌های هوشمند.

نام نویسنده‌گان	سال انتشار	راهبرد	توضیحات
زیو[۲۱]	-	مدل‌های خاکستری	پیش‌بینی مصرف فولاد خام در چین
آزاده و همکاران[۲۲]	۲۰۱۳	شبکه‌های عصبی	پیش‌بینی مصرف فولاد خام در ایران با در نظر گرفتن متغیر تولید ناخالص داخلی، نیز رشد تولید ناخالص داخلی، تورم و نیز ساخت و ساز
ژو و همکاران[۲۳]	۲۰۱۳	مدل‌های خاکستری والگوریتم بهینه‌سازی از حمام ذرات	پیش‌بینی مصرف سنگ آهن در چین
ایوانز[۲۴]	۲۰۱۴	مدل‌های خاکستری	پیش‌بینی مصرف فولاد خام در انگلستان
ونگ و همکاران[۲۵]	۲۰۱۵	مدل ترکیبی	پیش‌بینی تقاضای فولاد در چین

۱.۳ رگرسیون فازی

در مدل‌سازی‌های کلاسیک، رگرسیون خطی چندمتغیره از جمله روش‌های تجزیه و تحلیل رگرسیونی است که قادر است، ساختارهای موجود در سیستم‌های مورد مطالعه را به شرط خطی بودن آنها به صورت بهینه مدل‌سازی کند. اما این مدل‌ها در فرایند مدل‌سازی خود از مفهوم عبارت خطأ استفاده می‌کنند، به عبارت دیگر تخمین‌های این‌گونه از مدل‌ها مقادیر دقیقی است و شامل جمله خطأ نیست؛ این همان مفهوم پایه‌یی رگرسیون فازی است که ناتانکا و همکارانش^[۱۸] پیشنهاد داده‌اند. مفهوم اساسی نظریه‌ی فازی و رگرسیون فازی این است که جمله خطأ از باقی مانده‌های بین مقادیر تخمین‌زده شده و مقادیر اصلی یا مشاهدات تولید نمی‌شود، بلکه در عدم قطعیت پارامترهای مدل و امکان توزیع در ارتباط با مشاهدات حقیقتی به کار گرفته می‌شود. یک مدل رگرسیون خطی فازی را در حالت کلی می‌توان به صورت زیر نمایش داد:

$$\tilde{Y} = \tilde{\beta}_0 + \tilde{\beta}_1 x_1 + \cdots + \tilde{\beta}_n x_n = \sum_{i=1}^n \tilde{\beta}_i x_i = X' \tilde{\beta} \quad (4)$$

به طوری‌که X بردار متغیرهای مستقل، علامت پریم '۰' بیان‌گر ترانهاده، n تعداد متغیرها و $\tilde{\beta}$ مجموعه‌های فازی بیان‌گر آمین پارامتر مدل هستند. این اعداد فازی (پارامترهای $\tilde{\beta}$) به شکل اعداد فازی نوع - ال «دوبویس و پراد» (α_i, c_i) با توزیع احتمال به صورت زیر هستند:

$$\mu_{\tilde{\beta}_i}(\beta_i) = L\{(\alpha_i - \beta_i/c)\} \quad (5)$$

به طوری‌که L یک تابع است. پارامترهای فازی نیز به شکل اعداد فازی مثالی به کار گرفته شده‌اند.

$$\mu_{\tilde{\beta}_i}(\beta_i) = \begin{cases} 1 - \frac{|\alpha_i - \beta_i|}{c_i} & \alpha_i - c_i \leq \beta_i \leq \alpha_i + c_i, \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

به طوری‌که $(\beta_i)_{\tilde{\beta}}$ تابع عضویت مجموعه‌ی فازی بیان‌گر پارامترهای β است. α_i نیز مرکز اعداد فازی و c_i گسترش حول مرکز آنها هستند. حال با توجه به اصل گسترش، تابع عضویت عدد فازی $\tilde{\beta} = X_t^t \tilde{\beta}$ را می‌توان به صورت زیر تعریف کرد:

$$\mu_{\tilde{y}}(y_t) = \begin{cases} 1 - \frac{|y_t - x_t \alpha|}{c_i|x_t|} & \text{for } x_t \neq 0 \\ 1 & \text{for } x_t = 0, y_t = 0, \\ 0 & \text{for } x_t = 0, y_t \neq 0, \end{cases} \quad (7)$$

به طوری‌که α و c به ترتیب بردارهای مقادیر مربوط به پارامترها و میزان گسترش‌های آنها حول مرکز هستند. به طور کلی مدل از کمینه کردن کل ابهامات (که برابر با مجموع گسترش‌های تکی و مربوط به هر یک از پارامترهای فازی مدل است) استفاده می‌کند.

$$\text{Minimize} \quad S = \sum_{t=1}^k c' |x_t| \quad (8)$$

البته این روش به طور هم‌زمان شرایطی را که مقدار عضویت به ازای هر مشاهده y_t باید بزرگ‌تر از یک حد آستانه‌ی تعیین شده در سطح h باشد ($h \in [0, 1]$ ، نیز در نظر می‌گیرد. این معیار بیان‌گر این حقیقت است که خروجی‌های فازی مدل باید

از این رو پرسپترون چندلایه اشاره شده در رابطه ۳ در حقیقت به عنوان یک نگاشت غیرخطی از مشاهدات گذشته به مقدار آینده خواهد بود یعنی:

$$y_t = f(x_1, x_2, \dots, x_p, W) + \varepsilon_t \quad (3)$$

به طوری که W بردار همه پارامترها و f تابعی است که توسط ساختار شبکه عصبی و وزن‌های اتصالی تعیین می‌شود، از این رو شبکه‌های عصبی معادل یک مدل رگرسیون غیرخطی هستند.^[۲۷] شکل ۱ مدل ساده بیان شده توسط رابطه فوق بوده که دارای قدرت تقریب بسیار زیادی است، چرا که قادر است هر تابع دلخواه را به شرط آنکه تعداد گرههای مخفی (Q) به اندازه کافی بزرگ باشند را تقریب بزند.

