

بهینه‌سازی هوشمند انرژی و کنترل تطبیقی کوره‌های قوس الکتریکی در صنعت فولاد با استفاده از دوقلوی

دیجیتال و شبکه‌های عصبی

سارا محمودی رشید*

مربی دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

چکیده

در این پژوهش، یک چارچوب نوین برای بهینه‌سازی مصرف انرژی و کنترل تطبیقی عملکرد کوره‌های قوس الکتریکی در صنعت فولاد ارائه شده است که بر پایه تلفیق دوقلوی دیجیتال و شبکه‌های عصبی تطبیقی طراحی گردیده است. هدف اصلی، کاهش مصرف انرژی، افزایش پایداری فرآیند و ارتقاء دقت کنترل در شرایط عملیاتی متغیر است. بدین منظور، ابتدا یک مدل دوقلوی دیجیتال از فرآیند ذوب فولاد توسعه یافته و به صورت برخط به روزرسانی شده است. سپس، از شبکه‌های عصبی تطبیقی برای تخمین غیرخطی دینامیک فرآیند و طراحی کنترل کننده بهره گرفته شد. پیاده‌سازی سیستم در محیط MATLAB/Simulink انجام شد و عملکرد آن در سناریوهای عملیاتی گوناگون ارزیابی گردید. نتایج شبیه‌سازی نشان می‌دهد که روش پیشنهادی موجب کاهش متوسط ۸/۷ درصدی مصرف انرژی، بهبود ۲۴/۳ درصدی در پاسخ گذرا و افزایش ۱۴/۱۲ درصدی دقت ردیابی توان نسبت به کنترل کننده‌های کلاسیک شده است. این دستاوردها حاکی از اثربخشی روش ارائه شده در بهبود بهره‌وری انرژی و پایداری فرآیندهای حرارتی در صنعت فولاد است و می‌تواند به عنوان الگویی برای پیاده‌سازی سیستم‌های هوشمند مشابه در سایر فرآیندهای صنعتی در نظر گرفته شود.

مقاله پژوهشی

تاریخ دریافت:

۱۴۰۴/۰۲/۲۶

تاریخ پذیرش:

۱۴۰۴/۰۷/۰۸

کلیدواژه‌ها:

هوش مصنوعی صنعتی، کوره قوس الکتریکی، بهینه‌سازی مصرف انرژی، کنترل تطبیقی، شبکه عصبی یادگیرنده، بهره‌وری در صنعت فولاد

نویسنده مسئول:

s.mahmoudirashid@tabrizu.ac.ir

doi : 10.22034/ABMIR.2025.23151.1128

E-ISSN: [2821-2037](#)

/© 2025. Published by Yazd University This is an open access article

under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).



۱- مقدمه

صنعت فولاد یکی از پرمصرف‌ترین بخش‌های صنعتی از نظر انرژی به‌شمار می‌رود، به‌ویژه در فرآیندهای حرارتی مانند کوره‌های قوس الکتریکی که نقش کلیدی در ذوب و بازیافت فولاد دارند [۱].

۲- پیشینه و انگیزه پژوهش

با توجه به افزایش قیمت انرژی و الزامات زیست‌محیطی، کاهش مصرف انرژی و ارتقاء بهره‌وری فرآیندهای تولیدی به یکی از اولویت‌های راهبردی شرکت‌های فولادی تبدیل شده است [۲]. در سال‌های اخیر، پیشرفت‌های سریع در حوزه هوش مصنوعی صنعتی و فناوری‌های دیجیتال، بستر جدیدی برای کنترل و بهینه‌سازی فرآیندهای پیچیده فراهم کرده‌اند [۳].

دوقلوی دیجیتال به‌عنوان نمایه‌ای مجازی از یک سیستم فیزیکی، امکان شبیه‌سازی دقیق، پایش بلادرنگ و به‌روزرسانی مستمر مدل‌های فرآیند را فراهم می‌سازد [۴]. از سوی دیگر، شبکه‌های عصبی تطبیقی به دلیل توانایی بالا در مدل‌سازی سیستم‌های غیرخطی و یادگیری از داده‌های جاری، ابزار قدرتمندی برای طراحی کنترل‌کننده‌های هوشمند محسوب می‌شوند [۵]. با این حال، تلفیق این دو فناوری نوظهور در محیط‌های صنعتی پیچیده مانند کوره‌های قوس الکتریکی هنوز در مراحل ابتدایی قرار دارد و نیازمند پژوهش‌های کاربردی و نظام‌مند است [۶].

در این پژوهش، با بهره‌گیری از توانمندی‌های دوقلوی دیجیتال در مدل‌سازی بلادرنگ و شبکه‌های عصبی در کنترل غیرخطی، یک چارچوب نوآورانه برای کنترل تطبیقی و بهینه‌سازی مصرف انرژی در کوره‌های قوس الکتریکی ارائه شده است. هدف از این تحقیق، ارائه راهکاری عملی برای افزایش بهره‌وری، کاهش هزینه‌های انرژی و تقویت پایداری در صنعت فولاد از طریق پیاده‌سازی فناوری‌های نسل چهارم صنعت است.

۳- بررسی ادبیات

کوره‌های قوس الکتریکی به‌عنوان یکی از اصلی‌ترین تجهیزات در فرآیند ذوب فولاد، نقش بسزایی در بازدهی انرژی و پایداری زیست‌محیطی صنعت فولاد ایفا می‌کنند [۷]. با این حال، ماهیت دینامیکی، غیرخطی و متغیرپذیر عملکرد کوره‌های قوس الکتریکی باعث شده است که کنترل بهینه آن به چالشی جدی در حوزه مهندسی فرآیند تبدیل شود [۸]. در دهه گذشته، پژوهش‌های متعددی به منظور بهبود عملکرد این کوره‌ها از منظر مصرف انرژی، کنترل توان ورودی و ثبات فرآیند انجام شده است [۹]. بسیاری از این مطالعات از الگوریتم‌های کلاسیک کنترل مانند PID^۱ یا روش‌های بهینه‌سازی خطی بهره گرفته‌اند [۱۰]؛ اما این رویکردها معمولاً در مواجهه با شرایط عملیاتی متغیر و اغتشاشات محیطی، کارایی محدودی از خود نشان داده‌اند [۱۱].

در سال‌های اخیر، کاربرد روش‌های هوش مصنوعی به‌ویژه شبکه‌های عصبی مصنوعی در مدل‌سازی و کنترل فرآیندهای صنعتی رشد چشمگیری داشته است [۱۲]. برخی مطالعات از شبکه‌های عصبی مصنوعی برای پیش‌بینی مصرف انرژی یا طراحی کنترل‌کننده‌های پیش‌بین استفاده کرده‌اند [۱۳]. همچنین، مفهوم دوقلوی دیجیتال به‌عنوان ابزاری نوین برای شبیه‌سازی بلادرنگ و تصمیم‌گیری داده‌محور، مورد توجه صنایع پیشرفته قرار گرفته است [۱۴]. با این حال، مرور منابع موجود نشان می‌دهد که ادغام سیستماتیک دوقلوی دیجیتال با ساختارهای کنترل تطبیقی مبتنی بر یادگیری عصبی، به‌ویژه در زمینه بهینه‌سازی کوره‌های قوس الکتریکی، کمتر مورد بررسی قرار گرفته است [۱۵].

در این پژوهش، با شناسایی این خلأ، یک رویکرد ترکیبی مبتنی بر دوقلوی دیجیتال و شبکه‌های عصبی تطبیقی ارائه شده است تا با بهره‌گیری از ظرفیت‌های مدل‌سازی بلادرنگ و یادگیری داده‌محور، کنترل و بهینه‌سازی مصرف انرژی در کوره‌های قوس الکتریکی به‌شکلی مؤثر و پایدار تحقق یابد. مطالعات متعددی نشان داده‌اند که استفاده از شبکه‌های عصبی مصنوعی می‌تواند به بهبود دقت مدل‌سازی دینامیک فرآیندهای حرارتی مانند کوره‌های قوس الکتریکی کمک کند [۱۶]. برای مثال، پژوهش‌هایی از اوایل دهه

^۱ Proportional-integral-derivative

فراهم کرده‌اند [۲۰].

کاربرد دوقلوی دیجیتال در صنعت فولاد یکی از زمینه‌های نوظهور در تحول دیجیتال به شمار می‌رود [۲۱]. پژوهش‌های اخیر نشان داده‌اند که ایجاد مدل مجازی هم‌زمان از کوره‌های صنعتی می‌تواند منجر به تحلیل بلادرنگ، پیش‌بینی خطا و بهینه‌سازی مصرف انرژی شود [۲۲]. گرچه هر دو حوزه دوقلوی دیجیتال و کنترل هوشمند به‌صورت جداگانه توسعه یافته‌اند، اما پژوهش‌های محدودی به تلفیق این دو فناوری پرداخته‌اند [۲۳]. برخی مطالعات اولیه در زمینه سیستم‌های تهویه صنعتی یا نیروگاه‌ها نشان داده‌اند که ترکیب دوقلوی دیجیتال با کنترل‌کننده‌های تطبیقی مبتنی بر شبکه عصبی مصنوعی یا منطق فازی می‌تواند اثربخشی بالایی در مدیریت بهینه مصرف انرژی داشته باشد [۲۴].

برخی پژوهش‌ها، مصرف انرژی در کوره‌های قوس الکتریکی را تا بیش از ۶۰٪ کل انرژی فرآیند فولادسازی برآورد کرده‌اند [۲۵]. تلاش‌های گسترده‌ای برای بهینه‌سازی این بخش انجام شده است، از جمله طراحی برنامه‌های کنترل بار هوشمند، تنظیم توالی ذوب و بهینه‌سازی نقطه کاری ولتاژ و جریان کوره [۲۶].

