



گروه ملی صنعتی فولاد ایران



انجمن آهن و فولاد ایران



دانشگاه شهید چمران اهواز

سمپوزیوم فولاد ۸۷

۱۳ و ۱۴ اسفند ماه ۸۷

اهواز - دانشگاه شهید چمران

مدلسازی استحاله بازگشت مارتنزیت به آستنیت برای تولید فولاد ریزدانه توسط شبکه عصبی

حامد میرزاده^۱، عباس نجفی زاده^۲
دانشکده مهندسی مواد - دانشگاه صنعتی اصفهان

چکیده

در این تحقیق، بازگشت مارتنزیت به آستنیت به عنوان مرحله اصلی بعد از تغییر شکل سرد در عملیات ترمومکانیکی ابتکاری برای تولید فولادهای زنگ نزن آستنیتی ریزدانه مورد توجه قرار گرفت. اثر دما و زمان آنیل بر میزان بازگشت مارتنزیت در فولاد زنگ نزن ۳۰۴ توسط شبکه‌های عصبی مصنوعی مدل شد. مدل به دست آمده کارایی بالا و تطابق خوبی با واقعیت از خود نشان داد. با استفاده از این مدل، محدوده مناسب تشکیل آستنیت برای بهبود اندازه دانه توسط "روش تشکیل و بازگشت مارتنزیت کرنشی" مشخص شد.

کلمات کلیدی: بازگشت مارتنزیت، فولاد زنگ نزن، بهبود اندازه دانه، شبکه‌های عصبی مصنوعی.

¹ h-m@gmx.com

² abbas.najafizadeh@gmail.com

مقدمه

یک روش ابتکاری برای تولید برخی فولادهای آستنیتی ریزدانه ابداع شده است که بر پایه تشکیل مارتنزیت کرنشی^۱ توسط تغییر فرم سرد و سپس عملیات حرارتی برای تشکیل مجدد آستنیت استوار می‌باشد [۲۰۱]. این روش برای فولادهای زنگ نزن آستنیتی نیمه پایدار^۲ بسیار مناسب است. در این فرآیند، درصد بالایی از آستنیت نیمه پایدار باید به مارتنزیت کرنشی تبدیل شود [۳-۴] و سپس بازگشت^۳ مارتنزیت به آستنیت توسط یک عملیات حرارتی در دمای نسبتاً پایین، امکان کاهش قابل توجه اندازه دانه‌های آستنیت را فراهم می‌آورد [۵]. بازگشت مارتنزیت به آستنیت می‌تواند در دمایی بسیار کمتر از دمای تبلور مجدد انجام شود. بازگشت کامل در دماهایی از مرتبه ۷۵۰ درجه سانتیگراد امکانپذیر است [۶]. استحاله بازگشت به دو صورت برشی و دیفوزیونی انجام می‌شود [۷]. برای تولید فولاد ریزدانه، کنترل میزان مارتنزیت در مرحله اول و کنترل دما و زمان آنیل در مرحله دوم از اهمیت زیادی برخوردار هستند. در مرحله آنیل به دو نکته باید توجه کرد: الف) باید تمام مارتنزیت به آستنیت تبدیل شود و ب) چون فولاد آستنیتی حاصل، بسیار ریزدانه است، نیروی محرکه رشد دانه‌ها بسیار زیاد بوده و باید آنیل به سرعت متوقف شود. مشاهده می‌شود که دستیابی به شرایط بهینه آنیل در فرآیند بهبود اندازه دانه از اهمیت زیادی برخوردار است. در این تحقیق، اثر دما و زمان آنیل بر میزان بازگشت مارتنزیت در فولاد زنگ نزن ۳۰۴ توسط شبکه‌های عصبی مصنوعی^۴ مدل شده و نتایج آن در این مقاله آورده شده است.