با وجود تمامی مزایای ذکر شده برای مدل‌های هوشمند، ذکر این نکته حائز اهمیت است که سهم قابل توجهی از سیستم‌های مورد مطالعه در دنیای واقعی، سیستم‌های غیرقطعی هستند که روش‌هایی معمول و کلاسیک مدل‌سازی قادر به درک کامل و جامع روابط موجود در آنها نمی‌باشد. بسیاری از دانشمندان و محققان عدم قطعیت موجود در سیستم‌های واقعی را مربوط به فقدان کیفی و یا کمی اطلاعات و دانش بشر از این‌گونه از سیستم‌ها می‌دانند. از دیدگاهی دیگر، اطلاعات از مهم‌ترین و ارزشمندترین منابع موجود برای تصمیم‌گیرندگان در جهت مقابله با عدم قطعیت‌های موجود در سیستم‌های تحت مطالعه و اتخاذ تصمیمات دقیق تر می‌باشند.

اما توجه به این نکته ضروری است که فراهم نمودن داده‌ها و اطلاعات لازم به منظور بهبود کیفیت تصمیمات اتخاذی، امر ساده‌ی نبوده و در کنار هزینه‌های بالای آنها، در برخی از موارد نیز عملأً غیرممکن است. بر این اساس دانش مدیریت و برنامه‌ریزی، در عصر حاضر نیازمند روش‌هایی است که تا حد امکان قابلیت رویارویی با مشکلاتی چون پیچیدگی، عدم قطعیت، ابهام و چند پهلوی را داشته و در این‌گونه از شرایط نیز کارا و کارآمد باشند. ابزارهای محاسبات نرم، برخلاف روش‌های کلاسیک و محاسبات سخت، ابزارهای مناسب‌تری در مدل‌سازی ابهامات و عدم قطعیت‌های موجود در سیستم‌های تحت مطالعه هستند؛ اما در حالت کلی به منظور مدل‌سازی مسائل پیچیده‌ی دنیای واقعی عملکرد مناسبی را از خود نشان نداده‌اند.

بر این اساس می‌توان این‌گونه نتیجه‌گیری کرد که با وجود تمام ویرگی‌های منحصر به فرد روش‌های هوش میانجی و محاسباتی و محاسبات نرم هیچ یک از این روش‌ها در حالت کلی قابلیت به کارگیری کارا و کارآمد در مدل‌سازی سیستم‌های مورد مطالعه را نخواهد داشت. از یک سو ابزارهای هوش محاسباتی در مرتفع ساختن مشکل پیچیدگی‌های موجود در سیستم‌های مورد مطالعه موفق ترند اما در رویارویی با ابهامات و عدم قطعیت‌ها دچار ناکارآمدی می‌شوند. از سوی دیگر ابزارهای محاسبات نرم در رویارویی با پیچیدگی‌ها دچار ناکارآمدی می‌شوند و در مرتفع ساختن مشکل ابهامات و عدم قطعیت‌های موجود در سیستم‌های مورد مطالعه عملکرد بهتری را از خود نشان می‌دهند. پس شاید استفاده‌ی هم‌زمان از این دو ابزار و در کنار هم قرار دادن آنها، در حالت کلی راه حل مناسب‌تری برای استفاده از مزایای منحصر به فرد آنها و همچنین مرتفع ساختن محدودیت‌های تکی هر یک از آنها باشد.^[۱]

بر این اساس در این مقاله به منظور مدل‌سازی دقیق‌تر و کامل‌تر سیستم مورد مطالعه، سعی شده است بر اساس شرایط خاص مسئله، روش‌هایی مدل‌سازی کلاسیک و هوشمند ذکر شده در قسمت‌های قبلی فازی‌سازی شوند. در ادامه‌ی این قسمت شرح مختصری از فرایند مدل‌سازی کلاسیک نرم و هوشمند نرم (مدل ترکیبی پیشنهادی) بر اساس شرایط خاص مسئله‌ی مورد مطالعه ارائه شده است.

$$\mu_{\tilde{w}_{i,j}}(w_{i,j}) = \begin{cases} \frac{1}{b_{i,j} - a_{i,j}}(w_{i,j} - a_{i,j}) & \text{if } a_{i,j} \leq w_{i,j} \leq b_{i,j}, \\ \frac{1}{b_{i,j} - c_{i,j}}(w_{i,j} - c_{i,j}) & \text{if } b_{i,j} \leq w_{i,j} \leq c_{i,j}, \\ 0 & \text{otherwise,} \end{cases} \quad (12)$$

به طوری که $\mu_{\tilde{w}_{i,j}}$ تابع عضویت مجموعه فازی است که با پارامترهای $w_{i,j}$ مشخص می‌شود. حال با استفاده از پارامترهای فازی به صورت اعداد فازی مثلثی و همچنین اصل گسترش، تابع عضویت y_t مطابق $\tilde{x}_{t,j} = g(\tilde{w}_{i,j} + \sum_{i=1}^p \tilde{w}_{i,j} \cdot x_{t,i})$ ذیل بست خواهد آمد.^[۲۱]

$$\mu_{\tilde{X}_{t,j}}(x_{t,j}) = \begin{cases} \frac{(X_{t,j} - g(\sum_{i=1}^p a_{i,j} \cdot x_{t,i}))}{g(\sum_{i=1}^p b_{i,j} \cdot x_{t,i}) - g(\sum_{i=1}^p a_{i,j} \cdot x_{t,i})}, & \text{if } g(\sum_{i=1}^p a_{i,j} \cdot x_{t,i}) \leq X_{t,j} \leq g(\sum_{i=1}^p b_{i,j} \cdot x_{t,i}), \\ \frac{(X_{t,j} - g(\sum_{i=1}^p c_{i,j} \cdot x_{t,i}))}{g(\sum_{i=1}^p b_{i,j} \cdot x_{t,i}) - g(\sum_{i=1}^p c_{i,j} \cdot x_{t,i})}, & \text{if } g(\sum_{i=1}^p b_{i,j} \cdot x_{t,i}) \leq X_{t,j} \leq g(\sum_{i=1}^p c_{i,j} \cdot x_{t,i}), \\ 0 & \text{otherwise,} \end{cases} \quad (13)$$