از دیدگاه عملی، ادغام سیستماتیک دوقلوهایی دیجیتال با کنترل تطبیقی مبتنی بر شبکه عصبی در کوره‌های قوس الکتریکی با مجموعه‌ای از چالش‌های ذاتی همراه است که اهمیت و نوآوری این رویکرد را برجسته می‌سازد. نخست آنکه، کوره‌های قوس الکتریکی ماهیتی بسیار غیرخطی، پویا و وابسته به شرایط عملیاتی متغیر دارند و مدل‌سازی دقیق آن‌ها نیازمند در نظر گرفتن اثرات پیچیده‌ای مانند اغتشاشات ناشی از تغییر ترکیب قراضه و نوسانات قوس است. این مسئله سبب می‌شود که پیاده‌سازی یک دوقلوی دیجیتال دقیق و همگام‌سازی آن با واقعیت فیزیکی، فرآیندی دشوار و زمان‌بر باشد. دوم، چالش‌های جمع‌آوری داده در این محیط صنعتی قابل توجه است؛ چرا که سنسورها در معرض دمای بسیار بالا، میدان‌های الکترومغناطیسی شدید و شرایط سخت کاری قرار دارند که می‌تواند دقت و پایداری داده‌ها را تحت تأثیر قرار دهد. سوم، کنترل تطبیقی مبتنی بر شبکه عصبی برای آنکه بتواند عملکردی اثربخش داشته باشد، نیازمند داده‌های بلادرنگ با کیفیت

۲۰۱۰ به کارگیری ساختارهای شبکه عصبی چندلایه پرسپترون و شبکه تابع پایه شعاعی را برای شناسایی رفتار حرارتی غیرخطی در محیط‌های صنعتی پیشنهاد داده‌اند که در مقایسه با مدل‌های مبتنی بر فیزیک، دقت بالاتری داشته‌اند [۱۷].

شبکه MLP به دلیل ساختار لایه‌های عمیق و قابلیت یادگیری روابط پیچیده، توانایی بالایی در تقریب توابع غیرخطی با دقت زیاد دارد؛ با این حال، فرآیند آموزش آن معمولاً زمان‌بر بوده و در برخی شرایط به‌ویژه در حضور داده‌های نویزی، ممکن است به کمینه‌های محلی همگرا شود. در مقابل، شبکه RBF^1 استفاده از توابع شعاعی به‌عنوان واحدهای مخفی، از سرعت همگرایی بالاتر و سادگی در آموزش برخوردار است و می‌تواند در تقریب نواحی محلی از داده عملکرد بسیار مطلوبی داشته باشد؛ اما نقطه ضعف اصلی آن در مدل‌سازی رفتارهای بسیار غیرخطی و گسترده نهفته است.

ترکیب این دو ساختار، موسوم به $MLP-RBF^2$ ، باعث می‌شود که مزایای هر دو شبکه به‌طور مکمل در یک چارچوب واحد به کار گرفته شوند. در این رویکرد، RBF نقش تقویت سرعت همگرایی و افزایش پایداری آموزش در نواحی محلی را بر عهده دارد، در حالی که MLP مسئولیت تعمیم‌پذیری و یادگیری الگوهای پیچیده‌تر غیرخطی در مقیاس کلی را ایفا می‌کند. نتیجه این هم‌افزایی، مدلی است که هم از دقت بالا در تقریب رفتار غیرخطی سیستم برخوردار است، هم از نظر سرعت و کارایی محاسباتی عملکرد بهتری دارد. این ویژگی‌ها به‌ویژه در محیط‌های صنعتی پویا مانند کوره‌های قوس الکتریکی، که هم رفتارهای محلی و هم دینامیک‌های پیچیده در آن‌ها وجود دارد، اهمیت زیادی پیدا می‌کند.

روش‌های کنترل تطبیقی با بهره‌گیری از الگوریتم‌های یادگیری، در سال‌های اخیر جایگزین مناسبی برای کنترل‌کننده‌های کلاسیک در شرایط متغیر شده‌اند [۱۸]. به‌ویژه، ساختارهایی مانند کنترل عصبی-تطبیقی و کنترل مبتنی بر یادگیری تقویتی در محیط‌های صنعتی غیرخطی نتایج چشمگیری داشته‌اند [۱۹]. این رویکردها امکان تنظیم پیوسته پارامترهای کنترل در شرایط کاری متغیر را

^۲ Multilayer perceptron- Radial basis function

^۱ Radial basis function

نتایج این پژوهش نه تنها نشان‌دهنده امکان‌پذیری و اثربخشی تلفیق فناوری‌های نوین مانند دوقلوی دیجیتال و یادگیری ماشین در صنعت فولاد است، بلکه الگویی عملی برای سایر صنایع انرژی‌بر در مسیر تحول دیجیتال و هوشمندسازی فراهم می‌سازد.

۴- فرمول‌بندی مسئله

در این بخش، به صورت نظام‌مند به تعریف مسئله اصلی پژوهش پرداخته می‌شود و چارچوب مفهومی آن به‌طور دقیق تشریح خواهد شد. چالش اساسی در این تحقیق، طراحی یک سامانه هوشمند برای کنترل تطبیقی و بهینه‌سازی مصرف انرژی در کوره‌های قوس الکتریکی است که قادر باشد در مواجهه با شرایط دینامیکی و متغیر فرآیند، عملکردی پایدار، دقیق و کارآمد از خود نشان دهد. با توجه به ماهیت پیچیده، غیرخطی و وابسته به زمان این نوع سیستم‌های حرارتی، بهره‌گیری از روش‌های سنتی کنترلی دیگر پاسخگوی نیازهای بهره‌وری و پایداری در صنعت فولاد نیست. از این‌رو، یک مدل دقیق از فرآیند به‌عنوان پایه طراحی کنترل‌کننده مورد نیاز است، که در این مقاله، با استفاده از مفهوم دوقلوی دیجیتال و شبکه‌های عصبی تطبیقی، این مدل توسعه‌یافته و در ادامه، راهکار پیشنهادی بر اساس آن پیاده‌سازی و ارزیابی می‌شود.

۴-۱ مدل دینامیکی فرآیند ذوب در کوره قوس الکتریکی

فرآیند ذوب در کوره قوس الکتریکی به دلیل نوسانات ولتاژ، تغییر بار حرارتی و رفتار غیرخطی الکترودها، به عنوان یک سیستم پیچیده غیرخطی شناخته می‌شود. مدل دینامیکی پایه‌شده بر روی معادلات انرژی و الکتریکی قابل بیان به صورت (۱) است:

$$\frac{dT(t)}{dt} C = \eta \cdot P(t) - Q_{\text{loss}}(t) \quad (1)$$

که در آن $T(t)$ دمای لحظه‌ای فلز (C, C^0) ظرفیت گرمایی معادل سیستم (J/C^0) ، η بازده انتقال حرارت، $P(t)$ توان ورودی از کوره (W) ، $Q_{\text{loss}}(t)$ تلفات حرارتی به محیط (W) است. برای مدل‌سازی تلفات، از رابطه (۲) استفاده می‌شود:

$$Q_{\text{loss}}(t) = hA(T(t) - T_{\text{amb}}) \quad (2)$$

بالا و پردازش سریع است؛ در حالی که سرعت بالای دینامیک کوره، محدودیت‌های پردازشی سخت‌گیرانه‌ای را به همراه دارد. در نهایت، موضوع ادغام بلادرنگ میان مدل دیجیتال و سیستم کنترل نیز یک چالش اساسی است؛ زیرا هرگونه تأخیر در انتقال یا پردازش داده می‌تواند موجب کاهش اثربخشی و حتی بروز ناپایداری در سیستم شود. این موانع، در کنار پتانسیل بالای بهبود بهره‌وری انرژی و افزایش عمر تجهیزات، نشان می‌دهند که ترکیب دوقلوی دیجیتال با کنترل تطبیقی مبتنی بر شبکه عصبی در حوزه کوره‌های قوس الکتریکی نه تنها یک مسیر نوآورانه، بلکه ضرورتی برای پیشرفت آینده صنعت فولاد محسوب می‌شود.

۳-۱ شکاف‌ها و مشارکت‌های پژوهشی

با وجود پیشرفت‌های قابل‌توجه در استفاده از الگوریتم‌های هوش مصنوعی برای بهبود عملکرد فرآیندهای صنعتی، همچنان چالش‌هایی اساسی در زمینه مدل‌سازی دقیق، کنترل تطبیقی و کاهش مصرف انرژی در کوره‌های قوس الکتریکی باقی‌مانده است. بسیاری از روش‌های مرسوم کنترل، توانایی لازم برای مدیریت شرایط دینامیکی متغیر و نوسانات شدید بار در فرآیند ذوب را ندارند. همچنین، رویکردهای مبتنی بر شبکه‌های عصبی غالباً فاقد قابلیت به‌روزرسانی بلادرنگ و سازگاری با شرایط واقعی عملیاتی هستند. مشارکت‌های کلیدی این پژوهش به شرح زیر است:

- ارائه یک چارچوب یکپارچه بر پایه دوقلوی دیجیتال و شبکه‌های عصبی تطبیقی برای مدل‌سازی و کنترل فرآیند ذوب فولاد به‌صورت بلادرنگ، که قادر است شرایط متغیر و غیرخطی سیستم را با دقت بالا شبیه‌سازی و کنترل نماید.
- طراحی کنترل‌کننده تطبیقی هوشمند مبتنی بر یادگیری مستمر که توانایی سازگاری با تغییرات لحظه‌ای در فرآیند را داراست و عملکرد بهتری نسبت به روش‌های کلاسیک از خود نشان می‌دهد.
- به‌کارگیری ساختارهای ترکیبی شبکه عصبی چندلایه پرسپترون و شبکه تابع پایه شعاعی در فرآیند مدل‌سازی و کنترل، به‌گونه‌ای که مزایای دقت بالا، سرعت همگرایی مطلوب و توانایی تقریب رفتار غیرخطی سیستم به‌طور هم‌زمان محقق گردد.

که در آن $u(i)$ همان بردار ورودی‌های واقعی است که توسط حسگرها در فرآیند عملیاتی ثبت شده و θ پارامترهای قابل تنظیم مدل (مانند بازدهی‌ها و ضرایب انتقال حرارت) است.

به‌منظور انطباق مدل با داده‌های واقعی، یک فیلتر تطبیقی برخط به‌کار گرفته می‌شود که با کمینه‌سازی تابع خطای پیش‌بینی، پارامترهای مدل را توسط معادله (۶) به‌روزرسانی می‌کند:

$$J(\theta) = \sum_{i=1}^N (T_{\text{meas}}(i) - T_{\text{pred}}(i; \theta))^2 \quad (6)$$

که در آن θ پارامترهای بهینه مدل، T_{meas} دمای واقعی اندازه‌گیری شده، T_{pred} خروجی مدل پیش‌بینی شده توسط دوقلوی دیجیتال است. در این حالت، الگوریتم بهینه‌سازی (مانند گرادینت کاهشی یا فیلتر تطبیقی کالمن) پارامترهای θ را به‌گونه‌ای تنظیم می‌کند که اختلاف بین دمای واقعی و دمای شبیه‌سازی شده حداقل شود.

