

## Investigating the possibility of predicting iron recovery in iron ore processing plants based on feed grade using artificial intelligence

Mohammad Tahami<sup>1</sup> , Majid Shirvani<sup>2</sup> , Mohammad-Reza Mohammadi<sup>3</sup> ,  
Mohammad Ranjbar<sup>3</sup> , Mahin Schaffie<sup>3</sup> 

1. Faculty of Engineering, Shahid Bahonar University of Kerman, Kerman, Iran. E-mail: [tahami@eng.uk.ac.ir](mailto:tahami@eng.uk.ac.ir)
2. Faculty of Mining Engineering, Isfahan University of Technology, Isfahan, Iran. E-mail: [m.shirvani@mi.iut.ac.ir](mailto:m.shirvani@mi.iut.ac.ir)
3. Faculty of Engineering, Shahid Bahonar University of Kerman, Kerman, Iran. E-mail: [mohammadi.mrm@eng.uk.ac.ir](mailto:mohammadi.mrm@eng.uk.ac.ir)
4. Faculty of Engineering, Shahid Bahonar University of Kerman, Kerman, Iran. E-mail: [m.ranjbar@uk.ac.ir](mailto:m.ranjbar@uk.ac.ir)
5. Faculty of Engineering, Shahid Bahonar University of Kerman, Kerman, Iran. E-mail: [m.schaffie@uk.ac.ir](mailto:m.schaffie@uk.ac.ir)

### Article Info

**Article type:** research paper

#### Article history:

Received 6 August 2024

Received in revised form

13 November 2024

Accepted 6 December 2024

Published online 11 December 2024

### ABSTRACT

**Objective:** The aim of processing iron ore in processing plants is to achieve a product with an appropriate grade and maximum iron recovery. The amount of iron recovery in processing systems depends on several parameters, and its determination through weighing and laboratory tests is time-consuming and costly. With the development of the use of artificial intelligence for predicting and optimizing the performance of industrial systems, it seems that this technology could address many of the issues faced in mineral processing industries, including iron ore processing plants. Therefore, the objective of this research is to assess the feasibility of using artificial intelligence to predict iron recovery based on iron (Fe) and iron oxide (FeO) grades as the first step towards developing the application of this technology in the mining industry.

**Materials and methods:** For this study, daily data on the Fe and FeO grades in the feed as well as iron recovery from the Central Iron Ore Concentrate Plant, which includes two production lines (Choghart and Sechahun), were collected. Iron recovery modeling was performed using two neural network models: MLP (Multilayer Perceptron Neural Network) and CFNN (Cascade Forward Neural Network). In this modeling, the Fe and FeO grades of the feed were treated as the model inputs, while iron recovery was considered the output.

**Results:** The results showed that both models performed relatively similarly, but CFNN exhibited better statistical parameters. The  $R^2$  value for the CFNN model was obtained as 0.831 for the Choghart production line and 0.837 for the Sechahun line, while the RMSE for these models was calculated as 1.655 and 1.823, respectively. The analysis indicated that the CFNN model could confidently predict iron recovery with a relative error of less than 5% at a 95% confidence level for both production lines.

**Conclusions:** Using Fe and FeO grades alone as inputs for the models cannot lead to a comprehensive model that can replace conventional calculations. Therefore, the influence of other effective parameters will be thoroughly identified in this study. Additionally, sensitivity analysis revealed a direct relationship between iron recovery and both input parameters, with the Fe grade having a greater impact on iron recovery. The results of this study show that using artificial intelligence to predict iron recovery is very promising. By increasing model accuracy through the addition of data and input parameters, it is possible to develop models that can reduce the costs and time required for grade assessment in the plant.

#### Keywords:

Iron recovery;  
Magnetic separation;  
Modeling;  
Artificial neural networks,  
Mineral processing.

**Citation** Tahami, Shirvani, Mohammadi, Ranjbar, Schaffie (2024). Investigating the possibility of predicting iron recovery in iron ore processing plants based on feed grade using artificial intelligence, *Journal of Separation Science and Engineering*, 16 (2), 92-107. <http://doi.org/10.22103/jsse.2024.4559>



© The Author(s).

Publisher: Shahid Bahonar University of Kerman

## بررسی امکان پیش بینی بازیابی آهن در کارخانه های فرآوری سنگ آهن بر مبنای عیار خوراک با استفاده از هوش مصنوعی

محمد تهامی<sup>۱</sup>✉، مجید شیروانی<sup>۲</sup>، محمد رضا محمدی<sup>۳</sup>، محمد رنجبر<sup>۴</sup>، مهین شفیع<sup>۳</sup>

۱. دانشکده فنی و مهندسی، دانشگاه شهید باهنر کرمان، کرمان، ایران. رایانامه: [tahami@eng.uk.ac.ir](mailto:tahami@eng.uk.ac.ir)

۲. دانشکده مهندسی معدن، دانشگاه صنعتی اصفهان، اصفهان، ایران. رایانامه: [m.shirvani@mi.iut.ac.ir](mailto:m.shirvani@mi.iut.ac.ir)

۳. دانشکده فنی و مهندسی، دانشگاه شهید باهنر کرمان، کرمان، ایران. رایانامه: [mohammadi.mrm@gmail.com](mailto:mohammadi.mrm@gmail.com)

۴. دانشکده فنی و مهندسی، دانشگاه شهید باهنر کرمان، کرمان، ایران. رایانامه: [m.ranjbar@uk.ac.ir](mailto:m.ranjbar@uk.ac.ir)

۵. دانشکده فنی و مهندسی، دانشگاه شهید باهنر کرمان، کرمان، ایران. رایانامه: [m.schaffie@uk.ac.ir](mailto:m.schaffie@uk.ac.ir)

### چکیده

### اطلاعات مقاله

**هدف:** هدف از فرآوری سنگ آهن در کارخانه های فرآوری، دستیابی به محصولی با عیار مناسب و حداکثر بازیابی آهن است. میزان بازیابی آهن در سیستم های فرآوری به پارامترهای متعددی وابسته است که تعیین آن از طریق توزین و تست های آزمایشگاهی، زمان بر و پرهزینه می باشد. با توسعه استفاده از هوش مصنوعی برای پیش بینی و بهینه سازی عملکرد سیستم های صنعتی، به نظر می رسد که این فناوری بتواند راهگشای بسیاری از مسائل مطرح در صنایع فرآوری مواد معدنی، از جمله کارخانه های فرآوری سنگ آهن باشد. لذا هدف از این تحقیق، امکان سنجی استفاده از هوش مصنوعی برای پیش بینی بازیابی آهن بر مبنای عیار آهن (Fe) و اکسید آهن (FeO) به عنوان اولین قدم در راستای توسعه کاربرد این فناوری در صنایع معدنی است.

**مواد و روش:** برای انجام این پژوهش، داده های روزانه عیار Fe و FeO در خوراک و بازیابی آهن مربوط به کارخانه کنسانتره سنگ آهن مرکزی، که شامل دو خط تولید چغارت و سه چاهون است، جمع آوری شد. مدل سازی بازیابی آهن با استفاده از دو مدل MLP (Multilayerperceptron neural network) و CFNN (Cascade forward neural network) انجام گرفت. در این مدل سازی، عیار Fe و FeO خوراک به عنوان ورودی های مدل و بازیابی آهن به عنوان خروجی در نظر گرفته شدند.

نوع مقاله: علمی پژوهشی

تاریخچه مقاله:

دریافت: ۱۴۰۳/۰۵/۱۶

دریافت فایل اصلاح شده نهایی:

۱۴۰۳/۰۸/۲۳

پذیرش: ۱۴۰۳/۰۸/۱۶

انتشار: ۱۴۰۳/۰۹/۲۱

**نتایج:** هر دو مدل عملکرد نسبتاً مشابهی دارند، اما CFNN از پارامترهای آماری بهتری برخوردار است. مقدار  $R^2$  در مدل CFNN برای خطوط تولید چغارت و سه چاهون به ترتیب ۰/۸۳۱ و ۰/۸۳۷ به دست آمد، در حالی که RMSE این مدل ها به ترتیب ۱/۶۵۵ و ۱/۸۲۳ محاسبه شد. با بررسی نتایج مشخص گردید که مدل CFNN قادر است با اطمینان ۹۵ درصد، بازیابی آهن را با خطای نسبی کمتر از ۵ درصد برای هر دو خط تولید پیش بینی کند.