به قسمی که: $x_{t,I} = 1(t = 1, 2, \dots, k), x_{t,i} = x_{t-i}(t = 1, 2, \dots, k, i = 0), x_{t,i} = x_{t-i}(t = 1, 2, \dots, k, i = 1, 2, \dots, p)$ حال با در نظر گرفتن عدد فازی مثلثی $\tilde{x}_{t,j}$ مطابق رابطه ۱۳ و همچنین پارامترهای فازی \tilde{w}_j مطابق رابطه زیر:

$$\mu_{\tilde{w}_j}(w_j) = \begin{cases} \frac{1}{e_j - d_j}(w_j - d_j) & \text{if } d_j \leq w_j \leq e_j, \\ \frac{1}{e_j - f_j}(w_j - f_j) & \text{if } e_j \leq w_j \leq f_j, \\ 0 & \text{otherwise,} \end{cases} \quad (14)$$

آنگاه تابع عضویت $\tilde{y}_t = f(\tilde{w}_j + \sum_{j=1}^q \tilde{w}_j \cdot \tilde{X}_{t,j}) = f(\sum_{j=1}^q \tilde{w}_j \cdot \tilde{X}_{t,j})$ مطابق زیر خواهد بود:

$$\mu_{\tilde{Y}}(y_t) \cong \begin{cases} \frac{-B_1}{rA_1} + [(\frac{B_1}{rA_1})^r - \frac{C_1 - f^{-1}(x_t)}{A_1}]^{\frac{1}{r}} & \text{if } C_1 \leq f^{-1}(y_t) \leq C_2, \\ \frac{-B_2}{rA_2} + [(\frac{B_2}{rA_2})^r - \frac{C_2 - f^{-1}(x_t)}{A_2}]^{\frac{1}{r}} & \text{if } C_2 \leq f^{-1}(y_t) \leq C_3, \\ 0 & \text{otherwise,} \end{cases} \quad (15)$$

به قسمی که:

$$A_1 = \sum_{j=1}^q (e_j - d_j) \cdot (g(\sum_{i=1}^p b_{i,j} \cdot x_{t,i}) - g(\sum_{i=1}^p a_{i,j} \cdot x_{t,i})),$$

$$B_1 = \sum_{j=1}^q (d_j \cdot (g(\sum_{i=1}^p b_{i,j} \cdot x_{t,i}) - g(\sum_{i=1}^p a_{i,j} \cdot x_{t,i})) + g(\sum_{i=1}^p a_{i,j} \cdot x_{t,i}) \cdot (e_j - d_j)),$$

$$A_2 = \sum_{j=1}^q (f_j - e_j) \cdot (g(\sum_{i=1}^p c_{i,j} \cdot x_{t,i}) - g(\sum_{i=1}^p b_{i,j} \cdot x_{t,i})),$$

برای تمام نقاط داده‌ی y_1, y_2, \dots, y_k بیشتر از مقدار انتخابی سطح h باشند. انتخاب مقدار سطح h برگسترهای پارامترهای فازی مدل مؤثر است.

$$\mu_{\tilde{y}}(y_t) \geq h \quad \text{for } t = 1, 2, \dots, k \quad (16)$$

شاخص t به تعداد داده‌های غیرفازی به کار گرفته شده در فرایند ساخت مدل بر می‌گردد. مسئله پیدا کردن پارامترهای رگرسیون فازی توسط تابع کاکا به صورت یک مسئله برنامه‌ریزی خطی به صورت زیر فرمول بندی شده است.^[۲۴]

$$\begin{aligned} \text{Minimize} \quad & S = \sum_{t=1}^k |x_t| \\ \text{subject to} \quad & x_t' \alpha + (1-h)c' |x_t| \geq y_t \quad t = 1, 2, \dots, k \\ & x_t' \alpha - (1-h)c' |x_t| \leq y_t \quad t = 1, 2, \dots, k \\ & c \geq 0 \end{aligned} \quad (17)$$

به طوری که $c' = c_1, c_2, \dots, c_n$ و $\alpha' = (\alpha_1, \alpha_2, \dots, \alpha_n)$ بدرار متغیرهای مجهول و S کل ابهامی است که قبلًا تعریف شده است.

۲.۳. مدل ترکیبی پیشنهادی

شبکه‌های عصبی مصنوعی، روش‌های مدل‌سازی دقیق و ارزشمندی برای دامنه‌ی وسیعی از مسائل غیرخطی هستند، اما این روش‌ها، توانایی مواجهه کارا و کارآمد با مسائل غیرقطعی و مبهم را ندارند و در حالت کلی نمی‌توانند عدم قطعیت‌های موجود در سیستم‌های مورد مطالعه را مدل‌سازی کنند. این گونه از روش‌ها مشابه سایر روش‌های مدل‌سازی غیرفازی دارای محدودیت تعداد زیاد داده‌های گذشته برای حصول نتایج دقیق هستند. در قسمت قبل مشاهده شد که مدل‌های فازی همچون رگرسیون فازی، مدل‌های متسابقی در شرایط داده‌های در دسترس کم هستند. اما اولاً در تمام سیستم‌های غیرخطی قابلیت کاربرد ندارند و دوم این که عملکرد آنها همیشه مناسب و قابل قبول نیست. بنابراین در این قسمت، یک نسخه‌ی فازی از شبکه‌های عصبی مصنوعی به منظور مدل‌سازی سیستم مورد مطالعه از نوع پیوسته سببی غیرخطی ارائه شده است.