۳-۴ طراحی شبکه عصبی تطبیقی برای مدل‌سازی معکوس فرآیند

برای تخمین معکوس رفتار غیرخطی سیستم و پیش‌بینی توان ورودی به‌ازای دمای هدف، از شبکه عصبی ترکیبی MLP-RBF شبکه عصبی چندلایه پرسپترون و شبکه تابع پایه شعاعی معادله (۷) استفاده می‌شود:

$$P_{\text{est}}(t) = f_{\text{MLP}}\left(T(t), \frac{dT(t)}{dt}, T_{\text{ref}}(t)\right) + f_{\text{RBF}}(T(t)) \quad (7)$$

که f_{MLP} بخش یادگیرنده با ساختار پرسپترون چندلایه، تابع تقریب موضعی با گره‌های شعاعی، $T_{\text{ref}}(t)$ دمای مرجع هدف‌گذاری شده است. ترکیب این دو ساختار، هم دقت بالا و هم توانایی تطبیق سریع در شرایط متغیر را تضمین می‌کند.

۴-۴ طراحی کنترل‌کننده تطبیقی مبتنی بر مدل شبکه عصبی

بر اساس مدل به‌دست‌آمده، کنترل‌کننده‌ای طراحی می‌شود که خروجی مطلوب T_{ref} را با کمترین مصرف انرژی دنبال کند. سیگنال کنترلی به‌صورت تطبیقی (۸) به‌روزرسانی می‌شود:

که در آن h ضریب انتقال حرارت، A سطح مؤثر و T_{amb} دمای محیط است.

۲-۴ ساخت دوقلوی دیجیتال

یک دوقلوی دیجیتال به‌صورت مدل دینامیکی مجازی از فرآیند واقعی ساخته می‌شود که بتواند در زمان واقعی تطابق خود را با سیستم اصلی حفظ کند. در سیستم کوره قوس الکتریکی نمی‌توان صرفاً با داده‌های خروجی به دقت مدل اطمینان کرد، بلکه ورودی‌های فرآیند نیز باید به‌طور دقیق اندازه‌گیری و در مدل شبیه‌سازی شده لحاظ شوند تا تابع هزینه معنای واقعی خود را پیدا کند. در این تحقیق، برای ایجاد انطباق بین دوقلوی دیجیتال و فرآیند واقعی ورودی‌های اصلی کوره قوس الکتریکی به صورت بردار ورودی (۳) در نظر گرفته شده‌اند:

$$u(i) = \begin{bmatrix} P_{\text{el}}(i) \\ m_{\text{scrap}}(i) \\ m_{\text{oxy}}(i) \\ m_{\text{coal}}(i) \\ Q_{\text{cool}}(i) \end{bmatrix} \quad (3)$$

که در آن $P_{\text{el}}(i)$ توان الکتریکی تزریق‌شده به کوره در لحظه i بر حسب (MW)، $m_{\text{scrap}}(i)$ جرم شارژ قراضه فلزی در هر سیکل (بر حسب تن)، $m_{\text{oxy}}(i)$ میزان تزریق اکسیژن (Nm^3/min)، $m_{\text{coal}}(i)$ میزان تزریق کربن جانبی (kg/min)، $Q_{\text{cool}}(i)$ میزان خنک‌کاری آب یا سیال در دیواره‌ها (kW) یا (kJ/min). مدل دوقلوی دیجیتال بر اساس یک معادله موازنه انرژی دینامیکی به‌صورت (۴) بیان شده است:

$$C_{\text{eq}} \frac{dT_{\text{pred}}(t)}{dt} = \eta_{\text{el}} P_{\text{el}}(t) + \eta_{\text{oxy}} H_{\text{oxy}}(m_{\text{oxy}}(t)) + \eta_{\text{coal}} H_{\text{coal}}(m_{\text{coal}}(t)) - Q_{\text{loss}}(T_{\text{pred}}(t), Q_{\text{cool}}(t)) \quad (4)$$

که در آن C_{eq} ظرفیت گرمایی مؤثر بار در کوره، η_{el} ، η_{oxy} ، η_{coal} ضرایب بازدهی ورودی‌های الکتریکی، اکسیژن و کربن، H_{oxy} انرژی شیمیایی آزادشده از واکنش‌های اکسیژن و کربن، H_{coal} اتلاف حرارتی وابسته به دمای بار و نرخ خنک‌کاری. دمای پیش‌بینی شده مدل دیجیتال در گام i برابر است با رابطه (۵):

$$T_{\text{pred}}(i; \theta) = f(u(i), \theta) \quad (5)$$

۴-۳-۴ قید وابستگی ضرایب (کاهش درجه آزادی)

برای جلوگیری از عدم تشخیص ضرایب، قیود (۱۳) اعمال می‌شود:

$$\alpha(t) \geq 0, \beta(t) \geq 0, \gamma(t) \geq 0, \quad (13)$$

$$\alpha(t) + \beta(t) + \gamma(t) = 1$$

بدین ترتیب فقط دو پارامتر مستقل تنظیم می‌شوند و سومی از قید جمع به دست می‌آید (آنالوگ «یک منهای ضریب» در حالت دوعبارتی).

۴-۵-۵ تعریف تابع هدف چندمعیاره

هدف کنترل‌کننده نه تنها رسیدن به دمای مطلوب بلکه بهینه‌سازی مصرف انرژی و حفظ پایداری حرارتی در برابر اغتشاشات محیطی است. بنابراین، یک تابع هدف چندمعیاره به صورت (۱۴) تعریف می‌شود:

$$J(\theta) = w_1 \cdot e_T^2(t) + w_2 \cdot \Delta u^2(t) + w_3 \cdot \left(\frac{dT(t)}{dt} \right)^2 \quad (14)$$

که در آن $e(t) = T_{ref}(t) - T(t)$ خطای دمایی،

$$u(t) - u(t-1)$$

نرخ تغییرات دما به عنوان معیار پایداری و ضرایب w_1, w_2, w_3

و w_3 وزن‌دهی اهداف مختلف سیستم هستند.

ضرایب w_1, w_2, w_3 نمی‌توانند کاملاً مستقل از یکدیگر تنظیم شوند، زیرا این امر منجر به بیش‌پارامتری می‌شود. برای رفع این مشکل، قید (۱۵) اعمال می‌شود:

$$w_1 \geq 0, w_2 \geq 0, w_3 \geq 0, w_1 + w_2 + w_3 = 1 \quad (15)$$

در نتیجه، تنها دو ضریب مستقل باقی می‌مانند و ضریب سوم به‌طور خودکار از رابطه بالا محاسبه می‌شود. برای پیاده‌سازی عملی، دو روش متداول وجود دارد:

پارامترسازی Softmax توسط (۱۶):

$$w_1 = \frac{e^a}{e^a + e^b + e^c}, \quad w_2 = \frac{e^b}{e^a + e^b + e^c}, \quad w_3 = \frac{e^c}{e^a + e^b + e^c} \quad (16)$$

که در آن $(a, b, c) \in \mathbb{R}$ متغیرهای بدون قید هستند و ضرایب همیشه نرمال و نامنفی باقی می‌مانند.

▪ پروژکشن روی سیمپلکس:

$$u(t) = \alpha u(t-1) + \beta \cdot (T_{ref}(t) - T(t)) \quad (8)$$

$$+ \gamma \cdot \frac{d}{dt}(T_{ref}(t) - T(t))$$

که ضرایب α, β و γ به صورت برخط و با استفاده از گرادینت کاهش خطا به‌روزرسانی می‌شوند:

$$\theta(t+1) = \theta(t) - \eta \cdot \nabla_{\theta} J(\theta) \quad (9)$$

۴-۱-۴ به‌روزرسانی برخط

منظور از به‌روزرسانی برخط آن است که ضرایب کنترلی رابطه (۴) در هر گام نمونه‌برداری، همزمان با ورود داده‌های جدید اندازه‌گیری شده از کوره، بازتنظیم می‌شوند؛ یعنی بدون توقف فرایند و بر مبنای داده‌های جاری رابطه (۱۰):

$$u(t) = \alpha(t)u(t-1) + \beta(t)e(t) + \gamma(t)\dot{e}(t), \quad (10)$$

$$e(t) = T_{ref}(t) - T(t)$$

در این‌جا $\dot{e}(t)$ مشتق خطا است که با یک مشتق‌گیر فیلترشده توسط معادله (۱۱) محاسبه می‌شود:

$$\dot{e}(t) = (1-\lambda)\dot{e}(t-1) + \lambda \frac{e(t) - e(t-1)}{\Delta t}, \quad (11)$$

$$0 < \lambda < 1$$

۴-۲-۴ گردآوری و همگام‌سازی داده

داده‌ها در افق زمانی $\{t_k\}_{k=1}^N$ با دوره نمونه‌برداری Δt جمع‌آوری می‌شوند:

- دما $T(t_k)$: از پایرومتر نوری/ترموکوپل‌های تماس‌پذیر (رزولوشن 1°C و خطای کالیبراسیون $\pm 0.5\%$).
- توان لحظه‌ای $P(t_k)$ (خروجی مبدل/ترانس): از پاورآنالایزر (رزولوشن 0.1 MW).
- دبی اکسیژن/مواد افزودنی: از فلومترهای جرمی (برای دوقلو دیجیتال و اعتبارسنجی).

برای حذف نویز اندازه‌گیری، از میانگین متحرک درجه ۳ مطابق رابطه (۱۲) استفاده می‌کنیم:

$$\tilde{T}(t_k) = \frac{1}{3}(T(t_k) + T(t_{k-1}) + T(t_{k-2})) \quad (12)$$

و سپس $\tilde{e}(t_k) = T_{ref}(t_k) - \tilde{T}(t_k)$ مبنای قانون تطبیق قرار می‌گیرد. برچسب زمانی یکسان موجب همگام‌سازی کانال‌ها می‌شود تا $u, \dot{e}, e$ در یک t قابل اتکا باشند.

عملگرهای انتخاب، جهش و تقاطع، به صورت تکراری مقادیر بهینه ضرایب را پیدا می‌کند. معیار توقف الگوریتم رسیدن به حداقل خطا یا تعداد مشخصی نسل تکرار است.

