E-ISSN: 2676-6159 | P-ISSN: 2538-5079

Journal of Decisions and Operations Research

www.journal-dmor.ir

J. Decis. Oper. Res. Vol. 7, Spec. Issue (2022) 1–10.

Paper Type: Original Article

# Prediction of Lime Quality in Lime Baking Furnaces Using Neural Fuzzy Methods

**Iman Zabbah[1], Ali Maroosi[2,*], Abolfazl Noghandi[2], Zahra Abbasi[2]**

[1] *Department of Computer, Torbat-e-Heydariyeh Branch, Islamic Azad University, Torbat-e-Heydariyeh, Iran; imanzabbah@gmail.com.*

[2] *Department of Computer Engineering, Faculty of Technical and Engineering, University of Torbat-e-Heydarieh, Torbat-e-Heydarieh, Iran; ali.maroosi@torbath.ac.ir; abolfazlnoghandi@gmail.com; zahra.abbasi@gmail.com.*

***Citation:***

Zabbah, I., Maroosi, A., Noghandi, A., & Abbasi, Z. (2022). Prediction of lime quality in lime baking furnaces using neural fuzzy methods. *Journal of decisions and operations research, 7*(Spec. Issue), 1-10.

Received: 26/04/2021 Reviewed: 25/05/2021 Revised: 09/07/2021 Accepted: 12/08/2021

## Abstract

**Purpose:** Optimizing the quality of lime, while using the energy system in the lime baking oven is a great service. Since lime baking is always allowed, you can easily control it. The purpose of this study was to predict the quality of lime during the manufacturing process in a lime baking oven and adjust the parameters provided before service delivery.

**Methodology:** The system variables presented in this study include: input tonnage and parameters of each round. Improper adjustment of these parameters will result in increased fuel consumption, resulting in poor quality lime production. Accordingly, in this paper, artificial neural networks as well as fuzzy neural networks have been used as predictive tools to predict the quality of lime produced during the baking process.

**Findings:** These parameters are feeder, idle furnace, preheater, air conditioner, furnace, time and fuel consumption and output of the produced lime quality model. Modeling in matlab software (Matlab 2017) was performed using 472 samples with 8 properties.

**Originality/Value:** Eighty percent of the samples were used for training and 20% for testing. At the end of modeling, artificial neural networks error 0.066 and fuzzy neural network error 0.054 were obtained.

**Keywords:** Lime quality prediction, Lime kiln, Artificial neural network, Neuro-fuzzy.

Corresponding Author: ali.maroosi@torbath.ac.ir

http://dorl.net/dor/20.1001.1.25385097.1401.7.5.5.8

Licensee. **Journal of Decisions and Operations Research**. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (http://creativecommons.org/licenses/by/4.0).

Journal of Decisions and Operations Research

تصمیم‌گیری و تحقیق در عملیات

دوره ۷، شماره ویژه، (۱۴۰۱)، ۱۰-۱

www.journal-dmor.ir

نوع مقاله: پژوهشی

# پیش‌بینی کیفیت آهک در کوره پخت آهک با استفاده از روش‌های مبتنی بر فازی عصبی

**ایمان ذباح[1]، علی ماروسی[2,*]، ابوالفضل نوقندی[2]، زهرا عباسی[2]**

[1]گروه کامپیوتر، واحد تربت حیدریه، دانشگاه آزاد اسلامی، تربت‌حیدریه، ایران.

[2]گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه تربت‌حیدریه، تربت‌حیدریه، ایران.

## چکیده

**هدف:** بهینه‌سازی کیفیت آهک، هم‌زمان با کاهش مصرف انرژی در کوره پخت آهک از اهمیت بسزایی برخوردار است. ازآنجایی‌که پخت آهک همواره در شرایط عدم قطعیت صورت می‌گیرد، لذا باید کنترل آن توسط روش‌های هوشمند انجام شود. هدف از انجام این پژوهش، پیش‌بینی کیفیت آهک در طول فرایند ساخت آن در کوره پخت آهک و تنظیم پارامترهای ورودی، قبل از تولید می‌باشد.

**روش‌شناسی پژوهش:** متغیرهای سیستم ارایه‌شده در این تحقیق شامل: میزان تناژ ورودی و پارامترهای هر دور می‌باشند. عدم تنظیم صحیح این پارامترها ضمن افزایش مصرف سوخت، منجر به تولید آهک فاقد کیفیت لازم خواهد گردید. بر همین اساس در این مقاله از شبکه‌های عصبی مصنوعی و همچنین شبکه‌های مصنوعی فازی عصبی، به‌عنوان ابزارهای پیش‌بینی کننده و به‌منظور پیش‌بینی کیفیت آهک تولیدی در طی فرایند پخت استفاده شده است. این پارامترها عبارت‌اند از فیدر، آی دی کوره، پیش‌گرمکن، کولر، کوره، زمان و میزان سوخت مصرفی و خروجی مدل کیفیت آهک تولیدشده می‌باشد.