کلمات کلیدی:

بازیابی آهن،

جدایش مغناطیسی،

مدل سازی،

شبکه عصبی،

فرآوری مواد معدنی.

**نتیجه گیری:** استفاده از عیارهای Fe و FeO به تنهایی به عنوان ورودی مدل ها، نمی تواند به یک مدل جامع جهت جایگزینی با محاسبات مرسوم، تبدیل شود، لذا تاثیر سایر پارامترهای موثر کاملاً در این پژوهش مشخص می گردد. همچنین آنالیز حساسیت نشان داد که بازیابی آهن با هر دو پارامتر ورودی مدل رابطه مستقیم دارد، اما عیار Fe خوراک تأثیر بیشتری بر بازیابی آهن می گذارد. نتایج این تحقیق نشان می دهد که استفاده از هوش مصنوعی برای پیش بینی بازیابی آهن بسیار امیدوارکننده است. با افزایش دقت مدل ها از طریق افزودن داده ها و پارامترهای ورودی، می توان به مدلهایی دست یافت که قادر به کاهش هزینه ها و زمان مورد نیاز برای عیارسنجی در کارخانه هستند.

استناد: تهامی، شیروانی، محمدی، رنجبر، شفیع (۱۴۰۳). بررسی امکان پیش بینی بازیابی آهن در کارخانه های فرآوری سنگ آهن بر مبنای عیار

خوراک با استفاده از هوش مصنوعی جداسازی، (۲) ۱۶، ۱۰۷-۹۲. <http://doi.org/10.22103/jsse.2024.4559>



© نویسندگان

ناشر: دانشگاه شهید باهنر کرمان

## ۱- مقدمه

آهن به عنوان دومین فلز از نظر فراوانی در پوسته زمین، نقش کلیدی در اقتصاد امروزی ایفا می کند. این فلز در صنایع فولاد سازی تولید شده و سنگ آهن به عنوان پایه و اساس این صنایع می باشد [۱، ۲]. در حال حاضر، صنعت فولاد جهان از ذخایر غنی هماتیت، گوتیت و خصوصاً مگنتیت تامین می شود. جدایش مغناطیسی، کارآمدترین روش برای تغلیظ کانسنگ های مگنتیتی می باشد [۳، ۴]. پرعیارسازی سنگ معدن مگنتیتی جهت رسیدن به عیار مطلوب عموماً با استفاده از روش های جدایش مغناطیسی تر انجام می شود [۵]. جداکننده های مغناطیسی تر با شدت میدان پایین ( $WLIMS^1$ )، متداول ترین سیستم برای تغلیظ کانسنگ های مگنتیتی می باشند [۶-۸]. عوامل زیادی در جداکننده های مغناطیسی تر تاثیر گذارند. مهم ترین شاخص های موثر بر عیار و بازیابی کنسانتره شامل دامنه دلنه بندی ذرات، درجه آزادی، خواص مغناطیسی کانی ها و بافت سنگ می باشد [۹-۱۴]. جداکننده های مغناطیسی تر شامل یک استوانه (درام) توخالی و چرخان است که چندین آهنربای ثابت با قطب های متناوب درون آن قرار دارد. کانی های با خواص فرومغناطیسی مثل مگنتیت حساسیت بالایی در میدان های مغناطیسی کم دارند و بنابراین می توانند توسط جداکننده های مغناطیسی شدت پایین (کمتر از ۰/۳ تسلا) تغلیظ شوند. در جداکننده های مغناطیسی شدت پایین، میدان استاندارد برای جداکننده ۰/۱۲ تسلا در فاصله ۵۰ میلی متری از سطح درام بوده و حداکثر شدت میدان مغناطیسی در سطح درام، کمتر از ۰/۳ تسلا می باشد [۱۵].

یکی از مهمترین چالش ها در فراوری سنگ آهن، پیش بینی بازیابی بهینه وزنی آهن در کارخانه های فراوری می باشد که از جداکننده های مغناطیسی تر استفاده می کنند. این پیش بینی معمولاً با استفاده از تست لوله دیویس در آزمایشگاه انجام می گردد. آزمایش لوله دیویس به زمان طولانی، نیروی انسانی و هزینه بالایی نیاز دارد. برای حل این مشکل، شاهچراغی و همکاران، یک مدل ساده، سریع و دقیق برای پیش بینی بازیابی وزنی تست لوله دیویس از طریق عیار Fe و FeO با استفاده از تکنیک رگرسیون تطبیقی چند متغیره (MARS) پیشنهاد دادند. این مدل با حدود ۹۰۰۰ داده از معادن مختلف سنگ آهن ایران اعتبار سنجی شد و مقادیر  $R^2$  و جذر میانگین مربعات خطا (RMSE) برای مدل در مرحله آموزش (Train) به ترتیب ۰/۹۸۱ و ۲/۳۶۴ و در مرحله تست (Test)، به ترتیب برابر با ۰/۹۷۸ و ۲/۵۳۸ بدست آمد [۱۶]. تهامی و همکاران برای مدل سازی بازیابی آهن در تست لوله دیویس از حدود ۶۵۰ داده استفاده کردند. در این مطالعه از شبکه های عصبی رگرسیون عمومی (GRNN) و تابع شعاعی پایه (RBF) بهره گیری شد و پیش بینی بازیابی آهن با استفاده از عیار Fe و FeO خوراک به عنوان ورودی مدل انجام گرفت. در نهایت مدل GRNN عملکرد بهتری از خود نشان داد و  $R^2$  آن برابر با ۰/۹۷۶ محاسبه گردید [۱۷]. همچنین در پژوهشی، یک شبکه عصبی پیش خور برای پیش بینی کارایی و انتخابی بودن فرآیند جدایش مغناطیسی با استفاده از پارامترهای عیار آهن، اکسید آهن و گوگرد توسعه یافت. این مدل با الگوریتم ژنتیکی انجام شد و میانگین مربعات خطای آن، ۰/۲۷۶ و ۱/۷۸۲ و  $R^2$  آن برابر با ۰/۹۵ و ۰/۹۲ به ترتیب برای لندیس انتخاب پذیری و بازدهی جدایش به دست آمد [۱۸]. تحقیقات پیشین نشان می دهند که پیش بینی بازیابی آهن از طریق تست لوله دیویس محور برخی از تحقیقات بوده است اما پیش بینی بازیابی آهن توسط داده های کارخانه تاکنون

<sup>1</sup> Wet Low Intensity Magnetic Separator

انجام نشده است. انجام تست دیویس تیوب و سایر تست های آزمایشگاهی مستلزم صرف زمان و هزینه می باشد. لذا در این تحقیق، برای نخستین بار از داده های کارخانه، برای پیش بینی بازیابی آهن استفاده شده است. برای محاسبه بازیابی آهن در کارخانه، باید عیار و تناژ کنسانتره تعیین گردد. برای این مقصود، عیارسنجی در آزمایشگاه انجام شده و جرم کنسانتره توسط تجهیزاتی مثل دستگاه توزین نوارنقاله (Belt Scale) بدست می آید [۱۹]. سپس بازیابی از طریق رابطه ۱ محاسبه خواهد شد [۱۵].

$$\text{Iron Recovery} = \frac{cC}{fF} \quad (1)$$

که در آن  $c$  عیار کنسانتره،  $C$  تناژ کنسانتره،  $f$  عیار خوراک و  $F$  تناژ خوراک می باشد. عیارسنجی، توزین و محاسبه بازیابی آهن در کنسانتره، نیازمند صرف زمان و هزینه است. پیش بینی بازیابی آهن می تولد از دو جهت حائز اهمیت باشد: ۱- رسیدن به مدلی قابل اطمینان جهت کاهش هزینه های عیارسنجی و صرفه جویی در زمان ۲- تعیین بازیابی آهن بار ورودی به کارخانه پیش از خوراک دهی. با توجه به اینکه تاکنون پیش بینی میزان بازیابی آهن در کارخانه های فرآوری سنگ آهن مورد بررسی قرار نگرفته است، این تحقیق به عنوان یک اقدام اولیه انجام شده تا به توسعه مدلی برای پیش بینی بازیابی آهن دست یابد. هدف از این تحقیق پیش بینی بازیابی آهن در کنسانتره کارخانه فرآوری سنگ آهن مرکزی با استفاده از عیار آهن (Fe) و اکسید آهن (FeO) خوراک کارخانه می باشد. برای این منظور ابتدا داده های کارخانه کنسانتره سنگ آهن مرکزی جمع آوری شد، سپس توسط شبکه عصبی و از طریق عیار Fe و FeO خوراک به عنوان داده های ورودی، مدلسازی انجام گردید.