۴-۶ مدل بهبود یافته تخمین نرخ تغییرات انرژی در فرآیند

برای در نظر گرفتن اثر دینامیک انتقال انرژی درون کوره، مدل انرژی بهبود یافته‌ای به کار می‌رود که نرخ تغییر انرژی تجمعی را توسط (۱۹) شامل می‌شود:

$$\frac{dE_{\text{totd}}(t)}{dt} = \eta \cdot P(t) - (hA(T(t) - T_{\text{amb}}) + R \cdot I^2(t)) \quad (19)$$

در اینجا $E_{\text{total}}(t)$ انرژی تجمع یافته در فرآیند ذوب، R مقاومت الکتریکی مسیر جریان، $I(t)$ جریان ورودی لحظه‌ای به الکترودها است. این مدل اجازه می‌دهد رفتار حرارتی سیستم با دقت بیشتری تخمین زده شده و برای پیش‌بینی دقیق‌تر مصرف انرژی استفاده شود.

۴-۷ به‌روزرسانی تطبیقی ضرایب کنترل‌کننده با استفاده از قانون یادگیری

برای بهبود انعطاف‌پذیری در برابر تغییرات فرآیندی، ضرایب کنترل‌کننده به صورت تطبیقی و با استفاده از قانون یادگیری مبتنی بر گرادینت خطا (۲۰) اصلاح می‌شوند:

$$\frac{d\theta_i(t)}{dt} = -\lambda \cdot \frac{\partial J(t)}{\partial \theta_i(t)} \quad (20)$$

که در آن θ_i شامل ضرایب α ، β و γ کنترل‌کننده است. λ نرخ یادگیری و $\frac{\partial J(t)}{\partial \theta_i(t)}$ مشتق تابع هزینه نسبت به هر پارامتر است.

۴-۸ معیار پایداری با استفاده از تابع لیپانوف

برای تضمین پایداری سیستم در برابر اغتشاشات و تغییرات مدل، تابع لیپانوف (۲۱) تعریف می‌شود:

$$V(t) = \frac{1}{2} e_T^2(t) + \frac{1}{2} \sum_i (\theta_i(t) - \theta_i^*)^2 \quad (21)$$

و با اطمینان از اینکه مشتق آن منفی مطابق (۲۲) باشد:

پس از هر گام به‌روزرسانی ضرایب با روش گرادینت، بردار $\theta = [w_1, w_2, w_3]^T$ روی مجموعه $S = \{\theta \in \mathbb{R}^3 \mid \theta \geq 0, 1^T \theta = 1\}$ پرتاب می‌شود.

در اصل، مسئله کنترلی ماهیت چندهدفه دارد، زیرا کمینه‌سازی خطای دما، کاهش تلاش کنترلی و تضمین پایداری حرارتی اهدافی متعارض هستند. برای حل عملی، از روش اسکالاری‌سازی استفاده می‌شود که مسئله چندهدفه را به یک تابع تک‌هدفه وزن‌دار تبدیل می‌کند. این کار امکان استفاده از روش‌های کلاسیک کنترل تطبیقی و بهینه‌سازی مانند گرادینت کاهشی و کنترل پیش‌بین مدل را فراهم می‌سازد.

ضرایب w_1, w_2, w_3 به صورت تجربی یا با روش‌های بهینه‌سازی (مانند الگوریتم ژنتیک) تعیین می‌شوند. به طور مشخص، در الگوریتم ژنتیک یک تابع هدف تعریف می‌شود که میزان خطا یا اختلاف بین مقادیر واقعی (به‌دست آمده از اندازه‌گیری یا شبیه‌سازی) و مقادیر تخمینی (محاسبه شده توسط مدل پیشنهادی) را ارزیابی می‌کند. هدف اصلی این است که ضرایب به گونه‌ای انتخاب شوند که این اختلاف حداقل شود. تابع برازش مورد استفاده به شکل (۱۷) تعریف شد:

$$J = \sum_{k=1}^N \left(y_{\text{measured}}(k) - y_{\text{estimated}}(k; \alpha_1, \alpha_2, \alpha_3) \right)^2 \quad (17)$$

که در آن:

- $y_{\text{measured}}(k)$ داده واقعی یا مرجع در لحظه k است،
- $y_{\text{estimated}}(k; \alpha_1, \alpha_2, \alpha_3)$ خروجی مدل پیشنهادی با ضرایب $\alpha_1, \alpha_2, \alpha_3$
- N تعداد کل نمونه‌های داده،
- $\alpha_1, \alpha_2, \alpha_3$ ضرایب وزنی مورد نظر.

با توجه به محدودیت وابستگی بین ضرایب، شرط (۱۸) نیز در فرآیند بهینه‌سازی اعمال می‌شود:

$$\alpha_1 + \alpha_2 + \alpha_3 = 1, \alpha_i \geq 0 \quad (18)$$

بنابراین، عملاً تنها دو ضریب مستقل هستند و ضریب سوم به صورت خودکار از رابطه بالا تعیین می‌شود. الگوریتم ژنتیک با ایجاد جمعیتی اولیه از ضرایب، محاسبه مقدار تابع J و استفاده از

که در آن η نرخ یادگیری اصلی، ξ نرخ اصلاح ناشی از عدم تطابق بین دوقلوی دیجیتال و فرآیند واقعی است. این اصلاح موجب همگرایی سریع‌تر و دقت بالاتر شبکه در تخمین مدل می‌شود.

۴-۱۲ طراحی کنترل‌کننده بر پایه شبکه عصبی پیش‌بینی‌کننده

خروجی کنترل به صورت پیش‌بینی‌شده برای چند مرحله آینده (۲۶) محاسبه می‌شود:

$$u(t) = \arg \min_u \sum_{k=1}^{N_p} (T_{ref}(t+k) - T_{NN}(t+k | t))^2 + \lambda \sum_{k=1}^{N_c} (\Delta u(t+k-1))^2 \quad (26)$$

که در آن N_p افق پیش‌بینی، N_c افق کنترل، $T_{NN}(t+k | t)$ دمای پیش‌بینی‌شده توسط شبکه عصبی و $\Delta u(t)$ تغییرات سیگنال کنترلی است. این ساختار مشابه کنترل پیش‌بین مدل عمل می‌کند اما با از شبکه عصبی تطبیقی به جای مدل ریاضی صریح بهره‌گیری می‌کند.

۴-۱۳ ترکیب کنترل‌کننده با دوقلوی دیجیتال به منظور بهبود قابلیت اطمینان

جهت افزایش اعتمادپذیری در تصمیمات کنترلی، دوقلوی دیجیتال به عنوان بلوک بازخورد برای بررسی صحت تصمیمات کنترلی وارد حلقه (۲۷) می‌شود:

$$\text{If } |T_{DT}(t+1 | u(t)) - T_{pred}(t+1)| > \delta, \text{ then } u(t) \leftarrow u(t) - \epsilon \cdot \text{sign}(e_T(t)) \quad (27)$$

در این رابطه δ آستانه مجاز اختلاف پیش‌بینی، ϵ ضریب تنظیم تدریجی کنترلی و T_{pred} خروجی پیش‌بینی اولیه کنترل‌کننده است. این مکانیسم به تصمیم‌گیرنده اجازه می‌دهد تا کنترل را با توجه به بازخورد دوقلوی دیجیتال تصحیح کرده و از اشتباهات ناشی از مدل‌سازی جلوگیری کند.

۴-۱۴ تحلیل پیچیدگی محاسباتی

در ارزیابی روش پیشنهادی، پیچیدگی محاسباتی هر مرحله تحلیل و با روش‌های مقایسه‌ای سنجیده شد. الگوریتم پیشنهادی شامل

$$\frac{dV(t)}{dt} \leq 0 \quad (22)$$

می‌توان نشان داد که سیستم به صورت مجانبی پایدار است و در صورت وجود اغتشاش، پاسخ از نوسان بیش‌ازحد محافظت می‌شود.

۴-۹ ارتباط دوقلوی دیجیتال با کنترلر در حلقه بسته

دوقلوی دیجیتال نه تنها برای شبیه‌سازی، بلکه در حلقه بسته برای تصحیح خطای مدل و ارسال پیش‌بینی‌های اصلاح‌شده به کنترل‌کننده مورد استفاده (۲۳) قرار می‌گیرد:

$$u_{corr}(t) = u_{NN}(t) + \kappa \cdot (T_{meas}(t) - T_{DT}(t)) \quad (23)$$

که در آن $u_{NN}(t)$ خروجی اولیه شبکه عصبی، $T_{DT}(t)$ دمای تخمین‌زده‌شده توسط دوقلوی دیجیتال و κ ضریب تطبیق برای اصلاح کنترل است.

۴-۱۰ ساختار شبکه عصبی تطبیقی

در این پژوهش، یک شبکه عصبی چندلایه با توانایی یادگیری برخط به منظور تقریب دینامیک ناشناخته سیستم در نظر گرفته شده است. ساختار کلی شبکه به صورت (۲۴) تعریف می‌شود:

$$y_{NN}(t) = \sum_{i=1}^n w_i(t) \cdot \sigma \left(\sum_{j=1}^m v_{ij}(t) \cdot x_j(t) \right) \cdot b_i \quad (24)$$

که در آن $x_j(t)$ ورودی‌های شبکه (شامل دما، نرخ تغییر دما، جریان، توان لحظه‌ای)، $\sigma(\cdot)$ تابع فعال‌سازی، به صورت سیگموئید، $w_i(t)$ و $v_{ij}(t)$ وزن‌های ورودی و خروجی شبکه که به صورت تطبیقی به‌روزرسانی می‌شوند. همچنین b_i بایاس لایه میانی است.

۴-۱۱ قانون یادگیری اصلاح‌شده مبتنی بر خطای مدل

برای بهبود تطابق شبکه با تغییرات دینامیکی فرآیند، یک قانون یادگیری اصلاح‌شده بر اساس خطای مدل بین دوقلوی دیجیتال و واقعیت طراحی شده (۲۵) است:

$$\Delta w_i = -\eta \cdot e_T(t) \cdot \sigma_i(t) + \xi \cdot (T_{real}(t) - T_{DT}(t)) \quad (25)$$

ماژول (مانند فیلتر، الگوریتم‌های بهینه‌سازی و ساختار تطبیقی) پیچیدگی بیشتری دارد، اما به دلیل طراحی بهینه و بهره‌گیری از ساختارهای ماتریسی ساده، نرخ رشد پیچیدگی آن همچنان در حد چندجمله‌ای باقی می‌ماند و لذا در سیستم‌های با ابعاد بزرگ و اجرای بلادرنگ نیز عملی خواهد بود.