شبکه‌ی عصبی پرسپترون چندلایه‌ی فازی: شبکه‌های عصبی پرسپترون چندلایه از جمله مهم‌ترین روش‌های مدل‌سازی غیرخطی هستند که قادر به تخمین موارد غیرخطی متعدد در سیستم‌های تحت مطالعه‌اند و یک چارچوب محاسبه‌ی انعطاف‌پذیر برای دامنه‌ی وسیعی از مسائل غیرخطی می‌باشند. اما پارامترهای پرسپترون‌های چندلایه (وزن‌ها و بایاس‌ها) مقداری قطعی هستند پس توانایی روایرویی با محیط‌ها و سیستم‌های غیرقطعی را ندارند. بنابراین در روش پیشنهادی به جای بدکارگیری این مقادیر قطعی، از اعداد فازی استفاده شده است. یک مدل فازی‌سازی شده با توابع و پارامترهای فازی در حالت کلی به صورت زیر است.^[۲۵]

$$\tilde{y}_t = f(\tilde{w}_j + \sum_{j=1}^q \tilde{w}_j \cdot \tilde{X}_{t,j}) = f(\sum_{j=1}^q \tilde{w}_j \cdot \tilde{X}_{t,j}), \quad (18)$$

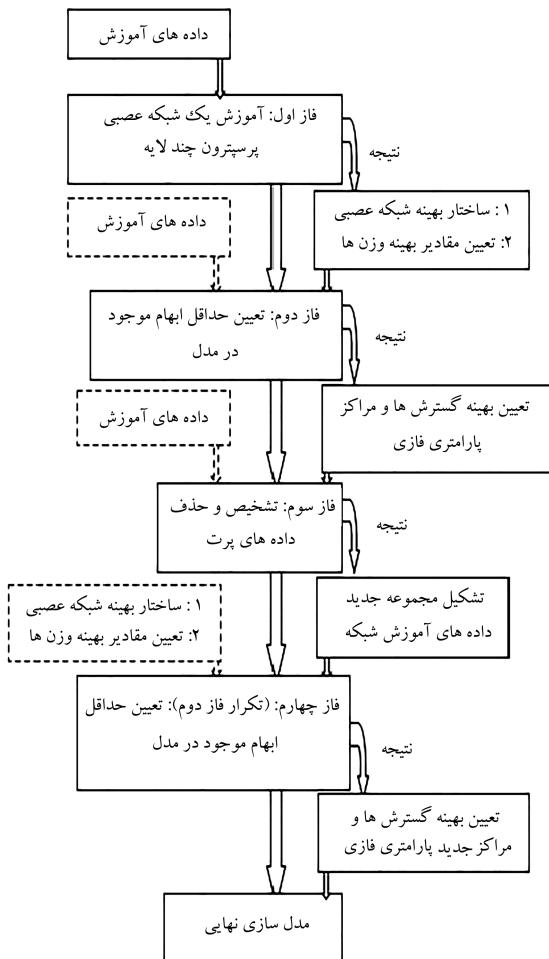
به قسمی که $(\tilde{w}_{i,j} + \sum_{i=1}^p \tilde{w}_{i,j} \cdot x_{t,i}) = g(\tilde{w}_{i,j} + \tilde{x}_{t,j} \cdot x_{t,i})$ سپس پارامترهای فازی در این معادله به صورت اعداد فازی مثلثی مطابق زیر در نظر گرفته شده‌اند.

$$\begin{aligned}
 & \text{Min} \quad \sum_{t=1}^k \sum_{j=1}^q \left(f_j \cdot g\left(\sum_{i=1}^p c_{i,j} \cdot x_{t,i}\right)\right) - \left(d_j \cdot g\left(\sum_{i=1}^p a_{i,j} \cdot x_{t,i}\right)\right) \\
 & \text{s.t} \\
 & \begin{cases} \frac{-B_1}{\tau A_1} + \left[\left(\frac{B_1}{\tau A_1}\right)^{\frac{1}{\tau}} - \frac{C_1 - f^{-1}(y_t)}{A_1}\right]^{\frac{1}{\tau}} \leq h & \text{if } C_1 \leq f^{-1}(y_t) \leq C_\tau \text{ for } t = 1, 2, \dots, k, \\ \frac{-B_\tau}{\tau A_\tau} + \left[\left(\frac{B_\tau}{\tau A_\tau}\right)^{\frac{1}{\tau}} - \frac{C_\tau - f^{-1}(y_t)}{A_\tau}\right]^{\frac{1}{\tau}} \leq h & \text{if } C_\tau \leq f^{-1}(y_t) \leq C_1 \text{ for } t = 1, 2, \dots, k, \end{cases} \\
 & \quad (16)
 \end{aligned}$$

فاز دو: تعیین کمینه‌ی ابهام با استفاده از معیارهایی مانند رابطه‌ی ۱۹ و $w^* = (w_0^*, w_1^*, \dots, w_q^*)$. تعداد محدودیت‌ها برابر با دو برابر تعداد مشاهدات است و مدل نهایی به صورت زیر خواهد بود:

$$\tilde{y}_t = \langle \alpha_0, c_0 \rangle + \langle \alpha_1, c_1 \rangle x_1 + \dots + \langle \alpha_q, c_q \rangle x_q \quad (20)$$

که c_i و α_i به ترتیب مراکز و گسترش‌های اعداد فازی هستند. فاز سه: با توجه به نظرات ایشیبیوجی^[۲۳] داده‌های حد بالا و پائین مدل وقتی که دامنه‌ی مدل پیشنهادی وسیع شود، حذف خواهد شد؛ پس در این مرحله داده‌های اطراف مرزهای بالا و پائین مدل حذف می‌شوند؛ سپس مدل مجدد فرمول بندی می‌شود. مراحل کلی این روش در شکل ۲ خلاصه‌سازی شده است.