#### ۱-۱- کارخانه کنسانتره مجتمع سنگ آهن مرکزی

کارخانه فرآوری مجتمع سنگ آهن مرکزی در سال ۱۳۸۴ به بهره برداری رسید. این کارخانه شامل دو خط تولید مستقل برای پرعیارسازی کانسنگ چغارت و سه چاهون می باشد که مجموع خوراک ورودی کارخانه، ۸ میلیون تن در سال در نظر گرفته شده است [۲۰]. در خط تولید چغارت، کانسنگ آهن استخراج شده از معدن چغارت پس از آسیاکنی تر توسط آسیای خود شکن، پس از عبور از سرند، به اولین مرحله جدایش مغناطیسی (کوبر) با ۴ درام ۳۸۰۰ گوس هم جهت با جریان پالپ وارد می شود. باطله آن به تیکنر باطله ارسال می شود و محصول کوپر به مدار آسیای گلوله ای جهت رسیدن به درجه آزادی مطلوب وارد شده و سپس به مرحله رافر وارد می شود. مراحل رافر و کلیئر شامل ۳ ردیف درام موازی ۲۸۰۰ گوس و نوع هم جهت با جریان پالپ می باشند. محصول درام های مغناطیسی مرحله رافر به کلیئر منتقل می شود و باطله آن ها به عنوان باطله از خط خارج می گردد. محصول کلیئر دارای عیاری مطلوب (معمولا ۶۷ درصد آهن) می باشد و به عنوان کنسانتره از خط خارج شده و در نهایت با کنسانتره خط سه چاهون مخلوط می شود. باطله مرحله کلیئر نیز جهت بازیابی مجدد آهن به مدار آسیای گلوله ای بازگردانده می شود [۲۰].

در خط تولید سه چاهون، سنگ آهن استخراج شده از معادن سه چاهون بعد از پرعیارسازی خشک، وارد آسیای خودشکن می شود. سایر بخش های فرآوری خط تولید سه چاهون مشابه با چغارت می باشد با این تفاوت که شدت میدان مغناطیسی تمامی جداکننده های مغناطیسی ۱۷۰۰ گوس بوده و از نوع غیر هم جهت با جریان پالپ می باشند [۲۰].



## ۲- جمع آوری داده ها

برای مدلسازی، داده های روزانه مربوط به عیار Fe و FeO خوراک و بازیابی آهن از تاریخ ۱۴۰۲/۰۱/۰۱ الی ۱۴۰۳/۰۱/۲۴ از کارخانه کنسانتره سنگ آهن مرکزی جمع آوری گردید. تعداد داده ها برای خط تولید چغارت ۳۷۳ عدد و برای خط تولید سه چاهون ۳۷۸ عدد بودند. جهت محاسبه عیار Fe و FeO در کارخانه، نمونه گیری توسط نمونه گیرهای خودکار هر ۲ ساعت یکبار از خوراک، کنسانتره و باطله انجام شده است، سپس عیارسنجی نمونه ها در آزمایشگاه و به روش تیتراسیون، صورت گرفته است. تمامی داده ها به صورت روزانه بوده و فارغ از تعداد ساعات کاری و توقفات کارخانه می باشد. تناژ کنسانتره از طریق دستگاه توزین نوار نقاله (Belt Scale) اندازه گیری شده و هر دو ساعت با استفاده از نمونه گیری، درصد رطوبت و متعاقباً تناژ خشک کنسانتره و بازیابی آهن از طریق رابطه ۱ محاسبه شده است. برای درک بهتر، توصیف آماری کلیه داده ها در جدول (۱) برای هر دو خط چغارت و سه چاهون ارائه شده است. در این جدول Fe و FeO مربوط به خوراک خط تولید و Re، بازیابی آهن در کنسانتره می باشد. داده های Fe و FeO خوراک به عنوان داده های ورودی مدل، و بازیابی آهن به عنوان خروجی مدل در نظر گرفته شدند.

## ۳- پیاده سازی مدل ها

۳-۱- مدل پرسپترون چندلایه<sup>۲</sup> (MLP)

شبکه های عصبی چندلایه (MLP) یکی از رایج ترین و محبوب ترین شبکه های عصبی مصنوعی (ANN) هستند. این شبکه عصبی پیش خور، از لایه های مختلفی تشکیل شده است. اولین و آخرین لایه ها، به ترتیب، لایه های ورودی و خروجی بوده که با داده های ورودی مدل و خروجی های آن مرتبط هستند. از سوی دیگر، پردازش اطلاعات، در لایه های میانی که به عنوان لایه های مخفی شناخته می شوند، انجام می گیرد [۲۱].

جدول ۱- توصیف آماری پارامترهای ورودی و خروجی مدل

Table 1: Statistical description of the input and output parameters of the model

| Sechahun line |       |       | Choghart Line |       |       | شاخص ها (Mertrics) %              |
|---------------|-------|-------|---------------|-------|-------|-----------------------------------|
| %Re           | %FeO  | %Fe   | %Re           | %FeO  | %Fe   |                                   |
| 50.83         | 13.47 | 38.35 | 60.52         | 17.38 | 45.39 | میانگین (Mean)                    |
| 36.32         | 10.70 | 30.79 | 46.40         | 12.48 | 37.95 | حداقل (Minimum)                   |
| 65.19         | 16.33 | 46.72 | 71.07         | 21.70 | 51.16 | حداکثر (Maximum)                  |
| 51.18         | 13.41 | 38.45 | 60.73         | 17.27 | 45.50 | میانه (Median)                    |
| 51.76         | 13.38 | 34.92 | 59.48         | 17.08 | 45.77 | مد (Mode)                         |
| -0.28         | 0.09  | -0.13 | -0.33         | 0.05  | -0.32 | چولگی (Skewness)                  |
| 0.18          | -0.28 | 0.16  | 0.16          | 0.27  | 0.25  | کشیدگی (Kurtosis)                 |
| 4.52          | 1.09  | 2.40  | 3.95          | 1.48  | 2.15  | انحراف معیار (Standard Deviation) |

لایه‌های مخفی، ارتباط بین ورودی‌های مدل و خروجی‌ها را برقرار می‌کنند. متغیرهای ورودی به تعداد یکسانی نورون نیاز دارند، در حالی که تعداد خروجی‌ها عموماً با پارامترهای مطلوب مطابقت دارد. رویکرد آزمون و خطا برای بهینه‌سازی تعداد لایه‌های مخفی و همچنین تعداد نورون‌ها در هر لایه مخفی به کار گرفته می‌شود. در ساختار پرسپترون چندلایه (MLP)، معمولاً برای بسیاری از مسائل، استفاده از یک لایه مخفی کافی است، اما برای مسائل پیچیده‌تر بهبود عملکرد مدل می‌تواند با حداقل دو لایه مخفی حاصل شود. در لایه مخفی، هر نورون به تمام نورون‌های موجود در لایه‌های قبلی و بعدی متصل می‌شود. برای به دست آوردن مقدار هر نورون، وزنی مقادیر هر نورون در لایه‌های قبلی با اضافه کردن یک عامل بلیاس به این مجموع انجام می‌گیرد. در نهایت، مقدار حاصل، از یک تابع فعال‌سازی عبور می‌کند [۲۲، ۲۳]. شکل (۱) ساختار شبکه عصبی چندلایه با دو لایه مخفی که در این مطالعه استفاده شده است را نشان می‌دهد. توابع فعال‌سازی که می‌توانند برای لایه‌های خروجی و مخفی به کار روند، در معادلات (۲-۴) آورده شده است.