جدول (۱): مقایسه پیچیدگی محاسباتی روش پیشنهادی با سایر

روش‌ها

روش	نوع عملیات غالب	مرتبه پیچیدگی محاسباتی	توضیح
RLS	به‌روزرسانی ماتریس معکوس	$O(n^2)$	کارایی بالا، ولی حساس به نویز و خطاهای گرد کردن
EKF	خطی‌سازی و به‌روزرسانی کوواریانس	$O(n^3)$	کارایی بالا، ولی حساس به نویز و خطاهای گرد کردن
شبکه عصبی ساده	ضرب ماتریس و توابع فعال‌سازی	$O(N \cdot d)$	ساده‌تر ولی نیازمند داده‌های زیاد برای آموزش
روش پیشنهادی	ترکیب بهینه‌سازی ماتریسی و یادگیری تطبیقی	$O(n^2 \log n)$	ساده‌تر ولی نیازمند داده‌های زیاد برای آموزش

۵- نتایج و بحث

در این بخش، نتایج شبیه‌سازی ارائه‌شده و عملکرد روش پیشنهادی از جنبه‌های مختلف مورد تحلیل و بررسی قرار می‌گیرد. هدف از این تحلیل، ارزیابی دقت، پایداری و کارایی الگوریتم طراحی‌شده در شرایط مختلف عملیاتی و مقایسه آن با روش‌های موجود است. همچنین، تأثیر به‌کارگیری شبکه عصبی تطبیقی، دوقلوی دیجیتال و کنترل پیش‌بین در بهبود پاسخ سیستم و افزایش قابلیت اطمینان کنترل بررسی می‌شود. نمودارها، جداول و مقایسه‌های عددی به‌منظور تبیین بهتر نتایج به کار رفته‌اند و بحث‌های ارائه‌شده بر

سه بخش اصلی است: ۱- مدل‌سازی دینامیکی و استخراج ویژگی‌ها، ۲- تخمین پارامترها با استفاده از فیلتر/بهینه‌ساز معرفی‌شده و ۳- یادگیری تطبیقی بر پایه شبکه عصبی/ماشین یادگیرنده.

- در بخش مدل‌سازی، محاسبات خطی ماتریسی با مرتبه $O(n^2)$ انجام می‌شود که با توجه به ابعاد متوسط سیستم‌های صنعتی قابل مدیریت است.
- بخش تخمین پارامترها عمدتاً بر اساس روش‌های بازگشتی و فیلترهای حالت عمل می‌کند که پیچیدگی آن حدود $O(n^3)$ است؛ اما با توجه به ساختار تکرارشونده، این هزینه در اجراهای آنلاین به شدت کاهش می‌یابد و در عمل نزدیک به $O(n^2)$ باقی می‌ماند.
- در بخش یادگیری تطبیقی، با استفاده از شبکه‌های عصبی سبک‌وزن، پیچیدگی یادگیری در مرحله آموزش برابر با $O(N \cdot d)$ که در آن N تعداد نمونه‌ها و d تعداد ویژگی‌ها است) بوده و در مرحله استنتاج تنها $O(d)$ خواهد بود. این موضوع اجرای بلادرنگ را تضمین می‌کند.

به‌طورکلی، پیچیدگی محاسباتی روش پیشنهادی در مقایسه با روش‌های مرجع هم‌رده یا پایین‌تر است، در حالی که دقت بالاتری را فراهم می‌آورد. این توازن میان دقت و هزینه محاسباتی موجب می‌شود که الگوریتم قابلیت پیاده‌سازی عملی در سیستم‌های صنعتی مقیاس متوسط و بزرگ را داشته باشد. به‌ویژه در محیط‌های دارای منابع سخت‌افزاری محدود، روش پیشنهادی به دلیل ساختار بازگشتی و طراحی ماژولار، امکان استقرار آسان را فراهم می‌سازد. تحلیل پیچیدگی محاسباتی نشان می‌دهد که روش پیشنهادی با وجود افزایش دقت، از نظر هزینه محاسباتی مقیاس‌پذیر بوده و برای کاربردهای بلادرنگ در سیستم‌های صنعتی مناسب است.

به‌منظور روشن‌تر ساختن ابعاد مقیاس‌پذیری و عملی بودن روش پیشنهادی، یک مقایسه دقیق از پیچیدگی محاسباتی آن با برخی روش‌های مرسوم در ادبیات شامل RLS^1 و EKF^2 و شبکه عصبی ساده در جدول (۱) ارائه گردید. این مقایسه به ما اجازه می‌دهد تا نشان دهیم که اگرچه روش پیشنهادی از لحاظ ترکیب چندین

^۲ Extended Kalman Filter

^۱ Recursive Least Squares

- جرم شارژ شده قراضه $M_{in}(i) = 5\text{ton}$
- نرخ تزریق اکسیژن $Q_{O_2}(i) = 1000\text{Nm}^3/\text{h}$

جدول (۲): پارامترهای عددی برای کنترل و مصرف انرژی

پارامتر	نماد	مقدار عددی	واحد
ظرفیت گرمایی معادل	C	12/000	J/°C
توان نامی ورودی	P _{max}	50/000	kW
نرخ تلفات حرارتی پایه	Q _{loss,0}	5/000	kW
دمای مرجع ذوب	T _{ref}	1/650	°C
نرخ یادگیری شبکه عصبی	η	0/001	—
نرخ اصلاح از دوقلو	ξ	0/002	—
افق پیش‌بینی	N _p	10	—
افق کنترل	N _c	5	—
ضریب وزن‌دهی تغییرات کنترل	λ	0/05	—
آستانه اختلاف	δ	15	°C
نرخ اصلاح کنترلی	ε	0/5	—

مدل دما در این حالت به صورت ساده شده به شکل (۲۸) نوشته می‌شود:

$$T_{\text{pred}}(i; \theta) = \theta_1 P_{\text{in}}(i) - \theta_2 M_{\text{in}}(i) + \theta_3 Q_{O_2}(i) \quad (28)$$

با مقادیر اولیه (۲۹):

$$\theta_1 = 0/12^\circ\text{C}/\text{MW}, \theta_2 = 8^\circ\text{C}/\text{ton}, \theta_3 = 0/05^\circ\text{C}/(\text{Nm}^3/\text{h}). \quad (29)$$

بنابراین با جایگذاری مقادیر عددی (۳۰):

$$T_{\text{pred}}(i; \theta) = 0/12 \times 30 - 8 \times 5 + 0/05 \times 1000 = 3/6 - 40 + 50 = 13/6^\circ\text{C} \quad (30)$$

اگر دمای واقعی اندازه‌گیری شده در همان لحظه $T_{\text{meas}}(i) = 15^\circ\text{C}$ باشد، آنگاه خطای مربعی (۳۱):

$$e(i) = (T_{\text{meas}}(i) - T_{\text{pred}}(i; \theta))^2 = (15 - 13/6)^2 = 1/96 \quad (31)$$

این خطا در تابع هزینه لحاظ شده و با استفاده از الگوریتم‌های بهینه‌سازی، مثلاً RLS یا گرادین کاهشی، پارامترهای $\theta_1, \theta_2, \theta_3$ به صورت برخط اصلاح می‌شوند تا انطباق بهتری بین دوقلوهای دیجیتال و فرآیند واقعی حاصل شود. بدین ترتیب، ورودی‌های اصلی فرآیند همواره اندازه‌گیری شده و در مدل لحاظ می‌شوند و

مبنای داده‌های حاصل از شبیه‌سازی صورت گرفته‌اند تا تصویری دقیق از عملکرد واقعی سیستم ارائه شود. در ادامه یک مثال صنعتی برای پیاده‌سازی روش ارائه شده در مقاله، شامل بهینه‌سازی هوشمند انرژی و کنترل تطبیقی در کوره‌های قوس الکتریکی در صنعت فولاد ارائه می‌شود.


۵-۱ مثال صنعتی: کنترل تطبیقی و بهینه‌سازی مصرف انرژی در کوره قوس الکتریکی با کمک دوقلو دیجیتال و شبکه عصبی

کوره قوس الکتریکی یکی از تجهیزات کلیدی در صنعت فولاد است که با اعمال جریان الکتریکی شدید، قراضه فلزی را ذوب می‌کند. مصرف انرژی در این فرآیند بسیار بالا است و پارامترهایی مانند دما، نرخ ذوب، مقاومت الکترونها و نرخ ورود مواد تأثیر زیادی بر عملکرد دارند. در این مثال، هدف پیاده‌سازی یک سیستم کنترل هوشمند بر پایه شبکه عصبی تطبیقی و دوقلو دیجیتال است که بتواند مصرف انرژی را بهینه کرده و عملکرد کوره را پایدار و قابل اعتماد نگه دارد. برای مدل‌سازی دینامیک دما درون کوره، از معادله انرژی استفاده می‌کنیم. برای تخمین دقیق مدل ناشناخته کوره، از یک شبکه عصبی استفاده می‌شود. وزن‌ها از قانون یادگیری تطبیقی با بازخورد دوقلو دیجیتال به‌روزرسانی می‌شوند. کنترل‌کننده توان ورودی به الکترونها را به صورت پیش‌بینانه بهینه می‌کند. این مثال نشان می‌دهد چگونه می‌توان با ترکیب شبکه عصبی تطبیقی، دوقلو دیجیتال و کنترل پیش‌بین، مصرف انرژی کوره را کاهش داده و پایداری فرآیند ذوب را افزایش داد. این رویکرد قابلیت تعمیم به دیگر فرآیندهای صنعتی پرانرژی را نیز دارد. در ادامه، در جدول (۲) پارامترهای عددی مورد استفاده برای شبیه‌سازی فرآیند کنترل تطبیقی و بهینه‌سازی انرژی در کوره قوس الکتریکی ارائه می‌شود. این مقادیر به صورت تقریبی و بر پایه داده‌های صنعتی مرسوم انتخاب شده‌اند تا شرایط یک سیستم واقعی را شبیه‌سازی کنند. هدف، بررسی عملکرد کنترل‌کننده پیش‌بین عصبی در تعامل با دوقلو دیجیتال برای رسیدن به پایداری دما و کاهش انرژی مصرفی است.


فرض کنید در یک بازه زمانی نمونه‌برداری داریم:

$$P_{\text{in}}(i) = 30\text{MW} \quad \text{توان الکتریکی تزریقی}$$

ردیابی نمایش داده شده‌اند که به خوبی نحوه کنترل تطبیقی و پاسخ سیستم را در شرایط نویزی به تصویر می‌کشند.



شکل (۲): دمای کوره با کنترل مبتنی بر شبکه عصبی تطبیقی
یک سامانه کنترل تطبیقی مبتنی بر شبکه عصبی برای تنظیم دمای متغیر یک کوره قوس الکتریکی در شکل (۳) مدل سازی شده است.