شکل ۲. مراحل روش پیشنهادی در مدل سازی‌های پیوسته سببی غیرخطی فازی.

$-g(\sum_{i=1}^p b_{i,j} \cdot x_{t,i}))$,
 $B_\tau = \sum_{j=1}^q (f_j \cdot (g(\sum_{i=1}^p c_{i,j} \cdot x_{t,i}) - g(\sum_{i=1}^p b_{i,j} \cdot x_{t,i})))$
 $+ g(\sum_{i=1}^p c_{i,j} \cdot x_{t,i}) \cdot (f_j - e_j))$,
 $C_1 = \sum_{j=1}^q (d_j \cdot g(\sum_{i=1}^p a_{i,j} \cdot x_{t,i}))$,
 $C_\tau = \sum_{j=1}^q (e_j \cdot g(\sum_{i=1}^p b_{i,j} \cdot x_{t,i}))$,
 $C_2 = \sum_{j=1}^q (f_j \cdot g(\sum_{i=1}^p c_{i,j} \cdot x_{t,i}))$,
حال با در نظر گرفتن یک سطح آستانه h برای تمام مشاهدات، یک مسئله برنامه‌ریزی غیرخطی مطابق رابطه‌ی ۱۶ به دست خواهد آمد.^[۲۴] اگرچه به منظور حصول یک مدل ساده‌تر از روش مذکور، اعداد فازی مثبتی به صورت متقابل، توابع فعال‌سازی خروجی خطی و وزن‌های اتصالی بین لایه‌ی ورودی و لایه‌ی میانی به صورت قطعی در نظر گرفته شده‌اند. بدین ترتیب برای تابع عضویت y_t خواهیم داشت:

$$\mu_{\tilde{y}}(y_t) = \begin{cases} 1 - \frac{|y_t - \sum_{j=1}^q \alpha_j \cdot X_{t,j}|}{\sum_{j=1}^q c_j |X_{t,j}|} & \text{for } X_{t,j} \neq 0, \\ 0 & \text{otherwise,} \end{cases} \quad (17)$$

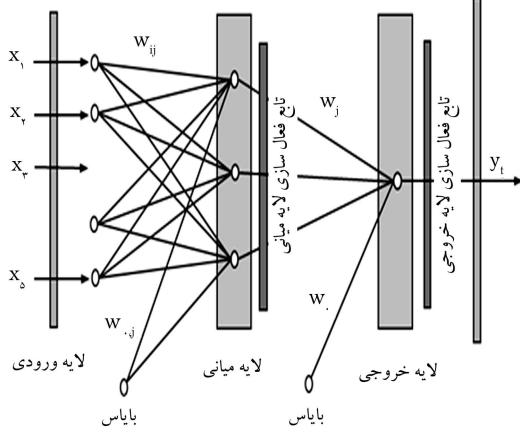
به عبارت دیگر در مدل ساده‌سازی شده S مطابق زیر تعریف می‌شود:

$$S = \sum_{j=1}^q \sum_{t=1}^k c_j |w_j| |x_{t,j}| \quad (18)$$

به قسمی که w وزن‌های ارتباطی بین نرون خروجی و نرون زام لایه‌ی میانی هستند. سپس مسئله‌ی تعیین مقادیر پارامترهای روش پیشنهادی مطابق زیر خواهد بود:

$$\begin{aligned}
 & \text{Min } S = \sum_{j=1}^q \sum_{t=1}^k c_j |w_j| |x_{t,j}| \\
 & \sum_{j=1}^q \alpha_j x_{t,j} + (1-h) \left(\sum_{j=1}^q c_j |x_{t,j}| \right) \geq y_t \\
 & \text{s.t. } \sum_{j=1}^q \alpha_j x_{t,j} - (1-h) \left(\sum_{j=1}^q c_j |x_{t,j}| \right) \leq y_t \\
 & c_j \geq 0 \quad \text{for } j = 1, 2, \dots, q \quad t = 1, 2, \dots, k
 \end{aligned} \quad (19)$$

مراحل روش مورد نظر در روابط ذکر شده به طور خلاصه به صورت زیر است:
فاز یک: آموزش یک مدل شبکه‌ی عصبی با استفاده از اطلاعات موجود در مشاهدات. نتیجه‌ی فاز یک، جواب بهینه‌ی پارامترها $w^* = (w_0^*, w_1^*, \dots, w_q^*)$ است که به عنوان یکی از مجموعه داده‌های ورودی در فاز دوم مورد استفاده قرار می‌گیرد.



شکل ۳. ساختار شبکه‌ی عصبی طراحی شده به منظور پیش‌بینی.

مختلف، شبکه‌ی ایده‌آل، شبکه‌ی تک لایه متشکل از ۵ نرون ورودی، ۳ نرون میانی و یک نرون خروجی به صورت $(5-3-1)^N$ است. توابع فعال‌سازی مرتب‌با تمام نرون‌های لایه‌ی میانی از نوع سیگموئیدی و تابع فعال‌سازی لایه‌ی خروجی از نوع خطی در نظر گرفته شده است. ساختار شبکه‌ی مورد نظر در شکل ۳ آورده شده است.