$$\text{Sigmoid: } f(z) = \frac{1}{1 + e^z} \quad (۲)$$


$$\text{Tansig تابع: } f(z) = \frac{2}{1 + e^{-2z}} - 1 \quad (۳)$$

$$\text{Purelin: } f(z) = z \quad (۴)$$

اگر ساختار MLP به گونه‌ای باشد که دو لایه مخفی با توابع فعال‌سازی داشته باشد، و Purelin به عنوان تابع فعال‌سازی لایه خروجی باشد، خروجی مدل از طریق رابطه (۵) محاسبه می‌شود:

$$\text{خروجی} = \text{Purelin}(w_3 \times (\log \text{sig}(w_2 \times (\tan \text{sig}(w_1 x) + b_1)) + b_2) + b_3) \quad (۵)$$

که در آن  $w_1, w_2, w_3$  و  $b_1, b_2, b_3$  به ترتیب بردارهای بایاس لایه‌های مخفی اول، دوم و لایه خروجی هستند. الگوریتم‌های بهینه‌سازی (الگوریتم‌های آموزش) به طور مستقیم بر عملکرد و قابلیت پیش‌بینی مدل MLP تأثیر می‌گذارند زیرا به آموزش شبکه عصبی کمک می‌کنند.



شکل ۱- شماتیکی از ساختار شبکه عصبی MLP


Figure1: Schematic of the structure of the MLP neural network

### ۲-۳- مدل پیش‌خور آبشاری<sup>۲</sup> (CFNN):

ایده اضافه کردن اتصالات بیشتر در معماری شبکه پیش‌خور از شبکه پیش‌خور معمولی می‌تواند قابلیت اکتشاف رابطه بین متغیرهای وابسته و مستقل شبکه را بهبود ببخشد [۲۴]. CFNN یا شبکه عصبی پیش‌رو

<sup>3</sup> Cascade forward neural network

گسترش یافته نوعی از شبکه‌های عصبی پس انتشار (Back-Propagation) است که ساختاری متفاوت نسبت به شبکه‌های پیش‌خور سنتی دارد. اصلی‌ترین تفاوت بین این شبکه‌ها تعداد اتصالات موجود بین متغیرهای هدف و متغیرهای مستقل است. در اولین لایه این شبکه یک پیوند وزنی که فقط از لایه ورودی وارد می‌شود وجود دارد، در حالی که سایر لایه‌های بعدی دارای اتصالات وزنی هستند که از ورودی و تمام لایه‌های قبلی وارد می‌شوند. در CFNN، همانند دیگر شبکه‌های پیش‌خور، لایه‌های پنهان متصل شده و توابع فعال‌سازی وجود دارند. نورون‌ها دارای بایاس‌های خود هستند و اتصالات دارای وزن‌های مشخص می‌باشند. در مدل‌سازی شبکه‌های عصبی، باید مجموعه‌ای از وزن‌های تنظیم شده ایجاد شود، به طوری که خطای پیش‌بینی مدل به سطح حداقل قابل قبول برسد [۲۵]. یک تصویر شماتیک از ساختار CFNN (با ۲ لایه پنهان) و اتصالات بین پارامترهای خروجی و ورودی در شکل (۲) نشان داده شده است.



شکل ۲- شماتیک از ساختار شبکه عصبی CFNN  
Figure2: Schematic of the structure of the CFNN neural network

#### ۴- ارزیابی مدل‌ها

##### ۴-۲- تحلیل آماری

برای ارزیابی عملکرد مدل، پارامترهای آماری مانند ضریب تعیین ( $R^2$ )، انحراف معیار (SD)، ریشه میانگین مربعات خطا (RMSE)، میانگین درصد خطای مطلق نسبی (AAPRE) و میانگین درصد خطای نسبی (APRE) به کار گرفته می‌شوند. تعاریف این پارامترها در معادلات (۶-۱۰) ارائه شده است.

$$R^2 = 1 - \frac{\sum_{i=1}^N (IR_{i,exp} - IR_{i,pred})^2}{\sum_{i=1}^N (IR_{i,pred} - \bar{IR}_{i,exp})^2} \quad (6)$$

$$SD = \sqrt{\frac{1}{N-1} \sum_{i=1}^N \left( \frac{IR_{i,exp} - IR_{i,pred}}{IR_{i,exp}} \right)^2} \quad (7)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (IR_{i,exp} - IR_{i,pred})^2} \quad (8)$$

$$AAPRE = \frac{100}{N} \sum_{i=1}^N \left| \frac{IR_{i,exp} - IR_{i,pred}}{IR_{i,exp}} \right| \quad (9)$$

$$APRE = \frac{100}{N} \sum_{i=1}^N \left( \frac{IR_{i,exp} - IR_{i,pred}}{IR_{i,exp}} \right) \quad (10)$$

که در آن ها  $IR^4$  بازیابی آهن و  $N$  نشان دهنده تعداد نمونه ها می باشد.  $i,exp$  و  $i,pred$  به ترتیب بازیابی های آهن مربوط به کارخانه و بازیابی های پیش بینی شده توسط مدل می باشد.

#### ۴-۲- تحلیل نموداری

نمودارهای متقاطع، مقادیری پیش‌بینی شده توسط مدل را با مقادیر تجربی (داده های جمع آوری شده از کارخانه) مقایسه می کنند که به آن‌ها نمودارهای برابری (Equality Plots) نیز گفته می‌شود. در یک مدل با عملکرد مناسب، نقاط داده در نزدیک حالت به خط  $X = Y$  قرار می گیرند. نمودارهای توزیع خطا روند توزیع خطای نسبی را نسبت به خط خطای صفر نشان می‌دهند. در این مطالعه،  $E_i$  با استفاده از معادله (۱۱) محاسبه شده و به صورت درصد خطای نسبی نمایش داده می‌شود. در این پژوهش نمودار بازیابی کارخانه نسبت به بازیابی پیش بینی شده بیانگر این نمودار می باشد.

$$E_i = \left[ \frac{IR_{i,exp} - IR_{i,pred}}{IR_{i,exp}} \right] \times 100 \quad i = 1,2,3, \dots, N \quad (11)$$

بررسی اینکه یک مدل چند درصد از داده ها را می تواند با یک خطای مشخص پیش بینی کند، با رسم فراوانی تجمعی داده‌ها در برابر خطای نسبی مطلق تعیین می‌شود. در این نمودار هرچه شیب خط بیشتر باشد، مدل از خطای کمتری برخوردار است. در این مطالعه،  $E_a$  با استفاده از معادله (۱۲) محاسبه شده و به صورت درصد خطای نسبی مطلق بیان می‌شود.

$$E_a = |E_i| \quad (12)$$

نمودار روند (Trend plot) نشان می‌دهد که خروجی مدل نسبت به یک ورودی خاص چگونه تغییر می‌کند و می‌توان روندهای صعودی و نزولی را توسط آن تشخیص داد. در این تحقیق، نمودار بازیابی نسبت به عیار  $Fe$  و  $FeO$  به عنوان نمودارهای روند می باشند.

#### ۵- نتایج و بحث

##### ۵-۲- ارزیابی و مقایسه مدل ها

برای ارزیابی اعتبار و کارایی مدل‌ها در پیش‌بینی بازیابی آهن بر اساس عیار  $Fe$  و  $FeO$  خوراک کارخانه، پارامترهای آماری شامل  $APRE$ ،  $AAPRE$ ،  $RMSE$ ،  $SD$  و  $R^2$  در هر دو مدل  $MLP$  و  $CFNN$  محاسبه شد. تمام داده‌های آماری ذکر شده، در جدول (۲) نمایش داده شده است. بر اساس جدول ۲،  $R^2$  هر دو مدل به ۱ بسیار نزدیک است که نشان‌دهنده عملکرد بالای مدل‌ها در پیش‌بینی بازیابی آهن است. با این حال، مدل  $MLP$  در تمام معیارهای آماری نسبت به مدل  $CFNN$  عملکرد بهتری را دارد.