شکل (۳): دمای کوره با شبکه عصبی تطبیقی و مرجع متغیر زمانی

دمای مرجع به صورت سینوسی تغییر می‌کند تا شرایط عملیاتی واقعی تر شبیه سازی شود. کنترل کننده تطبیقی با استفاده از یک نورون مصنوعی با وزن های قابل به روز رسانی، سیگنال کنترل را تولید می‌کند و ورودی توان را برای پیروی از دمای مرجع تنظیم می‌نماید. مدل دینامیکی کوره با استفاده از ثابت زمانی و بهره سیستم مدل شده و به روز رسانی وزن ها نیز به روش مشابه گرادیان نزولی انجام می‌شود. نتایج شامل پیروی دقیق دمای واقعی از مقدار

این مسئله تضمین می‌کند که خروجی های پیش بینی شده قابلیت مقایسه واقعی با داده های صنعتی داشته باشند.


منحنی تغییرات تابع هدف در طول آموزش شبکه عصبی بیانگر فرایند همگرایی مدل در شکل (۱) است. در ابتدای آموزش، مقدار تابع هدف نسبتاً بزرگ است زیرا وزن ها و بایاس های شبکه به صورت تصادفی مقداردهی اولیه شده اند. با تکرار چرخه های آموزشی و اعمال الگوریتم بهینه سازی، خطا به تدریج کاهش یافته و شبکه به سمت مقادیر بهینه حرکت می‌کند. روند نزولی منحنی نشان می‌دهد که مدل به طور مؤثر الگوهای داده را یاد گرفته و توانسته است خطا را کاهش دهد.



شکل (۱): منحنی تغییرات تابع هدف در حین آموزش شبکه عصبی


در مراحل پایانی آموزش، تغییرات تابع هدف بسیار ناچیز شده و منحنی به یک مقدار تقریباً ثابت همگرا می‌شود که نشان دهنده رسیدن شبکه به پایداری نسبی و یادگیری کافی است. این رفتار صحت عملکرد الگوریتم بهینه سازی و کفایت ساختار انتخاب شده برای شبکه را تأیید می‌کند.

در شکل (۲) عملکرد یک کنترل کننده الهام گرفته از شبکه عصبی برای تنظیم دمای کوره قوس الکتریکی مورد بررسی قرار گرفته است. دمای مرجع ثابت در نظر گرفته شده و کنترل کننده تلاش می‌کند با توجه به خطای دما و نویز تصادفی، سیگنال توان ورودی را به گونه ای تنظیم کند که دمای واقعی به مقدار مرجع نزدیک شود. در این مدل، دینامیک گرمایی سیستم به کمک ظرفیت حرارتی و تلفات حرارتی پایه مدل سازی شده است. نتایج در قالب سه نمودار شامل دمای واقعی و مرجع، توان ورودی اعمال شده و خطای



شکل (۵): کنترل دما با یادگیری تطبیقی و دوقلوی دیجیتال


در شکل (۶)، کنترل تطبیقی دمای کوره قوس الکتریکی با بهره‌گیری از یک شبکه عصبی ساده و وزن‌های به‌روزشونده، برای ردیابی دقیق یک دمای مرجع پویا صورت گرفته است. تغییرات پیچیده در ورودی توان، تأثیر اتلاف انرژی نوسانی و وجود نویز محیطی، این سیستم را به محیطی واقعی نزدیک می‌کند. وزن‌های شبکه عصبی به صورت بلادرنگ و با الگوریتمی مشابه گرادیان نزولی به‌روزرسانی می‌شوند تا توانایی کنترل سیستم در برابر اختلالات افزایش یابد که نشان‌دهنده یک نمونه از پیاده‌سازی دوقلوی دیجیتال هوشمند در صنعت فولاد است.



شکل (۶): کنترل با شبکه عصبی و دوقلوی دیجیتال

مرجع، تغییرات ورودی توان و میزان خطای کنترل، اثربخشی الگوریتم کنترل هوشمند را نشان می‌دهد.

شکل (۷) به مدل‌سازی یک کنترل‌کننده مبتنی بر شبکه عصبی مصنوعی برای پیگیری دمای یک کوره قوس الکتریکی می‌پردازد. دمای مرجع به صورت تابع سینوسی تغییر می‌کند تا شرایط پویا و پیچیده‌تری ایجاد گردد. شبکه عصبی شامل یک لایه پنهان با تابع فعال‌سازی سیگموئید و الگوریتم یادگیری گرادیان نزولی ساده برای به‌روزرسانی وزن‌هاست. ورودی شبکه شامل دمای فعلی، مشتق دما و خطای ردیابی است. در طول شبیه‌سازی، کنترل توان ورودی بر اساس خروجی شبکه انجام می‌شود و رفتار دینامیکی سیستم شبیه‌سازی شده و به صورت نمودارهایی از دمای واقعی، توان ورودی و خطای کنترلی نمایش داده شده است. این روش نشان می‌دهد که شبکه عصبی می‌تواند در شرایط دینامیکی متغیر، عملکرد کنترل را بهبود دهد.




شکل (۷): کنترل تطبیقی دمای کوره با شبکه عصبی چندلایه

یک کنترل‌کننده تطبیقی مبتنی بر شبکه عصبی طراحی شده که با بهره‌گیری از بازخورد دوقلوی دیجیتال، توانایی بهینه‌سازی دمای کوره قوس الکتریکی را در برابر نوسانات شدید و افت انرژی حرارتی را در شکل (۸) نشان می‌دهد. سیستم کنترلی از چهار ورودی شامل دما، نرخ تغییر دما، خطا و انتگرال خطا بهره می‌گیرد و با یادگیری برخط وزن‌های شبکه عصبی، به صورت بلادرنگ با شرایط دینامیکی متغیر سازگار می‌شود. مدل دوقلوی دیجیتال نیز با در نظر گرفتن تلفات غیرخطی، نویز حرارتی و نوسانات خارجی، بازخوردی واقع‌گرایانه از وضعیت فیزیکی کوره فراهم می‌کند که منجر به دقت بالا در ردیابی دمای می‌شود.

مدل منجر شد.

شکل (۷) روند تغییر خطای مدل را در دو سناریوی آموزشی مختلف نمایش می‌دهد. در حالت نخست که تنها داده‌های شبیه‌سازی شده برای آموزش استفاده شده‌اند، مشاهده می‌شود که کاهش خطا با شیب کمتر و همگرایی در مراحل بالاتری رخ می‌دهد. در مقابل، زمانی که مجموعه داده ترکیبی شامل داده‌های شبیه‌سازی و داده‌های واقعی به کار گرفته شده است، خطا در همان مراحل ابتدایی سریع‌تر کاهش یافته و در نهایت مقدار کمتری را نسبت به حالت صرفاً شبیه‌سازی تجربه می‌کند. این مقایسه نشان می‌دهد که افزودن داده واقعی به فرآیند آموزش نه تنها موجب بهبود دقت مدل می‌شود، بلکه سرعت همگرایی شبکه عصبی را نیز افزایش می‌دهد.




شکل (۷): مقایسه خطای مدل در آموزش صرفاً شبیه‌سازی شده و آموزش ترکیبی (شبیه‌سازی + واقعی)

جدول (۳) عملکرد روش پیشنهادی مبتنی بر شبکه عصبی و دوقلوی دیجیتال را در مقایسه با سه روش مرجع نشان می‌دهد. همان‌طور که مشاهده می‌شود، روش پیشنهادی در تمام معیارهای کلیدی مانند کاهش خطای ردیابی دما، مصرف انرژی کمتر، زمان نشست کوتاه‌تر و پایداری بالا در مواجهه با اغتشاشات، عملکرد بهتری از خود نشان داده است. همچنین این روش در مدیریت شرایط غیرخطی کوره‌های قوس الکتریکی نسبت به سایر روش‌ها از دقت و انعطاف‌پذیری بیشتری برخوردار است. این برتری‌ها نشان می‌دهند که استفاده هم‌زمان از هوش مصنوعی و دوقلوی دیجیتال می‌تواند

در مدل دیجیتال توسعه داده شده، خروجی اصلی بر پایه دما تعریف شده است. این دما نه تنها به عنوان شاخص کلیدی برای بازنمایی شرایط واقعی کوره قوس الکتریکی در فضای دیجیتال به کار می‌رود، بلکه نقش مرجع اصلی برای الگوریتم‌های کنترل تطبیقی و بهینه‌سازی انرژی ایفا می‌کند. به بیان دیگر، دوقلوی دیجیتال قادر است تغییرات لحظه‌ای دما را در شرایط عملیاتی مختلف شبیه‌سازی کرده و اطلاعات آن را به شبکه عصبی و الگوریتم‌های کنترلی منتقل نماید تا تصمیم‌گیری بهینه در خصوص مصرف انرژی و پایداری فرآیند ذوب صورت گیرد. همچنین برای جلوگیری از ساده‌سازی بیش‌ازحد، مدل علاوه بر دما، امکان استخراج پارامترهای جانبی مانند توان مصرفی و مشخصه‌های الکترود را نیز دارد، اما تمرکز اصلی در این پژوهش بر خروجی دما به عنوان متغیر حیاتی فرآیند قرار گرفته است.