معیارهای عملکرد شبکه‌ی نهایی پیش‌بینی مصرف فولاد خام برای هر یک از مجموعه‌های آموزش و آزمایش در مقایسه با معیارهای عملکرد مدل رگرسیونی مستقر با خود، که در جداول ۵ و ۶ قابل مشاهده می‌باشد، نشان‌دهنده‌ی برتری مدل شبکه‌ی عصبی نسبت به مدل رگرسیون خطی ساده در افق بلندمدت است. نتایج حاکی از آن هستند که به کارگیری شبکه‌ی عصبی مصنوعی طراحی شده به منظور پیش‌بینی در افق بلند مدت، نسبت به مدل رگرسیون خطی $41/41\%$ بهبود در نتایج (براساس معیار خطای RMSE) ایجاد کرده است.

۲.۴. مدل سازی هوشمند نرم

در این قسمت به منظور مدل سازی سیستم مورد مطالعه در حالت فازی، پارامترهای شبکه‌ی عصبی پرسپترون چندلایه طراحی شده در بخش قبل، شامل وزن‌ها و بایاس‌ها و نیز ضرایب معادلات رگرسیون خطی به صورت مقادیر فازی در نظر گرفته می‌شوند. مطابق آن‌چه که در قسمت‌های پیشین به آن اشاره شد، با استفاده از مدل برنامه‌ریزی ریاضی، فازی سازی پارامترهای شبکه و ضرایب رگرسیون برای کمینه ساختن ابهامات صورت گرفته است. مجموعه داده‌های آموزش و آزمایش و نحوه پیش‌پردازش داده‌ها و نیز ساختار شبکه‌ی مورد استفاده در این قسمت مشابه با قسمت قبل در نظر گرفته شده است. حدود به دست آمده از فازی سازی شبکه عصبی، رگرسیون خطی و نیز بازه‌ی 95% اطمینان حاصل از مدل رگرسیون خطی ساده در جدول ۷ آمده است. نتایج حاکی از آن هستند که عملکرد مدل پرسپترون چندلایه‌ی فازی به مراتب بهتر از مدل‌های رگرسیون فازی و رگرسیون خطی است و به کارگیری این مدل اکیداً منجر به بهبود نتایج شده است.

۵. نتیجه‌گیری

داشتن نگرش عمیق و فهم دقیق از سیستم مورد مطالعه، از عوامل بنیادین و مؤثر بر کیفیت تصمیمات اتخاذی است. دست یافتن به شناختی کامل از عوامل

جدول ۴. متغیرهای ورودی به مدل.

ردیف	نام متغیر	نماد
۱	تولید داخلی فولاد خام	x_1
۲	تولید ناخالص داخلی	x_2
۳	قیمت فولاد خام	x_3
۴	سرمایه‌گذاری	x_4
۵	واردات فولاد خام	x_5

۴. طراحی مدل هوشمند به منظور پیش‌بینی مصرف فولاد خام کشور

همان‌گونه که در قسمت‌های پیشین نیز اشاره شد، لازمه‌ی دست یافتن به نتایج دقیق و کارا طراحی مدلی منطبق بر نوع، ساختار و شرایط خاص حاکم بر مسئله‌ی مورد مطالعه است. از این‌رو در این مقاله به منظور حصول پیشینه‌ی دقت و کارایی با به کارگیری ابزارهای هوش محاسباتی همچون شبکه‌های عصبی پرسپترون چندلایه و منطق فازی مدلی به منظور پیش‌بینی مصرف فولاد خام کشور طراحی شده و مورد بحث و بررسی قرار گرفته است.

۱.۴. مدل سازی هوشمند سخت

به طور کلی یک شبکه‌ی عصبی پرسپترون چندلایه شامل یک لایه‌ی ورودی، یک چند لایه‌ی میانی و بالاخره یک لایه‌ی خروجی است. یکی از مهم‌ترین مراحل طراحی این‌گونه از شبکه‌ها تعیین تعداد لایه‌های میانی و همچنین تعیین تعداد نرون‌های موجود در هر لایه است. در پژوهش‌های مرتبط پیشین تاکنون روش‌های متعدد و متفاوتی به منظور دست‌بایی به معماری پنهانی یک پرسپترون چندلایه پیشنهاد شده است.^[۲۰] اما بیشتر این روش‌ها به لحاظ دارا بودن ساختاری پیچیده و دشوار بودن به کارگیری آنها در حل مسائل در دنیای واقعی قابلیت استفاده چندانی نخواهند داشت. از سوی دیگر تاکنون هیچ یک از این روش‌ها توانسته‌اند مخصوص ارائه‌ی راه حلی بهینه برای همه‌ی مسائل پیش‌بینی واقعی باشند.^[۲۱] بنابراین تعداد زیادی از داشمندان و محققان در مواردی که هیچ روش نظاممندی به منظور تعیین پارامترهای مدل وجود نداشته است، با در نظر گرفتن شرایط حاکم بر هر مسئله‌ی خاص، روش آزمایش و خطأ را در پیش‌گرفته‌اند؛ در این مقاله نیز در موارد مشابه همین رویه در نظر گرفته شده است.

بی‌شک مهم‌ترین مسئله در معماری یک پرسپترون به منظور به کارگیری آن در مسائل پیش‌بینی، تعیین تعداد نرون‌های موجود در هر لایه است؛ زیرا نتایج به طور مستقیم یا غیرمستقیم به این امر وابسته‌اند و در نظر گرفتن تعداد بسیار زیادی با سیار انداز نرون‌های ورودی بر یادگیری و دقت شبکه تأثیر بسزایی خواهد داشت. در مسئله‌ی مورد مطالعه در این مقاله، با توجه به سببی بودن ساختار مسئله تعداد نرون‌های لایه‌ی ورودی برابر با تعداد متغیرهای مؤثر بر متغیر وابسته خواهد بود. با تکیه بر نتایج حاصل از پژوهش‌های پیشین که در قسمت‌های قبل به آنها اشاره شد و همچنین بهره‌مندی از نظرات و عقاید مدیران و کارشناسان صنعت فولاد،^[۲۲] مجموعه متغیرهای مؤثر بر متغیر وابسته مطابق با موارد ذکر شده در جدول ۴ است.