روش تحقیق

پایگاه داده‌ها

کسر حجمی مارتنزیت پیش از عملیات آنیل ($M_{Initial}$)، وابسته به پارامترهای تغییر فرم می‌باشد. در نتیجه، درصد مارتنزیت پس از آنیل (M_{Final}) را نمی‌توان به عنوان معیاری از میزان استحاله بازگشت دانست، زیرا به کسر حجمی مارتنزیت پیش از عملیات آنیل وابسته خواهد بود. بنابراین در تحقیق حاضر، پارامتری بدون بعد با نام "درصد نسبی بازگشت" با توجه به رابطه ۱ تعریف شد.

$$Reversion(\%) = \frac{M_{Initial} - M_{Final}}{M_{Initial}} \times 100 \quad (1)$$

مجموعه داده‌ها از مراجع [۸-۱۰] انتخاب و به سه گروه تقسیم شدند: ۵۰٪ برای فرآیند یادگیری، ۲۵٪

¹ Starin-induced martensite

² Metastable austenitic stainless steels

³ Reversion

⁴ Artificial neural networks (ANNs)

⁵ Training

برای تعیین اعتبار^۱ در حین فرآیند یادگیری و ۲۵٪ برای آزمودن^۲ مدل آموخته. مقادیر دما و زمان آتیل، به عنوان متغیرهای ورودی و درصد نسبی بازگشت به عنوان متغیر خروجی در محدوده منفی یک تا یک نرماله شدند.

معماری شبکه

شبکه پیشرو^۳ شبکه ای است تشکیل شده از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی که هر لایه، ورودی خود را از لایه قبلی دریافت و سپس خروجی خود را به لایه بعدی می‌فرستد. این شبکه، یکطرفه است یعنی حلقه پسرو ندارد. بنابراین خروجیهای هر لایه، هیچ اثری بر همان لایه و یا لایه‌های قبلی ندارند. هر لایه، خود از چندین المان پردازنده^۴ تشکیل می‌شود. شیوه آرایش لایه‌ها و المان‌ها در شبکه را معماری شبکه^۵ می‌نامند. در هر المان، ورودی‌ها وزن دار شده و با هم جمع می‌شوند. سپس این مجموع به تابع فعال سازی^۶ که تابعی غیرخطی است تحویل و خروجی المان به دست می‌آید (شکل ۱). در تحقیق حاضر، از تابع غیر خطی تانژانت‌هایپربولیک مطابق رابطه ۲ استفاده شد. هرچند که استفاده از بیش از یک لایه پنهان در برخی موارد راندمان بالاتری ایجاد می‌کند اما اصولاً شبکه‌های عصبی با یک لایه پنهان توانایی مدل کردن همه موارد کاربردی را دارند. بنابراین در این تحقیق، یک شبکه پیشرو با یک لایه پنهان استفاده شده است. تعداد بهینه المان‌ها در لایه پنهان توسط آزمایش و خطا تعیین شد.

$$y = f(s) = \tan \operatorname{sig}(s) = \frac{e^s - e^{-s}}{e^s + e^{-s}} \quad (2)$$

فرآیند یادگیری

در شبکه‌های عصبی، بخش عمده ای از داده‌ها برای به دست آوردن ارتباط بین متغیرهای ورودی و خروجی استفاده می‌شود. این کار با استفاده از فرآیند یادگیری توسط یک الگوری آموزشی^۷ انجام می‌شود. در حین آموزش، پارامترهای آزاد سیستم (وزنها و بایاسها) برای دستیابی به کمینه سراسری در تابع خطا تغییر

¹ Validation

² Testing

³ Feed-forward network

⁴ Neuron (Processing element)

⁵ Network architecture

⁶ Activation function

⁷ Training algorithm (learning rule)

می‌کنند و از اینرو به شبکه‌های عصبی لقب انطباق پذیر^۱ داده اند. معمولاً از الگوی محبوب انتشار به عقب^۲ برای آموزش شبکه استفاده می‌شود. نرخ کاهش خطا در الگوی استاندارد اولیه، بسیار پایین است. به همین دلیل تغییراتی در الگوی اصلی داده شده و الگوهای جدیدتری به وجود آمده اند. یکی از پرکاربردترین آنها الگوی Levenberg-Marquardt می‌باشد که سریعترین الگو برای شبکه‌هایی با اندازه متوسط است. روش مناسب دیگر، الگوی Quickprop می‌باشد که بسیار سریعتر از الگوی استاندارد بوده و برای رفع بسیاری از مشکلات روش اولیه ابداع شده است. هر سه روش نامبرده، در مقاله حاضر استفاده شده اند.