برای اعتبارسنجی مدل پیشنهادی، از داده‌های شبیه‌سازی شده و واقعی استفاده شد. مجموعه داده واقعی از سیستم واحد مدیریت انرژی هوشمند [۲۷] به دست آمد، جایی که تغییرات دما و سیگنال‌های کنترلی در طول یک بازه ۳۰ روزه به‌طور پیوسته ثبت شدند. در راستای اعتبارسنجی مدل پیشنهادی، داده‌های واقعی به کار رفته در این پژوهش مشابه ساختار مجموعه‌های داده صنعتی معتبر است. به عنوان نمونه‌ای واقعی و مستند، در مجموعه داده ارائه شده توسط Engel و همکاران در مجله Scientific Data (سال ۲۰۲۵) [۲۷]، اطلاعات انرژی مصرفی و سیستم تهویه مطبوع یک محیط صنعتی هوشمند (به مدت چند سال) ثبت شده است. این مجموعه نمود وسیعی از رفتارهای واقعی کنترل، شرایط محیطی و مصرف انرژی را در سناریوهای متنوع پوشش می‌دهد. این داده‌ها شامل نویز اندازه‌گیری و نوسانات غیرمنتظره‌ای بودند که به‌طور طبیعی در محیط‌های واقعی رخ می‌دهند. سپس این مجموعه داده با پیش‌پردازش شامل نرمال‌سازی و حذف داده‌های پرت ترکیب شد و با داده‌های شبیه‌سازی تولید شده در MATLAB/Simulink ادغام گردید. این مجموعه داده ترکیبی اجازه داد ابتدا شبکه عصبی با داده‌های شبیه‌سازی آموزش ببیند تا دینامیک سیستم را یاد بگیرد و سپس با استفاده از اختلالات واقعی تنظیم دقیق شود، که در نتیجه به افزایش پایداری و قابلیت اعتماد

در راستای اعتبارسنجی دقیق‌تر روش پیشنهادی، چند سناریوی متنوع و نزدیک به شرایط واقعی عملیاتی مورد بررسی قرار گرفت. نخست در شکل (۸)، اثر نویز اندازه‌گیری بر سیگنال‌های دما و انرژی ورودی لحاظ شد. در چنین شرایطی، الگوریتم باید توانایی جداسازی مؤلفه‌های مفید از اغتشاشات تصادفی را داشته باشد تا عملکرد کنترل و پیش‌بینی مختل نشود. نتایج نشان داد که حتی با افزایش سطح نویز، تخمین مقادیر اصلی دما و انرژی همچنان در محدوده قابل قبول باقی می‌ماند.



شکل (۸): بررسی وجود نویز اندازه‌گیری در سیگنال‌های دما و انرژی ورودی

در سناریوی دوم، خطاهای حسگر به صورت آفست ثابت و همچنین قطع متناوب داده‌ها در شکل (۹) شبیه‌سازی گردید. بروز این دسته خطاها در محیط‌های واقعی امری اجتناب‌ناپذیر است و می‌تواند باعث ایجاد انحراف در تصمیم‌گیری‌های کنترلی شود. روش ارائه‌شده توانست با استفاده از سازوکارهای

بهینه‌سازی کنترل فرآیند را در محیط‌های صنعتی پیچیده تسهیل کند.

جدول (۳): مقایسه عددی عملکرد روش‌ها در کنترل دمای کوره

قوس الکتریکی

معیار ارزیابی	روش کلاسیک PID	کنترل تطبیقی PI	شبکه عصبی بدون دولو	روش پیشنهادی
میانگین خطای ردیابی دما	۷۴/۳	۴۸/۷	۳۵/۲	۱۲/۸
توان مصرفی کل	۵/۸۴	۵/۱۵	۴/۹۱	۴۳/۴
مقاومت به اغتشاشات	٪۷۲	٪۸۴	٪۸۸	٪۹۵
زمان نشست سیستم	۶۱	۴۵	۳۳	۲۱
نرخ سازگاری با بارهای غیرخطی	٪۶۸	٪۸۱	٪۸۷	٪۹۷

با توجه به جدول (۴)، مدل پیشنهادی در تمامی شاخص‌ها نسبت به روش‌های مرجع عملکرد بهتری ارائه کرده است. مقدار MSE و $RMSE$ کمتر بیانگر دقت بالاتر مدل در پیش‌بینی مقادیر واقعی است. همچنین کاهش MAE نشان‌دهنده کاهش انحراف مطلق خطا در تخمین‌ها است. از سوی دیگر، افزایش ضریب تعیین (R^2) تا مقدار ۱/۸۹ نشان می‌دهد که مدل پیشنهادی قادر است بیش از ۹۸ درصد تغییرات داده‌های واقعی را توضیح دهد، که نسبت به سایر روش‌ها بهبود قابل توجهی محسوب می‌شود.

جدول (۴): جدول نمونه ارزیابی عددی

روش مقایسه	MSE^1	$RMSE$	MAE^2	R^2
روش RLS	۰/۰۱۵	۰/۱۲۲	۰/۰۸۹	۰/۹۴۱
روش EKF	۰/۰۱۱	۰/۱۰۵	۰/۰۷۳	۰/۹۵۶
روش NN-Estimator	۰/۰۰۹	۰/۰۹۷	۰/۰۶۸	۰/۹۶۳
مدل پیشنهادی	۰/۰۰۵	۰/۰۷۱	۰/۰۵۱	۰/۹۸۱

² Root Mean Squared Error

³ Mean Absolute Error

¹ Mean Squared Error

چالش برانگیز است. با این حال، نتایج شبیه‌سازی نشان داد که رویکرد پیشنهادی توانسته است بدون بروز ناپایداری، مقادیر دما و انرژی را در سطح مطلوب کنترل نماید و انحرافات گذرا را به سرعت میرا کند.

ترکیب این آزمایش‌ها به خوبی نشان داد که چارچوب طراحی شده نه تنها در شرایط ایده‌آل بلکه در حضور اغتشاشات محیطی، خطاهای سنسوری و تغییرات بار نیز کارآمد است. بدین ترتیب، روش پیشنهادی از مقاومت بالا و قابلیت اطمینان برخوردار بوده و می‌تواند به عنوان یک راهکار عملی برای کاربردهای واقعی مورد استفاده قرار گیرد. به منظور بررسی میزان تأثیرپذیری عملکرد چارچوب پیشنهادی از تغییرات پارامترهای کلیدی، تحلیل حساسیت در سه محور اصلی شامل نرخ یادگیری شبکه عصبی، پارامترهای کنترلی سیستم و داده‌های ورودی دوقلوی دیجیتال طبق جدول (۵) صورت گرفت.

۱- نرخ یادگیری شبکه عصبی:

آزمایش‌ها نشان دادند که مقادیر پایین نرخ یادگیری سبب کندی همگرایی و افزایش زمان آموزش می‌شود، در حالی که مقادیر بیش‌ازحد بزرگ منجر به نوسان و کاهش دقت در فرآیند تطبیق مدل می‌گردد. محدوده بهینه‌ای از نرخ یادگیری شناسایی شد که در آن شبکه ضمن حفظ سرعت یادگیری، از پایداری بالایی برخوردار است.


۲- پارامترهای کنترلی:

تغییر ضرایب کنترلی نظیر بهره‌های تناسبی و انتگرالی بر پایداری و دقت ردیابی مرجع اثرگذار است. نتایج نشان دادند که سیستم در برابر تغییرات کوچک این پارامترها مقاوم بوده و پایداری خود را حفظ می‌کند، اما در صورت افزایش بیش‌ازحد این ضرایب، پاسخ سیستم دچار اُرشوت بالا و نوسانات گذرا می‌شود. در مقابل، کاهش شدید آن‌ها باعث کند شدن پاسخ دینامیکی خواهد شد.

۳- داده‌های ورودی دوقلوی دیجیتال:


کیفیت و دقت داده‌های ورودی نقش مهمی در کارایی کل سامانه دارند. آزمایش‌ها بیانگر آن بود که مدل پیشنهادی قادر است در برابر نویزهای کم تا متوسط عملکرد مناسب خود را حفظ کند. با این حال، در شرایطی که داده‌های ورودی دارای خطاهای قابل توجه

جبرانی تعبیه‌شده، اثر این خطاها را کاهش داده و پایداری سیستم را حفظ نماید.



شکل (۹): بررسی بروز خطاهای حسگر (آفت و قطع مقطعی داده‌ها)

در ادامه، تغییرات شرایط عملیاتی نظیر نوسان در بار حرارتی و تغییر نرخ تزریق انرژی در شکل (۱۰) بررسی شد.



شکل (۱۰): تغییرات شرایط عملیاتی شامل نوسان در بار و تغییر نرخ تزریق انرژی

این تغییرات اغلب موجب دینامیک‌های سریع و غیرخطی در سیستم می‌شوند که برای بسیاری از روش‌های متعارف

۶- نتیجه‌گیری

در این مقاله، یک چارچوب نوآورانه برای کنترل هوشمند و بهینه‌سازی مصرف انرژی در کوره‌های قوس الکتریکی در صنعت فولاد ارائه شد. این چارچوب مبتنی بر ترکیب شبکه عصبی تطبیقی و دوقلوی دیجیتال است که با هدف افزایش دقت ردیابی دما، کاهش مصرف انرژی و بهبود پایداری سیستم طراحی شده است. نتایج شبیه‌سازی‌ها نشان داد که الگوریتم پیشنهادی نه تنها توانسته است با دقت بالا رفتار حرارتی کوره را دنبال کند، بلکه با سازگاری با شرایط متغیر، اغتشاشات محیطی و مدل‌سازی ضرایب اتلاف حرارتی، نسبت به سایر روش‌های کنترل کلاسیک و تطبیقی عملکرد بهتری از خود نشان داده است. استفاده از دوقلوی دیجیتال باعث شد تا بازخورد دقیق‌تری از وضعیت حرارتی واقعی سیستم به دست آید و این بازخورد نقش مهمی در آموزش برخط شبکه عصبی و اصلاح وزن‌های آن ایفا کرد. همچنین، ساختار تطبیقی کنترل باعث شد تا سیستم نسبت به تغییرات تدریجی و ناگهانی در دینامیک کوره مقاوم باشد. در مسیر توسعه این تحقیق، به جای محدود کردن بحث به شبکه‌های کانولوشنی، می‌توان از ساختارهای پیچیده‌تر یادگیری عمیق مانند شبکه‌های بازگشتی پیشرفته یا مدل‌های هیبریدی ترکیبی بهره گرفت تا هم وابستگی‌های زمانی و هم در صورت وجود بعد مکانی در داده‌ها به شکل دقیق‌تری مدل‌سازی شوند.


همچنین پیاده‌سازی الگوریتم پیشنهادی در محیط واقعی کارخانه و مقایسه عملکرد آن با داده‌های عملیاتی واقعی می‌تواند گامی مؤثر در تجاری‌سازی این رویکرد باشد. از دیگر مسیرهای توسعه، می‌توان به استفاده از یادگیری تقویتی برای تنظیم خودکار سیاست کنترلی و گسترش چارچوب به سیستم‌های چندرودی-چندخروجی اشاره کرد. همچنین، یکپارچه‌سازی این سیستم با زیرساخت‌های اینترنت اشیا و تحلیل کلان‌داده‌های صنعتی برای پیش‌بینی نگهداری و کاهش زمان توقف نیز قابل بررسی است.

یا تأخیر زیاد باشند، کاهش محسوس در دقت تخمین و پیش‌بینی مشاهده شد. برای مقابله با این موضوع، از مکانیزم‌های فیلترینگ و هموارسازی داده‌ها استفاده گردید.