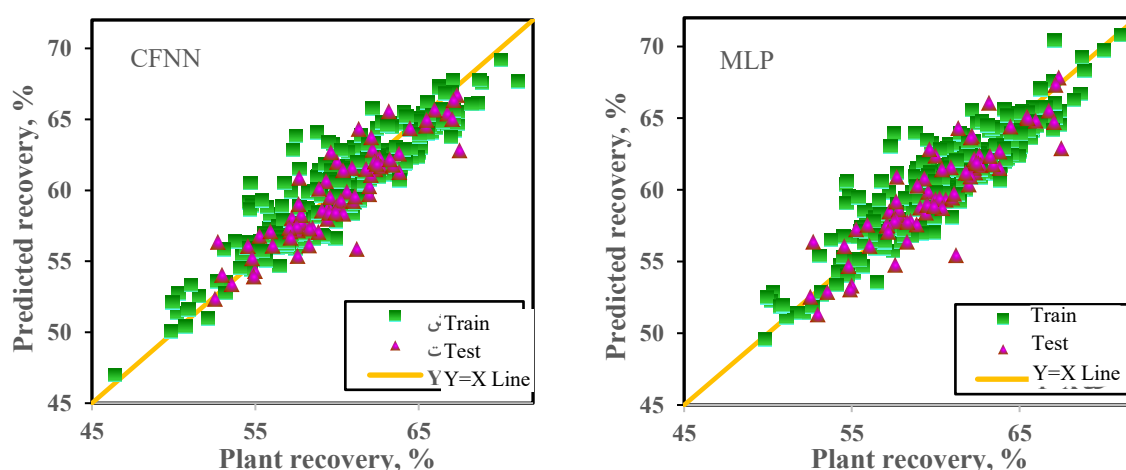
جدول ۲- داده های آماری مربوط به دو مدل CFNN و MLP برای خط تولید چغارت و سه چاهون

Table 2: Statistical data on two CFNN and MLP models for the Chagart and Sechahun production line

| R <sup>2</sup> | SD    | RMSE  | AAPRE, % | APRE, % |       |      |                      |
|----------------|-------|-------|----------|---------|-------|------|----------------------|
| 0.831          | 0.002 | 1.655 | 2.181    | -0.002  | Train |      |                      |
| 0.806          | 0.003 | 1.585 | 2.016    | 0.526   | Test  | CFNN |                      |
| 0.827          | 0.001 | 1.641 | 2.148    | 0.105   | Total |      | <b>Choghart Line</b> |
| 0.827          | 0.002 | 1.676 | 2.180    | -0.130  | Train |      |                      |
| 0.795          | 0.003 | 1.631 | 2.053    | 0.314   | Test  | MLP  |                      |
| 0.822          | 0.001 | 1.667 | 2.155    | -0.040  | Total |      |                      |
| 0.837          | 0.002 | 1.823 | 2.550    | -0.384  | Train |      |                      |
| 0.796          | 0.005 | 2.044 | 3.091    | -0.333  | Test  | CFNN |                      |
| 0.829          | 0.002 | 1.870 | 2.659    | -0.374  | Total |      | <b>Sechahun Line</b> |
| 0.832          | 0.002 | 1.852 | 2.613    | -0.774  | Train |      |                      |
| 0.775          | 0.005 | 2.148 | 3.346    | -0.911  | Test  | MLP  |                      |
| 0.820          | 0.002 | 1.915 | 2.760    | -0.801  | Total |      |                      |

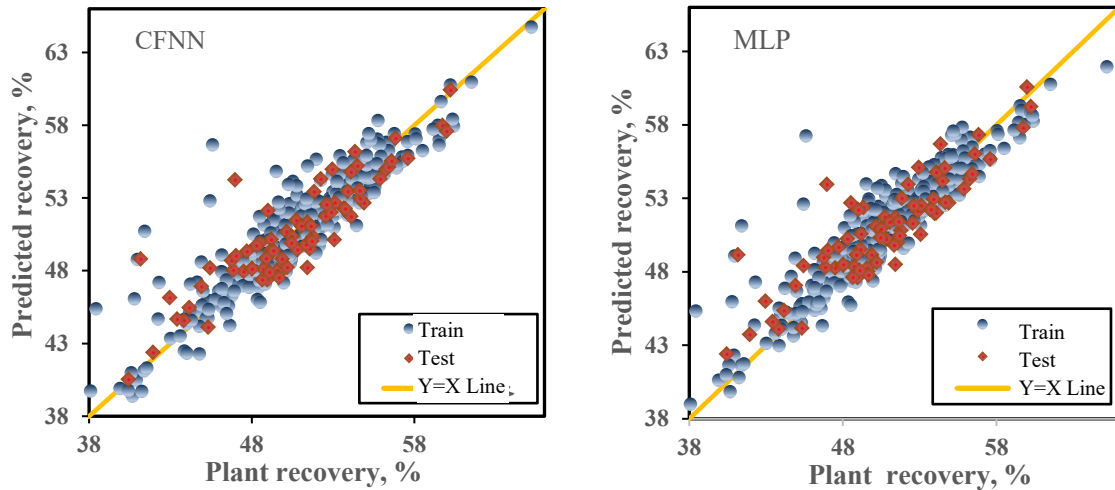
در هر دو مدل ۸۰ درصد داده ها به عنوان داده های آموزش (Train) و مابقی به عنوان تست (Test) در نظر گرفته شدند. با توجه به جدول ۲، توانایی هر دو مدل CFNN و MLP برای پیش بینی بازیابی کارخانه مطلوب بوده و مدل CFNN با اندکی اختلاف از پارامترهای آماری بهتری برخوردار است.

برای مقایسه و تحلیل مدل ها از طریق نموداری، نمودار متقاطع هر دو مدل برای خط تولید چغارت و سه چاهون به ترتیب در شکل (۳) و شکل (۴) نشان داده شده است. طبق نمودارهای متقاطع، اکثر نقاط برای هر دو مدل در این نمودار به خط  $Y=X$  نزدیک هستند و تفاوت قابل توجهی بین دو مدل در این نمودار قابل مشاهده نیست.



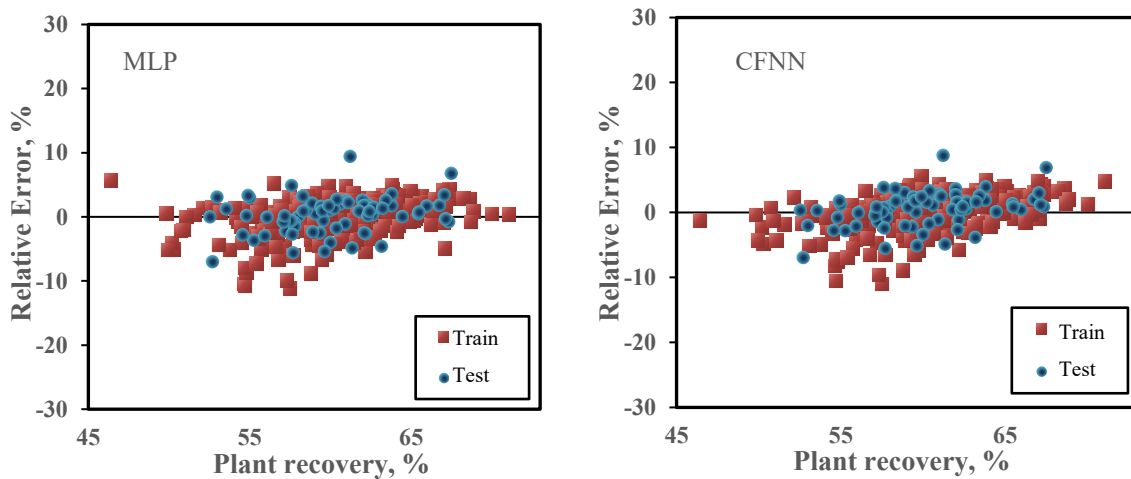
شکل ۳- نمودار های متقاطع مدل ها برای داده های بازیابی خط تولید چغارت