شیوه توقف آموزش شبکه

اگر شبکه عصبی بیش از حد آموخته^۳ شود، شروع به بخاطر سپردن^۴ داده‌ها می‌کند و از هدف اصلی که پیدا کردن ارتباط موجود در داده‌ها است دور می‌شود. یک روش مناسب برای محدود کردن تعداد دوره‌های تکرار، استفاده از روش توقف اولیه^۵ [۱۱] می‌باشد که در آن، به محض آنکه خطای حاصل از داده‌هایی که برای تعیین اعتبار مدل استفاده می‌شوند، شروع به افزایش کند، باید فرآیند یادگیری را متوقف کرد (شکل ۲). با استفاده از این روش، اطمینان بیشتری در مورد جلوگیری از تطبیق بیش از اندازه^۶ شبکه وجود خواهد داشت. از روش ذکر شده در این مقاله استفاده شده است.

نتایج و بحث

کارآیی مدل

بررسی عمومیت مدل و تعیین بهترین ساختار شبکه توسط رسم کردن منحنی مقایسه ای مقادیر پیش بینی شده توسط مدل و مقادیر واقعی و نیز توسط محاسبه مقدار خطا انجام می‌شود. در این مقاله برای محاسبه خطا از تابعی مطابق با رابطه ۳ استفاده شد:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2} \quad (3)$$

در جایکه t و y به ترتیب بیانگر مقادیر واقعی و مقادیر پیش بینی شده توسط مدل می‌باشند.

شکل ۳ خطای محاسبه شده توسط داده‌های مورد استفاده برای آموزش و آزمون مدل ایجاد شده توسط الگوی Levenberg-Marquardt را برای شبکه‌هایی با تعداد المان‌های پنهان مختلف نشان می‌دهد. با توجه به

¹ Adaptive

² Backpropagation (backwards propagation of error)

³ Overtraining

⁴ Memorizing

⁵ Early stopping technique

⁶ Overfitting

این شکل می‌توان مشاهده کرد که شبکه ای با ۴ المان پنهان دارای کمترین خطا در داده‌های مورد استفاده برای آزمون مدل می‌باشد و خطای حاصل از داده‌های مورد استفاده برای آموزش شبکه نیز بسیار کاهش یافته است. بنابراین برای تعیین مدل نهایی از شبکه ای با ۴ المان پنهان استفاده شد. خطای داده‌های مورد استفاده برای آموزش و آزمون مدل و نیز تعداد دوره‌های مورد نیاز برای رسیدن به شرایط بهینه برای الگوی Levenberg-Marquardt کمتر از بقیه الگوریتمها بود. بنابراین، همین الگو برای ایجاد مدل نهایی مورد استفاده قرار گرفت.

کاربردها


اثر دما و زمان آنیل بر درصد نسبی بازگشت را می‌توان در شکل ۴ مشاهده کرد. همانطور که دیده می‌شود، با افزایش دما و زمان آنیل می‌توان درصد نسبی بازگشت را افزایش داد. نرخ استحاله بازگشت در دماهای بالاتر بسیار بیشتر است. همچنین نرخ استحاله بازگشت در دماهای بالا در زمانهای اولیه، زیاد بوده و سپس به شدت کاهش می‌یابد تا جاییکه که نسبت به افزایش زمان آنیل واکنش قابل توجهی نشان نخواهد داد. خطوط کانتور برای درصد نسبی بازگشت بر حسب دما و زمان آنیل در شکل ۵ آورده شده اند. همانطور که دیده می‌شود، بازگشت کامل مارتنزیت در یک زمان معقول، تنها در دماهای بالاتر از ۷۵۰ درجه سانتیگراد میسر است که با نتایج پیشین [۶] مطابقت دارد. با استفاده از شکل ۵ می‌توان زمان بهینه آنیل در هر دما را مشخص کرد تا زمان کافی برای استحاله کامل مارتنزیت به آستنیت وجود داشته باشد و عین حال از رشد دانه‌های آستنیت نیز جلوگیری شود. به عنوان مثال، در دماهای ۷۷۰، ۸۰۰ و ۸۵۰ درجه سانتیگراد به ترتیب ۴۹، ۱۱ و ۴ دقیقه عملیات آنیل برای بازگشت مارتنزیت کافی است و بیش از آن منجر به رشد دانه و کاهش توانایی این روش برای بهبود اندازه دانه خواهد شد.