به منظور مدل سازی سببی خطی و غیرخطی سیستم مورد مطالعه، با در نظر گرفتن تمام شرایط خاص مرتبط با مسئله مورد نظر و نیز با پیروی از اصول کلی طراحی شبکه‌های عصبی مصنوعی، پس از بررسی پیش از پنج هزار شبکه‌ی

جدول ۵. مقایسه‌ی عملکرد مدل شبکه عصبی نهایی و مدل رگرسیون متناظر در افق بلند مدت.

داده‌های آموزش						
معیار	ضریب تعیین	میانگین خطای مطلق	درصد میانگین خطای مطلق	میانگین مریعت خط	مجذور میانگین	تشخیص
						جهت٪
رگرسیون	۰,۹۸۳۱۹	۷۲۶,۲۴	۰,۰۸	۷۷۶,۸۱	۸۲	+
پرسپترون	۰,۹۹۱۶۰	۴۳۴,۸۰	۰,۰۵	۵۴۸,۸۹	۹۳	-

جدول ۶. مقایسه‌ی عملکرد مدل شبکه عصبی نهایی و مدل رگرسیون متناظر در افق بلند مدت.

داده‌ای آزمایش						
معیار	ضریب تعیین	میانگین خطای مطلق	درصد میانگین خطای مطلق	میانگین مریعت خط	مجذور میانگین	تشخیص
						جهت٪
رگرسیون	۰,۹۳۸۳۹	۹۰۵,۸۱	۰,۰۷	۱۳۳۴,۴۱	۱۰۰	+
پرسپترون	۰,۹۷۶۹۵	۶۴۸,۲۹	۰,۰۶	۷۸۱,۹۵	۱۰۰	-

جدول ۷. میزان عملکرد روش‌های فازی در پیش‌بینی‌های بازه‌بی در مدل بلندمدت.

ردیف	روش	مجموعه آزمایش					
		پیش‌بینی شده	میزان بهبود (%)	میزان بازدهی			
۵	۴	۳	۲	۱	۰		
۱	روش رگرسیون چندمتغیره خطی (بازه ۹۵٪ اطمینان)	۰	۲۵۵۸۱	۰	-	-	-
۲	روش شبکه‌های عصبی مصنوعی سنتی (بازه ۹۵٪ اطمینان)	۰,۱۴	۲۵۰۳۳,۶۹	۰,۱۴	-	-	-
۳	روش ماشین‌های بردار پشتیبان (بازه ۹۵٪ اطمینان)	۰,۳۵	۲۴۱۹۲,۸۷	۰,۴۲	۰	-	-
۴	روش رگرسیون چندمتغیره خطی فازی	۰,۷۶	۲۳۱۵,۲	۰,۷۶	۰,۲۹	۰,۶۸	-
۵	روش شبکه‌های عصبی پرسپترون چندلایه‌ی فازی	۰,۳۵	۲۱۶۵,۴	۰,۵۳	۰,۳۵	۰,۰۵	۰,۶۸

به صورت کارا مدل سازی کنند و ضمن ایجاد انعطاف در مدل سازی‌های کلاسیک، به عنوان روشی پرکاربرد نتایج واقع گرایانه‌تری را عرضه و استنتاج کنند. نتایج حاکی از آن هستند که به کارگیری شبکه عصبی پرسپترون چندلایه‌ی طراحی شده به منظور پیش‌بینی در افق بلندمدت، نسبت به مدل رگرسیون خطی ۴۱,۴٪ نتایج را (بر اساس معیار خطای مجدد میانگین مریعت خط) بهبود داده است. همچنین در پیش‌بینی‌های بازه‌بی مدل شبکه عصبی پرسپترون چندلایه‌ی فازی، نسبت به مدل رگرسیون چندمتغیره خطی فازی، مدل ماشین‌های بردار پشتیبان (بازه ۹۵٪ اطمینان)، مدل شبکه‌های عصبی مصنوعی (بازه ۹۵٪ اطمینان)، و مدل رگرسیون خطی (بازه ۹۵٪ اطمینان) در افق بلندمدت به ترتیب ابراهارهای محاسبات نرم به ویژه منطق فازی می‌توانند این پیچیدگی‌ها و ابهامات را

مؤثر بر نحوه‌ی عملکرد سیستم‌ها و روابط حاکم بین آنها از راهکارهای اساسی برای افزایش عمق نگرش و دقت تصمیم‌گیرنگان است. شبیه‌سازی و مدل سازی از شناخته‌شده‌ترین ابزارهای موجود به منظور استخراج اطلاعات نهفته در سیستم‌های مورد مطالعه و ساختارهای حاکم بر آنها هستند. در عصر حاضر، رویارویی با افزایش سرعت تغییرات و تحولات محیطی، بر پیچیدگی‌ها و عدم قطعیت‌های محیطی افزوده تا جایی که رشد تصاعدی عدم اطمینان‌ها و ابهامات موجب شده است مدل سازی‌های کلاسیک نتوانند پاسخ‌گوی نیازمندی‌های تصمیم‌گیران در راستای اتخاذ تصمیمات دقیق و کارآمد باشند. بر این اساس ابزارهای هوش محاسباتی همچون شبکه‌های عصبی مصنوعی در کنار ابراهارهای محاسبات نرم به ویژه منطق فازی می‌توانند این پیچیدگی‌ها و ابهامات را

منابع (References)

"networks", Master of Science Thesis, Isfahan University of Technology (2005).

- Khashei, M. "Forecasting , analysis of esfahan steel company in tehran metals exchange using artificial neural
- Chen, D., Clements, K.W., Roberts, E.J. and et al.