Figure 3: Cross-plots of models for recoveries of Chogart production line



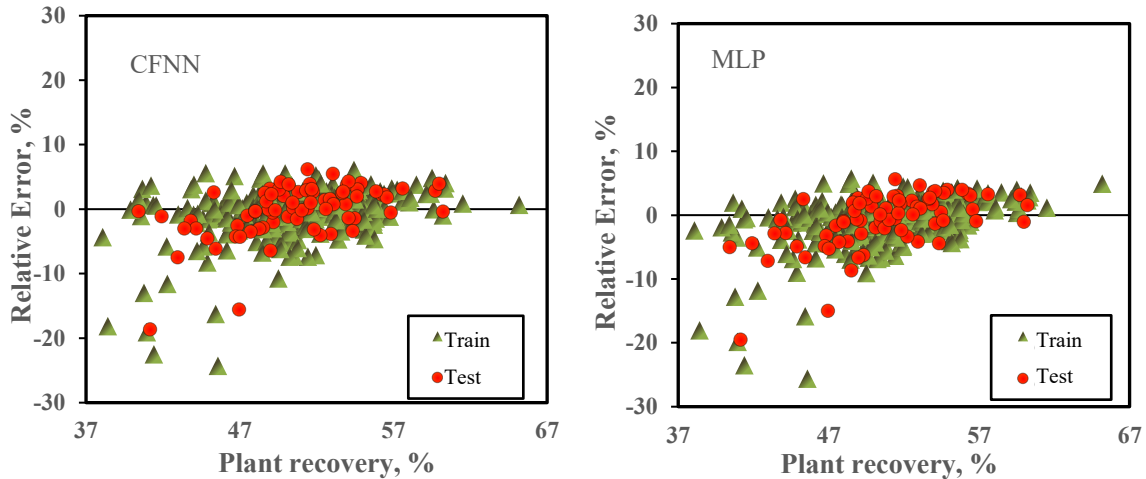
شکل ۴- نمودارهای متقاطع مدل‌ها برای داده‌های بازیابی خط تولید سه چاهون  
 Figure 4: Cross-plots of models for recoveries of Sechahun production line

نمودار توزیع خطای نسبی دو مدل CFNN و MLP برای هر دو خط تولید نسبت به بازیابی کارخانه در شکل (۵ و ۶) نمایش داده شده است. همانطور که مشاهده می‌گردد، خطای نسبی مدل‌ها برای خط تولید چغارت در محدوده ۱۰- الی ۱۰ درصد قرار می‌گیرد و مدل در مقادیر مختلف مقادیر بازیابی، عملکرد مشابهی دارد. این در حالی است که خطای نسبی مدل‌ها برای خط تولید سه چاهون در مقادیر بازیابی پایین، برای معدودی از داده‌ها به ۲۵- درصد نیز می‌رسد. اما تمرکز داده‌ها در این مقادیر، کم می‌باشد که می‌تواند نشان‌دهنده عملکرد نامناسب کارخانه در این مواقع و وجود خطاهای خارج از مدل باشد.



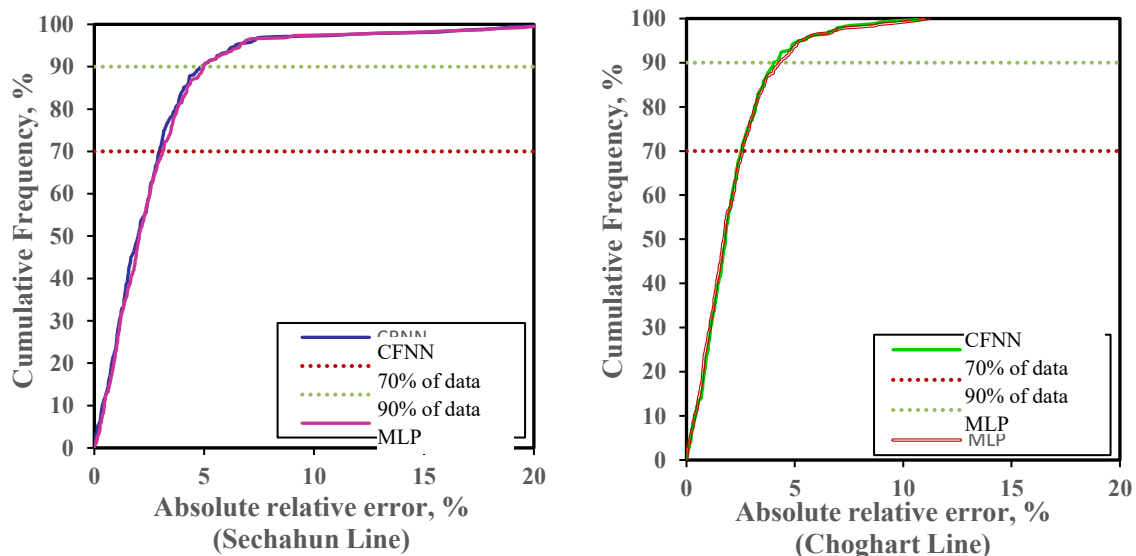
شکل ۵- نمودارهای توزیع خطای نسبی مدل‌ها برای خط تولید چغارت  
 Figure 5: Error distribution plots of models for Chogart production line





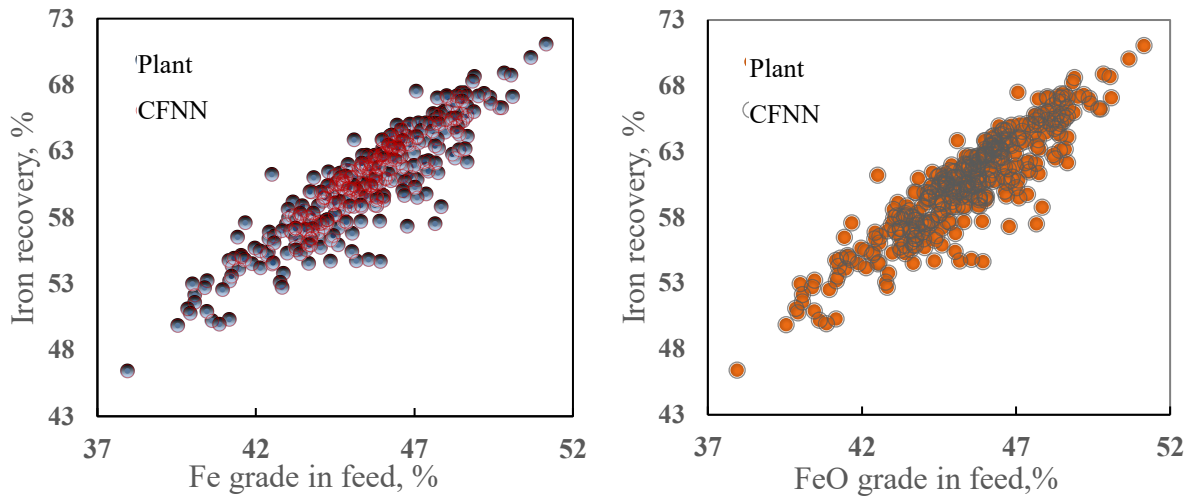
شکل ۶- نمودارهای توزیع خطای نسبی مدل ها برای خط تولید سه چاهون  
Figure 6: Error distribution plots of models for Sechahun production line

شکل (۷) فراوانی تجمعی داده‌ها را نسبت به خطای نسبی مطلق ( $E_a$ ) برای مدل‌های CFNN و MLP برای هر دو خط تولید را نشان می‌دهد. همانطور که مشاهده می‌شود، بیش از ۷۰٪ پیش‌بینی‌های هر دو مدل دارای خطای نسبی مطلق کمتر از ۳٪ هستند. همچنین برای حدود ۹۰٪ از بازیابی‌های آهن پیش‌بینی‌شده، خطای مطلق نسبی مدل کمتر از ۵٪ می‌باشد. همچنین دو مدل در این نمودار تفاوت بارزی با یکدیگر ندارند.