نتیجه گیری

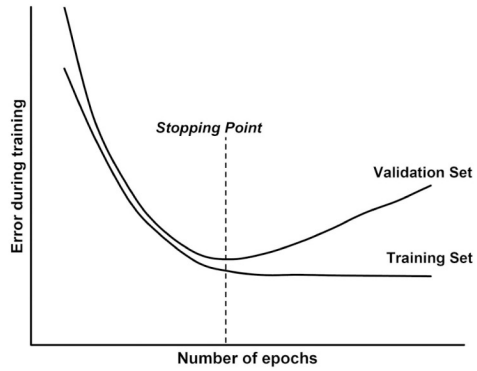
- ۱- اثر دما و زمان آنیل بر میزان بازگشت مارتنزیت در فولاد زنگ نزن ۳۰۴ توسط شبکه‌های عصبی مصنوعی مدل شد. مدل به دست آمده کارآیی بالا و تطابق خوبی با واقعیت از خود نشان داد.
- ۲- با افزایش دما و زمان آنیل، درصد نسبی بازگشت افزایش می‌یابد. همچنین نرخ استحاله بازگشت در دماهای بالاتر بسیار بیشتر است.
- ۳- در هر دمایی می‌توان زمان بهینه آنیل برای دستیابی به فولاد کاملاً آستنیتی ریزدانه را با استفاده از این مدل به دست آورد. همچنین، بازگشت کامل مارتنزیت در یک زمان معقول، تنها در دماهای بالاتر از ۷۵۰ درجه سانتیگراد میسر است.

مراجع


- [1] T. Maki, "Stainless Steel: Progress in Thermomechanical Treatment", Current Opinion in Solid State and Materials Science, 1997, 2, pp.290-295.
- [2] K. Tomimura, S. Takaki, S. Tanimoto, Y. Tokunaga, "Optimal Chemical Composition in Fe-Cr-Ni Alloys for Ultra Grain Refining by Reversion from Deformation Induced Martensite", ISIJ International, 1991, 31, pp. 721-727.
- [3] H. Mirzadeh, A. Najafizadeh, "Correlation between processing parameters and strain-induced martensitic transformation in cold worked AISI 301 stainless steel", Materials Characterization, 2008, 59, pp. 1650-1654.
- [4] H. Mirzadeh, A. Najafizadeh, "ANN modeling of strain-induced martensite and its applications in metastable austenitic stainless steels", Journal of Alloys and Compounds, 2008, in press.
- [5] H. Mirzadeh, A. Najafizadeh, "Modeling the reversion of martensite in the cold worked AISI 304 stainless steel by artificial neural networks", Materials and Design, 2008, in press.
- [6] A. F. Padilha, R. L. Plaut, P. R. Rios, "Annealing of Cold-worked Austenitic Stainless Steels", ISIJ International, 2003, 43, pp. 135-143.
- [7] K. Tomimura, S. Takaki, Y. Tokunaga, "Reversion Mechanism from Deformation Induced Martensite to Austenite in Metastable Austenitic Stainless Steels", ISIJ International, 1991, 31, pp. 1431-1437.
- [8] A. Di Schino, I. Salvatori, J. M. Kenny, "Effects of Martensite Formation and Austenite Reversion on Grain Refining of AISI 304 Stainless Steel", Journal of Materials Science, 2002, 37, pp. 4561-4565.
- [9] I. Meszaros, J. Prohaszka, "Magnetic Investigation of the Effect of α' -martensite on the Properties of Austenitic Stainless Steel", Journal of Materials Processing Technology, 2005, 161, pp. 162-168.
- [10] L. F. M. Martins, R. L. Plaut, A. F. Padilha, "Effect of Carbon on the Cold-worked State and Annealing Behavior of Two18wt%Cr-8wt%Ni Austenitic Stainless Steels", ISIJ International, 1998, 38, 572-579.
- [11] C. M. Bishop, "Neural Networks for Pattern Recognition", 1995, Oxford, Clarendon Press.




شکل ۱. عملیات انجام شده در یک المان پردازنده.




شکل ۲. شرایط توقف آموزش شبکه.



شکل ۳. خطای مدل برای شبکه‌هایی با تعداد المان‌های پنهان مختلف.



شکل ۴. اثر دما و زمان آنیل بر درصد نسبی بازگشت.



شکل ۵. خطوط کانتور برای درصد نسبی بازگشت بر حسب دما و زمان آتیل.