**یافته‌ها:** مدل‌سازی در نرم‌افزار متلب (۲۰۱۹) با استفاده از ٤٧٢ نمونه با ٨ ویژگی انجام شده است. از ٨٠% نمونه‌ها به‌منظور آموزش و ٢٠% به‌عنوان آزمون استفاده شده است.

**اصالت/ارزش افزوده علمی:** در پایان مدل‌سازی به کمک شبکه‌های عصبی مصنوعی خطای ٠/٠٦٦ و شبکه فازی عصبی خطای ٠/٠٥٤ حاصل گردید.

**کلیدواژه‌ها:** پیش‌بینی کیفیت آهک، کوره آهک‌پزی، شبکه عصبی مصنوعی، عصبی-فازی.



## ۱- مقدمه

آهک و گچ ازجمله موادی هستند که کارایی آن‌ها از دوران باستان، توسط بشر شناخته‌شده و از آن‌ها در ساختن انواع بناها، استفاده شده است. سنگ آهک چه از نوع کربنات کلسیم و چه از نوع دولو میتی عمده‌ترین سنگ‌ها، از خانواده کربنات‌ها هستند و ٢٢% پوسته زمین تا عمق ١١ کیلومتری را تشکیل می‌دهند. آهک علاوه بر صرفه‌جویی اقتصادی در هزینه ملات، ابتدا آب ملات را جذب می‌کند و سپس پس می‌دهد و به‌این‌ترتیب باعث کند گیر شدن گچ و همچنین افزایش خاصیت شکل‌پذیری آن می‌شود. پخت آهک در قدیم در کوره‌هایی صورت می‌گرفته است که در آن با ساختن طاقی از سنگ آهک، جایگاهی در زیر کوه درست می‌کردند و روی طاق را تا سر کوه پر از سنگ آهک می‌نمودند آنگاه سوخت را در آن جایگاه قرار داده و به مدت چهار شبانه‌روز به سنگ آهک حرارت می‌دادند تا بپزد و آهک زود گیر به دست