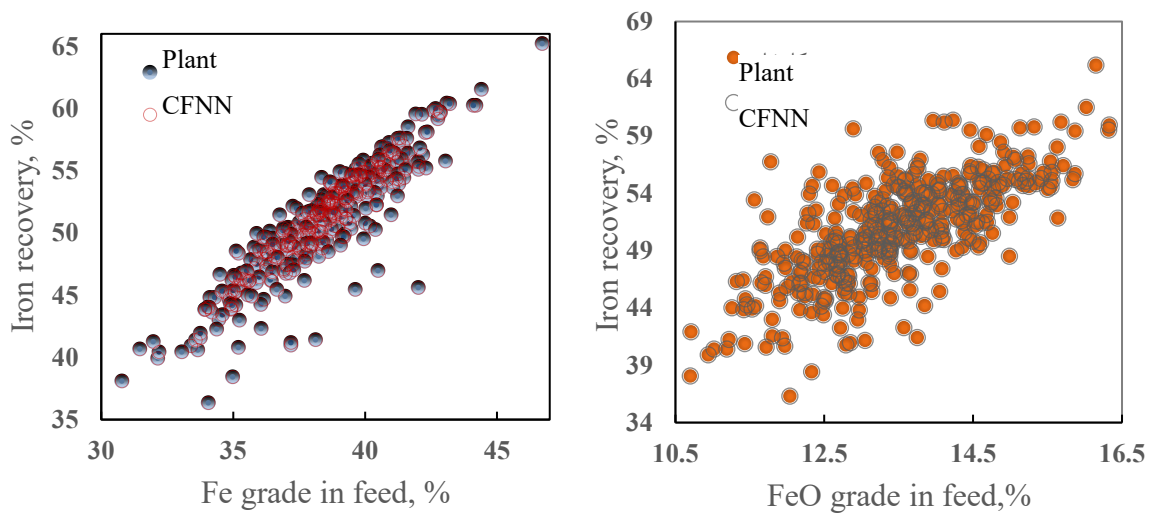


شکل ۷- نمودارهای فراوانی تجمعی خطای مدل ها برای هر دو خط تولید  
Figure 7: Cumulative frequency plots of models for both production lines

شکل (۸ و ۹) نمودارهای روند بازیابی آن نسبت به عیار Fe و FeO خوراک را برای خط تولید چغارت و سه چاهون نشان می‌دهد. در این شکل از مدل CFNN که عملکرد نسبتاً بهتری برخوردار بود، استفاده شد. همانطور که مشاهده می‌شود، رابطه بازیابی آهن نسبت به هر دو عیار خوراک صعودی بوده و با افزایش عیار های Fe و FeO در خوراک، بازیابی نیز افزایش می‌یابد. در خط تولید سه چاهون بازیابی آهن نسبت به عیار Fe خوراک صعودی عمل می‌کند ولی نسبت به FeO خوراک، روند صعودی از پراکندگی بالایی برخوردار است.



شکل ۸- نمودارهای روند بازیابی آهن برای خط تولید چغارت  
Figure 8: Trend plots of iron recovery for chogart production line



شکل ۹- نمودارهای روند بازیابی آهن برای خط تولید سه چاهون  
Figure 9: Trend plots of iron recovery for Sechahun production line

### ۳-۵- آنالیز حساسیت<sup>۵</sup>

در بخش قبل تاثیر هر پارامتر ورودی نسبت به بازیابی آهن به صورت نموداری مشخص شد، در این قسمت برای بررسی کمی تأثیر عیار Fe و FeO در خوراک، بر بازیابی آهن، عامل ارتباط<sup>۶</sup> (RF) برای تحلیل حساسیت معرفی شد. در واقع، بازیابی آهن بیشتر تحت تأثیر پارامتری با مقدار RF بالاتر است. برای اندازه‌گیری عامل ارتباط، از معادله (۱۳) استفاده می‌شود [۲۶].

$$RF(inp_i, IR) = \frac{\sum_{j=1}^n (inp_{i,j} - inp_{ave,i})(IR_j - IR_{ave})}{\sqrt{\sum_{j=1}^n (inp_{i,j} - inp_{ave,i})^2 \sum_{j=1}^n (IR_j - IR_{ave})^2}} \quad (13)$$

<sup>5</sup> Sensitivity analysis

<sup>6</sup> Relevancy Factor

که در آن  $\text{inp}_{\text{ave},i}$  مقادیر متوسط  $i$ -امین ورودی و  $\text{inp}_{i,j}$   $j$ -امین مقدار از ورودی  $i$ -ام می‌باشند. بنابراین، حداکثر  $J$  برابر با تعداد داده‌های هر خط تولید و حداکثر  $I$  برابر با تعداد پارامتر ورودی یعنی ۲ می‌باشد. در اینجا، عامل ارتباط در خط تولید چغارت برای عیار  $\text{Fe}$  ۰/۹ و برای عیار  $\text{FeO}$  ۰/۶ و برای خط تولید سه چاهون به ترتیب ۰/۹ و ۰/۷ محاسبه شد. در نتیجه مشخص می‌شود که بازیابی آهن با هر دو عیار  $\text{Fe}$  و  $\text{FeO}$  رابطه مستقیم دارد، اما عیار  $\text{Fe}$  تأثیر بیشتری بر روی بازیابی آهن می‌گذارد.

با توجه به اینکه هدف از این تحقیق بهره‌گیری از الگوریتم‌های هوش مصنوعی برای صرفه‌جویی در زمان و هزینه‌ها بود و به همین سبب، تنها از دو پارامتر  $\text{Fe}$  و  $\text{FeO}$  خوراک به عنوان ورودی‌های مدل و نماینده مهم‌ترین عوامل موثر استفاده گردید، پیشنهاد می‌گردد که در تحقیقات آینده برای افزایش دقت مدل از سایر پارامترهای موثر مثل درجه آزادی، کانی‌شناسی و پارامترهای عملیاتی کارخانه نیز در مدل سازی استفاده گردد. در این مقاله تنها از دو مدل هوش مصنوعی استفاده شد در نتیجه، بهره‌گیری از سایر مدل‌های هوشمند، افزایش تعداد داده‌های ورودی و مقایسه آن‌ها با یکدیگر نیز توصیه می‌گردد.

## ۶- نتیجه‌گیری

در کارخانه‌های فراوری سنگ آهن، بازیابی آهن از طریق توزین و عیار سنجی خوراک و کنسانتره محاسبه می‌شود. این عمل نیازمند صرف زمان و هزینه است. در این پژوهش برای پیش‌بینی بازیابی آهن، از دو مدل CFNN و MLP استفاده شد. ساختار مدل‌های هوشمند به گونه‌ای صورت گرفت که دو لایه پنهان وجود داشت که در هر لایه ۶ نورون قرار می‌گرفت. در این دو مدل از داده‌های کارخانه تولید کنسانتره سنگ آهن مرکزی، استفاده گردید و نتایج زیر حاصل شد:

۱- میانگین عیار خوراک و بازیابی آهن در خط تولید سه چاهون نسبت به خط تولید چغارت پایین‌تر مشاهده شد. در خط تولید سه چاهون در بازیابی‌های کمتر از حدود ۴۵ درصد خطای مدل‌ها بالا می‌باشد. البته با توجه به تعداد کم داده‌های با مقادیر بازیابی پایین، بازیابی کارخانه در بیشتر مواقع بالای ۴۵ درصد می‌باشد، که خطای مدل در این مقادیر پایین‌تر است.

۲-  $R^2$  مدل‌های CFNN و MLP نشان دادند که پیش‌بینی بازیابی آهن در کنسانتره کارخانه سنگ آهن مرکزی فقط از طریق دو ورودی  $\text{Fe}$  و  $\text{FeO}$  خوراک تنها به عنوان یک برآورد تقریبی قابل قبول است و نمی‌تواند جایگزین روابط محاسبه بازیابی شود. لذا اهمیت مشارکت سایر پارامترهای موثر در ورودی مدل برای تحقیقات آتی به وضوح در این تحقیق مشخص می‌گردد.