جدول (۵): مقایسه تحلیل حساسیت

پارامتر مورد تغییر	محدوده تغییر (%)	شاخص عملکرد اصلی	تغییر در پایداری سیستم
نرخ یادگیری شبکه عصبی	۰/۰۰۱ تا ۰/۵۰۰	۰/۰۱۲ → ۰/۰۲۸	پایدار، افت جزئی در یادگیری سریع
پارامتر کنترلی K_p	۳۰٪ - ۳۰٪	۰/۰۱۰ → ۰/۰۱۸	پایدار در بیشتر محدوده‌ها
پارامتر کنترلی K_i	۳۰٪ - ۳۰٪	۰/۰۰۹ → ۰/۰۲۱	پایدار، اما کندی در پاسخ
داده ورودی دوقلوی دیجیتال	۰٪ تا ۱۰٪ نویز افزوده	۰/۰۱۱ → ۰/۰۳۲	پایدار، افزایش خطای تخمین

نمودار حساسیت ارائه‌شده در شکل (۱۱) میزان تأثیرگذاری تغییرات هر یک از پارامترهای کلیدی مدل بر خطای کلی سیستم را نشان می‌دهد. همان‌طور که مشاهده می‌شود، برخی از پارامترها در مقایسه با سایرین حساسیت بالاتری داشته و تغییر اندک در مقدار آن‌ها منجر به افزایش قابل توجه خطای مدل می‌شود.



شکل (۱۱): تحلیل حساسیت پارامترها بر خطای مدل

این تحلیل می‌تواند در فرآیند بهینه‌سازی و انتخاب استراتژی‌های کنترلی به عنوان راهنمایی مهم مورد استفاده قرار گیرد، چرا که تمرکز بر پارامترهای حساس‌تر موجب بهبود کارایی سیستم و افزایش دقت تخمین خواهد شد.

References

- [1] B. Yu, Y. Dai, J. Fu, J. Qi, and X. Li, "Industrial risks assessment for the large-scale development of electric arc furnace steelmaking technology," *J Applied Energy*, vol. 377, p. 124611, 2025.
- [2] L. Holappa, "A general vision for reduction of energy consumption and CO2 emissions from the steel industry," *J Metals*, vol. 10, no. 9, p. 1117, 2020.
- [3] E. Carpanzano and D. Knüttel, "Advances in artificial intelligence methods applications in industrial control systems: Towards cognitive self-optimizing manufacturing systems," *J Applied sciences*, vol. 12, no. 21, p. 10962, 2022.
- [4] H. Jiang, S. Qin, J. Fu, J. Zhang, and G. Ding, "How to model and implement connections between physical and virtual models for digital twin application," *J Journal of Manufacturing Systems*, vol. 58, pp. 36-51, 2021.
- [5] L. Cui, Y. Xiao, D. Liu, and H. Han, "Digital twin-driven graph domain adaptation neural network for remaining useful life prediction of rolling bearing," *J Reliability Engineering System Safety*, vol. 245, p. 109991, 2024.
- [6] M. M. Abadi, H. Tang, and M. M. Rashidi, "A review of simulation and numerical modeling of electric arc furnace (EAF) and its processes," *J Heliyon*, vol. 10, no. 11, 2024.
- [7] B. Tian, G. Wei, H. Hu, R. Zhu, H. Bai, Z. Wang, and L. Yang, "Effects of fuel injection and energy efficiency on the production and environmental parameters of electric arc furnace-heat recovery systems," *J Journal of Cleaner Production*, vol. 405, p. 136909, 2023.
- [8] S. Jawahery, V.-V. Visuri, S. O. Wasbø, A. Hammervold, N. Hyttinen, and M. Schlautmann, "Thermophysical model for online optimization and control of the electric arc furnace," *J Metals*, vol. 11, no. 10, p. 1587, 2021.
- [9] L. Shiqi, "Electric Arc Furnace for Steelmaking," in *The ECPH Encyclopedia of Mining and Metallurgy*: Springer, 2024, pp. 548-550.
- [10] I. A. Abbas and M. K. Mustafa, "A review of adaptive tuning of PID-controller: Optimization techniques and applications," *J International Journal of Nonlinear Analysis Applications*, vol. 15, no. 2, pp. 29-37, 2024.
- [11] N. Ajlouni, A. Osyavas, F. Ajlouni, A. Almassri, F. Takaoglu, and M. Takaoglu, "Enhancing PID control robustness in CSTRs: a hybrid approach to tuning under external disturbances with GA, PSO, and machine learning," *J Neural Computing Applications*, vol. 37, no. 18, pp. 12153-12177, 2025.
- [12] Kiheha, M. M., & Barahouei, S. (2024). A novel approach to graph dimensionality reduction based on deep learning using fuzzy logic and random walks. *Theoretical and Applied Machine Intelligence Research*, 2(1), 131–141.
- [13] R. G. Alarcón, M. A. Alarcón, A. H. González, and A. Ferramosca, "Artificial Neural Networks for Energy Demand Prediction in an Economic MPC-Based Energy Management System," *J International Journal of Robust Nonlinear Control*, vol. 35, no. 2, pp. 642 - 658 ,2025.
- [14] Y.-P. Chen, V. Karkaria, Y.-K. Tsai, F. Rolark, D. Quispe, R. X. Gao, J. Cao, and W. Chen, "Real-time decision-making for Digital Twin in additive manufacturing with Model Predictive Control using time-series deep neural networks," *J Journal of Manufacturing Systems*, vol. 80, pp. 412-424, 2025.
- [15] A. Sivtsov, O. Y. Sheshukov, D. Egiazar'yan, M. Tsymbalist, and P. Orlov, "Automated process control in electric arc furnaces in the aspect of digital twin technology," *J Izvestiya. Ferrous Metallurgy*, vol. 67, no. 4, pp. 481-489, 2024.
- [16] M. M. Abadi, H. Tang, and M. M. Rashidi, "A review of simulation and numerical modeling of electric arc furnace (EAF) and its processes," *J Heliyon*, 2024.
- [17] Dehghani Mahmoudabadi, M., Mirzaei, K., & Peirovi, F. (2023). Improving credit assignment of rules in learning classifier systems using Markov reinforcement learning for secondary protein structure prediction. *Theoretical and Applied Machine Intelligence Research*, 1(2), 92–104.
- [18] Y. Yin, Z. Wang, L. Zheng, Q. Su, and Y. Guo, "Autonomous UAV navigation with adaptive control based on deep reinforcement learning," *J Electronics*, vol. 13, no. 13, p. 2432, 2024.
- [19] A. A. Khater, M. Fekry, M. El-Bardini, and A. M. El-Nagar, "Deep reinforcement learning-based adaptive fuzzy control for electro-hydraulic servo system," *J Neural Computing Applications*, pp. 1-18, 2025.
- [20] A. Barzegar and D.-J. Lee, "Deep reinforcement learning-based adaptive controller for trajectory tracking and altitude control of an aerial robot," *J Applied Sciences*, vol. 12 ,no. 9, p. 4764, 2022.
- [21] B. Gajdzik, *Digital Transformation Towards Smart Steel Manufacturing*. Springer, 2025.
- [22] B. Zheng, M. Pan, Q. Liu, X. Xu, C. Liu, X. Wang, W. Chu, S. Tian, J. Yuan, and Y. Xu, "Data-driven assisted real-time optimal control



- strategy of submerged arc furnace via intelligent energy terminals considering large-scale renewable energy utilization," J Scientific Reports, vol. 14, no. 1, p. 5582, 2024.
- [23] M. Jafari, A. Kavousi-Fard, T. Chen, and M. Karimi, "A review on digital twin technology in smart grid, transportation system and smart city: Challenges and future," J IEEe Access, vol. 11, pp. 17471-17484, 2023.
- [24] H. Hosamo, M. H. Hosamo, H. K. Nielsen, P. R. Svennevig, and K. Svidt, "Digital Twin of HVAC system (HVACDT) for multiobjective optimization of energy consumption and thermal comfort based on BIM framework with ANN-MOGA," J Advances in building energy research, vol. 17, no. 2, pp. 125-171, 2023.
- [25] J. D. Hernández, L. Onofri, and S. Engell, "Modeling and energy efficiency analysis of the steelmaking process in an electric arc furnace," J Metallurgical Materials Transactions B, vol. 53, no. 6, pp. 3413-3441, 2022.
- [26] T. R. Mohan, R. A. Uthra, and J. P. Roselyn, "Intelligent and effective means of power utilization in induction furnace controlled melting process of foundry industries reducing CO2 emissions," J Electrical Engineering, pp. 1-20, 2025.
- [27] J. Engel, A. Castellani, P. Wollstadt, F. Lanfermann, T. Schmitt, S. Schmitt, L. Fischer, S. Limmer, D. Luttrupp, and F. Jomrich, "A real-world energy management dataset from a smart company building for optimization and machine learning," J Scientific Data, vol. 12, no. 1, p. 864, 2025.

Smart Energy Optimization and Adaptive Control of Electric Arc Furnaces in the Steel Industry using Digital Twin and Neural Networks

Sara Mahmoudi Rashid*

Instructor of Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

Article Information

Original Research Paper

Received:

2025 May 16

Accepted:

2025 September 30

Keywords:

Industrial Artificial Intelligence, Electric Arc Furnace, Energy Consumption Optimization, Adaptive Control, Learning Neural Network, Steel Industry Efficiency

Corresponding Author*:

s.mahmoudirashid@tabrizu.ac.ir

Abstract

This study proposes a novel framework for energy optimization and adaptive control of Electric Arc Furnaces (EAFs) in the steel industry, based on the integration of a digital twin model and adaptive neural networks. The main objective is to reduce energy consumption, enhance process stability, and improve control accuracy under varying operational conditions. To achieve this, a real-time updated digital twin of the steel melting process was first developed. Subsequently, adaptive neural networks were employed to estimate the nonlinear dynamics of the system and design an intelligent controller. The proposed system was implemented in the MATLAB/Simulink environment and evaluated under multiple operational scenarios. Simulation results demonstrate that the proposed approach achieves an average energy consumption reduction of 8.7%, a 24.3% improvement in transient response, and a 14.12% increase in power tracking accuracy compared to conventional controllers. These outcomes highlight the effectiveness of the proposed method in enhancing energy efficiency and operational stability in thermal processes within the steel industry and suggest its potential as a scalable model for smart system implementation in other industrial applications.



: 10.22034/ABMIR.2025.23151.1128

E-ISSN: [2821-2037](#)

/© 2025. Published by Yazd University This is an open access article

under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