- "Forecasting steel demand in china", *Resources Policy*, **17**, pp 196-210 (1991).
3. Labson, S., Gooday, P. and Manson, A. "China steel", China's Emerging Steel Industry and its Impact on the World Iron Ore and Steel Market (1995).
 4. Evans, M. and Walton, S. "Time series properties , forecasts of crude steel consumption in the UK", *Journal of Forecasting*, **16**, pp 47-63 (1997).
 5. Crompton, P. "Forecasting steel consumption in south-east asia", *Resources Policy*, **25**, pp. 111-123 (1999).
 6. Crompton, P. and Wu, Y. "Bayesian vector autoregression forecasts of chinese steel consumption", *Journal of Chinese Economic and Business Studies*, **1**, pp. 205-219 (2003).
 7. Zare Nezhad, M. and Anvari, E. "Prediction of iron and steel consumption of iran using panel data", *Journal of Applied Sciences*, **8**, pp. 364-368 (2008).
 8. Huh, K.-S. "Steel consumption and economic growth in korea: long-term and short-term evidence", *Resources Policy*, **36**, pp. 107-113 (2011).
 9. Yin, X. and Chen, W. "Trends and development of steel demand in china: a bottom-up analysis", *Resources Policy*, **38**, pp. 407-415 (2013).
 10. Malenbaum, "Material Requirements in the United State and Abroad in the Year 2000: A Research Project Prepared for the National Comission on Material in Materials Policy", (1974).
 11. Roberts, M. C. "Predicting metal consumption: the case of US steel", *Resources Policy*, **16**, pp. 56-73 (1990).
 12. Findlay, C.A. and Xin, L. "China iron and steel industry policy: implications for australia", *Posifc Economic Papers*, **127**, pp. (1995).
 13. Roberts, M. C. "Metal use and the world economy", *Resources Policy*, **22**, pp. 183-196 (1996).
 14. Zhang, X. "Forecasting steel demand in China in 2000: implications for China's iron and steel industry", University of Adelaide (1998).
 15. Shen, Y.G. "Forecasting Chinas Steel demand" Scientific reports in world steel association, Mimeo at www.iisi.org (1998).
 16. Crompton, P. "Future trends in japanese steel consumption", *Resources Policy*, **26**, pp. 103-114 (2000).
 17. Rebiasz, B. "Polish steel consumption, 1974-2008", *Resources Policy*, **31**, pp. 37-49 (2006).
 18. Warell, L. and Olsson, A. "Trends and developments in the intensity of steel use: an econometric analysis", Online at: <http://pure.ltu.se/portal/files/3157773/Paper.Pdf> (2009).
 19. Wrell, L."Trends and developments in long-term steel demand-the intensity-of-use hypothesis revisited", *Resources Policy*, **39**, pp. 134-143 (2014).
 20. Crompton, P. "Explaining variation in steel consumption in the OECD", *Resources Policy*, **45**, pp. 239-246 (2015).
 21. Guo, H. "Application of grey- model in the demand forecast of the steel product", Department of Industrial Engineering and Management, Shanghai Jiaotong University, Shangha (2007).
 22. Azadeh, A., Neshat, N., Mardan, E. and et al. "Optimization of steel demand forecasting with complex and uncertain economic inputs by an integrated neural network-fuzzy mathematical programming approach", *The International Journal of Advanced Manufacturing Technology*, **65**, pp. 833-841 (2013).
 23. Ma, W., Zhu, X. and Wang, M. "Forecasting iron ore import and consumption of china using grey model optimized by particle swarm optimization algorithm", *Resources Policy*, **38**, pp. 613-620 (2013).
 24. Evans, M. "An alternative approach to estimating the parameters of a generalised grey verhulst model: An application to steel intensity of use in the UK", *Expert Systems with Applications*, **41**, pp. 1236-1244 (2014).
 25. Weng, Y., Zhou, L., Zhou, S. and et al. "Research on china's steel demand using combined forecast", *International Journal of u-and e-Service, Science and Technology*, **8**, pp. 189-200 (2015).
 26. Zhang, G., Patuwo, B.E. and Hu, M.Y. "Forecasting with artificial neural networks: the state of the art", *International Journal of Forecasting*, **14**, pp. 35-62 (1998).
 27. Tanaka, H. "Fuzzy data analysis by possibilistic linear models", *Fuzzy Sets and Systems*, **24**, pp. 363-375 (1987).
 28. Khashei, M., Raissi, GH. and Bijari, M. "Forecasting the worldwide billet price using a hybrid auto regressive Integrated moving average models and fuzzy logic", *Steel Symposium*, **85**, pp. 1-12 (2007).
 29. Khashei, M., Mokhatab Rafiei, F., Bijari, M. and et al. "A hybrid computational intelligence model for foreign exchange rate forecasting", *International Journal of Industrial Engineering*, **7**, pp. 91-100 (2011).
 30. Khashei, M., Zeinal Hamadani, A. and Bijari, M. "A fuzzy intelligent approach to the classification problem in gene expression data analysis", *Knowledge- Based Systems*, **27**, pp. 465- 474 (2012).
 31. Khashei, M., Bijari, M. and Mokhatab Rafiei, F. "Foreign exchange rate forecasting using improved artificial neural networks in incompelet data", *Industrial Engineering Conference, 8th ICARD At, Skelleftea* (2012).
 32. Wong, B.K. and Selvi, Y. "Neural network applications in finance: a review and analysis of the literature ", *Information & Management*, **34**, pp. 129-139 (1998).
 33. Ishibuchi, H. and Tanaka ,H. "Interval regression analysis based on mixed integer programming problem", *J. Japan Soc. Ind. Eng.*, **40**(5) pp.319-312 (1988).
 34. Torbat, S. "Application of computational intelligent tools in irans steel consumption prediction", Master of Science Thesis, Isfahan University of Technology (2016).