۳- استفاده از یکی از دو مدل شبکه عصبی پیشنهاد شده می‌تواند با ۹۰ درصد اطمینان، بازیابی آهن را با خطای کمتر از ۵ درصد پیش‌بینی کند. در نتیجه، می‌توان پیش از خوراک‌دهی به کارخانه سنگ آهن مرکزی، بازیابی آهن یک نمونه خوراک را با دقت نسبتاً قابل قبولی تخمین زد.

۴- رابطه بازیابی آهن با عیارهای Fe و FeO خوراک به صورت مستقیم است، به گونه ای که با افزایش این دو پارامتر بازیابی افزایش می یابد. با توجه به مقدار بالاتر عامل ارتباط (RF) برای عیار Fe، بازیابی آهن بیشتر تحت تأثیر عیار Fe خوراک در هر دو خط می باشد. روند بازیابی آهن نسبت به عیار FeO در خط تولید سه چاهون نسبت به خط تولید چغارت از پراکندگی بالایی برخوردار بود که احتمالاً به دلیل پایین تر بودن میانگین عیار FeO خوراک سه چاهون می باشد.

### تشکر و قدردانی

بدین وسیله از تمامی مسئولین مجموعه کنسانتره سنگ آهن مرکزی به جهت همکاری صمیمانه در اجرای این تحقیق، تشکر و قدردانی می نمایم.

## References

- [1] McNab, B., et al. Processing of magnetite iron ores-comparing grinding options. in Proceedings of the AusIMM Iron Ore Conference. 2009.
- [2] Rovenskikh, M. and A. Kobzeva, Analysis of iron ore reserves in Russia and worldwide. *Tsifrovaya ekonomika. Problemy i perspektivy razvitiya*, 2019: p. 318-323.
- [3] Hicyilmaz, C., et al., *Mineral Processing on the Verge of the 21st Century: Proceedings of the 8th International Mineral Processing Symposium, Antalya, Turkey, 16-18 October 2000*. 2017: Routledge.
- [4] Xiong, D., L. Lu, and R. Holmes, Developments in the physical separation of iron ore: magnetic separation, in *Iron ore*. 2015, Elsevier. p. 283-307. <https://doi.org/10.1016/B978-1-78242-156-6.00009-5>.
- [5] Karmazin, V., M. Bikbov, and A. Bikbov, The energy saving technology of beneficiation of iron ore. *Physical Separation in Science and Engineering*, 2002. 11(4): p. 211-224. <https://doi.org/10.1080/1055691021000062813>.
- [6] Wang, F., et al., Investigation of the magnetic separation performance of a low-intensity magnetic separator embedded with auxiliary permanent magnets. *Minerals Engineering*, 2022. 178: p. 107399. <https://doi.org/10.1016/j.mineng.2022.107399>.
- [7] Wang, F., et al., Performance assessment of an innovative precise low-intensity magnetic separator. *Minerals Engineering*, 2022. 187: p. 107774. <https://doi.org/10.1016/j.mineng.2022.107774>.
- [8] Karimi, P., Z. Mansourpour, and A. Khodadadi Darban, Simulation of magnetic separation process in wet low intensity magnetic separator using DPM-CFD Method. *Journal of Advanced Environmental Research and Technology*, 2023. 1(1): p. 59-73. <http://dx.doi.org/10.22034/jaert.1.1.59>.
- [9] Schulz, N.F., Determination of the magnetic separation characteristics with the Davis Magnetic Tube. *Trans. SME-AIME*, 1964. 229: p. 211-216.
- [10] Makhula, M., et al., Statistical analysis and concentration of iron ore using Longi LGS 500 WHIMS. *International Journal of Mining Science and Technology*, 2016. 26(5): p. 769-775. <https://doi.org/10.1016/j.ijmst.2016.05.052>.
- [11] Ren, L., S. Zeng, and Y. Zhang, Magnetic field characteristics analysis of a single assembled magnetic medium using ANSYS software. *International Journal of Mining Science and Technology*, 2015. 25(3): p. 479-487. <https://doi.org/10.1016/j.ijmst.2015.03.024>.
- [12] Li, W., et al., A preliminary investigation into separating performance and magnetic field characteristic analysis based on a novel matrix. *Minerals*, 2018. 8(3): p. 94. <https://www.mdpi.com/2075-163X/8/3/94#>.
- [13] Dobbins, M., J. Domenico, and P. Dunn. A discussion of magnetic separation techniques for concentrating ilmenite and chromite ores. in *The 6th international heavy minerals conference "back to basics"*, The Southern African Institute of Mining and Metallurgy. 2007.
- [14] Guarin, C., et al., The K Deeps magnetite mineralisation at Koolyanobbing, Western Australia. *Applied Earth Science*, 2010. 119(3): p. 143-153. <https://doi.org/10.1179/1743275811Y.0000000009>.
- [15] Wills, B.A. and J. Finch, *Wills' mineral processing technology: an introduction to the practical aspects of ore treatment and mineral recovery*. 2015: Butterworth-heinemann. <https://doi.org/10.2138/am.2008.502>.
- [16] Shahcheraghi, S.H., et al., A simple model for predicting optimal weight recovery of industrial iron ore processing—case study: Iranian iron ore mines. *Canadian Metallurgical Quarterly*, 2023. 62(2): p. 295-300. <https://doi.org/10.1080/00084433.2022.2075074>.
- [17] Tahami, M., et al., Integration of experimental study and neural network modeling for estimating iron recovery in Davis tube tests. *Scientific Reports*, 2024. 14(1): p. 22578. <https://doi.org/10.1038/s41598-024-72850-w>.

- 
- [18] Paledi, U., et al., *Selectivity index and separation efficiency prediction in industrial magnetic separation process using a hybrid neural genetic algorithm*. SN Applied Sciences, 2021. 3(3): p. 351. <https://doi.org/10.1007/s42452-021-04361-6>.
- [19] Izadi-Yazdan Abadi, M., R. Shokrizadeh, and F. Heydari, Development of a model for iron concentrate tonnage with least angle regressions—An industrial trial. *Canadian Metallurgical Quarterly*, 2024: p. 1-10. <https://doi.org/10.1080/00084433.2024.2366715>.
- [20] Technical Operation Manual for Choghart Production Line, Volume 1 of 2. 1999.
- [21] Lashkarbolooki, M., A.Z. Hezave, and S. Ayatollahi, Artificial neural network as an applicable tool to predict the binary heat capacity of mixtures containing ionic liquids. *Fluid Phase Equilibria*, 2012. 324: p. 102-107. <https://doi.org/10.1016/j.fluid.2012.03.015>.
- [22] Hemmati-Sarapardeh, A., et al., On the evaluation of the viscosity of nanofluid systems: Modeling and data assessment. *Renewable and Sustainable Energy Reviews*, 2018. 81: p. 313-329. <https://doi.org/10.1016/j.rser.2017.07.049>.
- [23] Hemmati-Sarapardeh, A., et al., Accurate determination of the CO<sub>2</sub>-crude oil minimum miscibility pressure of pure and impure CO<sub>2</sub> streams: a robust modelling approach. *The Canadian Journal of Chemical Engineering*, 2016. 94(2): p. 253-261. <https://doi.org/10.1002/cjce.22387>.
- [24] De Jesus, O. and M.T. Hagan, Backpropagation algorithms for a broad class of dynamic networks. *IEEE Transactions on Neural Networks*, 2007. 18(1): p. 14-27. <https://doi.org/10.1109/TNN.2006.882371>.
- [25] Nami, F. and F. Deyhimi, Prediction of activity coefficients at infinite dilution for organic solutes in ionic liquids by artificial neural network. *The Journal of Chemical Thermodynamics*, 2011. 43(1): p. 22-27. <https://doi.org/10.1016/j.jct.2010.07.011>.
- [26] Hemmati-Sarapardeh, A., et al., *Applications of artificial intelligence techniques in the petroleum industry*. 2020: Gulf Professional Publishing. <https://doi.org/10.1016/C2018-0-04421-7>.