* نویسنده مسئول

ali.maroosi@torbath.ac.ir

http://dorl.net/dor/20.1001.1.25385097.1401.7.5.5.8

آید (عبدالهی و همکاران[1]، ۲۰۱۹). کاربرد آهک در ساختمان‌های سنگی و آجری به‌عنوان ملات و نیز روکش دیوار، معمول بوده است. روش تهیه کلی آهک، همان حرارت دادن سنگ آهک (کربنات کلسیم) تا دمای ۱۰۰۰ تا ۱۲۰۰ درجه سانتی‌گراد است. البته، هر چه دما بالاتر باشد و گاز دی‌اکسید کربن حاصل، بهتر از محیط خارج شود، عمل تجزیه سنگ آهک بهتر صورت می‌پذیرد که این عمل مستلزم میزان سوخت بیشتر می‌باشد (چهرگانی و همکاران[2]، ۲۰۱۹). فرایند مربوط را می‌توان از جنبه شیمیایی به‌صورت واکنش‌های زیر بیان کرد: ۱- پخت آهک، ۲- شکفتن آهک و ۳- کربنات شدن یا سخت شدن. در ضمن حرارت دادن سنگ آهک از جنبه شیمیایی، کربنات کلسیم، ابتدا به آهک اکسید کلسیم و دی‌اکسید کربن تجزیه می‌شود. در درجه حرارت ۱۰۰۰ درجه سانتی‌گراد، یعنی حرارت سرخ شدن، واکنش مذکور به‌سرعت انجام می‌شود (ویسه و خدابنده[3]، ۲۰۰۵). لزوم بهینه‌سازی و کاهش مصرف انرژی در صنعت تولید آهک و سیمان همواره موردتوجه محققان بوده است (وندربورت و برودمن[4]، ۲۰۰۱). براساس گزارش‌های منتشرشده از آژانس بین‌المللی انرژی (*IEA*)، این نهاد نیز در نظر دارد که انرژی مصرفی در این بخش‌ها را تا سال ۲۰۲۵ با تاکید بر کاهش انرژی مصرفی به مقدار قابل‌توجهی کاهش دهد (مسجدی خاک و همکاران[5]، ۲۰۲۱). کارایی بیشتر این واحدها ازنظر انرژی مصرفی پایین است که یکی‌از علل مهم آن در عدم ترکیب مناسب و تنظیم دقیق ورودی‌های کوره است؛ بنابراین، ارایه راهکارهایی جهت مکانیزه کردن تولید و تنظیم هوشمند ورودی‌های کوره، ضمن ارتقا کیفیت منجر به کاهش مصرف انرژی خواهد شد. در زمینه بهینه‌سازی مصرف انرژی، می‌توان به پژوهش سعید موجودی و همکاران در سال ۱۳۹۶ اشاره کرد که راهکارهایی به منظور کاهش مصرف انرژی در سیمان سپاهان اصفهان ارایه دادند که مبتنی بر روش‌های هوشمند فازی بوده است (مجدی و همکاران[6]، ۲۰۱۷). بخش عمده‌ای از مطالعات در زمینه گچ و آهک بیشتر در زمینه ارزیابی مصرف انرژی در کارخانه‌های گچ بوده است مانند مطالعه باقری و همکاران در سال ۱۳۹۷ که نشان داده شده است روش‌های فراابتکاری کارکرد موثرتری در بهینه‌سازی مصرف انرژی، نسبت به روش‌های کلاسک دارند (باقری و همکاران[7]، ۲۰۱۸) و یا مطالعه التون[8] (۲۰۱۶) که برروی امکان ذخیره‌سازی انرژی و بهینه‌سازی مصرف آن در کارخانه آهک و سیمان تمرکز داشته‌اند. از دیگر تلاش‌های صورت گرفته به منظور هوشمندسازی در حوزه آهک ارایه راهکاری مبتنی بر شبکه‌های عصبی به منظور پیش‌بینی هزینه‌های انفجار در معادن سنگ آهک در سال ۱۳۹۹ می‌باشد که توسط بستامی و همکاران[9] (۲۰۲۰) ارایه گردید (اسدی و عنایت الهی[10]، ۲۰۱۶)، بررسی تاثیر افزودنی‌های معدنی بر بازدهی تولید سیمان از دیگر تلاشهای است که توسط بهرامی و همکاران[11] (۲۰۱۹) انجام گردید (بستامی و همکاران، ۲۰۲۰). آن‌چه که در پخت آهک اهمیت دارد، تنظیم پارامترهای ورودی کوره، با توجه به تناژ ورودی و وضعیت دمای کوره است. به‌این‌ترتیب که شخص خبره با توجه به دریافت اطلاعات از وضعیت کوره و مشاهده خلوص آهک تولیدشده، اقدام به تنظیم پارامترهای کنترلی می‌نماید. عدم دقت نظر توسط این شخص منجر به اعمال هزینه‌های بیشتر تولید، شده ضمن اینکه مصرف سوخت را به‌شدت افزایش می‌دهد. از این‌رو استفاده از متدهای مبتنی بر هوش مصنوعی، به منظور تنظیم پارامترهای کوره، می‌تواند ضمن کاهش خطای انسانی منجر به افزایش بهره‌وری تولید شود. در این مطالعه با تجزیه‌وتحلیل پارامترهای ورودی کوره پخت آهک و به کمک شبکه‌های عصبی مصنوعی و شبکه‌های عصبی- فازی، اقدام به مدل‌سازی و پیش‌بینی کیفیت آهک شده است؛ تا بتوان بر اساس آن پارامترهای دستگاه را تنظیم نمود.

## ۲- روش پژوهش

تحقیق حاضر، ارایه‌دهنده یک مدل پیش‌بینی کننده است که بر اساس متغیرهای ورودی به پیش‌بینی ویژگی‌های موثر در کیفیت آهک تولیدشده در کارخانه تولید آهک جهت بهبود میزان مصرف سوخت می‌پردازد.

### ۲-۱- مواد

در این مقاله از مجموعه داده یکی‌از کارخانه‌های تولید آهک که توسط محققین پژوهش و در یک بازه ۲۰ روزه جمع آوری‌شده، استفاده شده است. تعداد نمونه‌ها، ۴۷۲ و تعداد ویژگی‌های هر یک از آن‌ها ۸ مورد می‌باشد. **جدول ۱**، نمونه‌ای از داده‌های جمع‌آوری‌شده را نشان می‌دهد. ورودی مدل‌های شبکه عصبی و شبکه عصبی-فازی حاضر عبارت است از ساعت، تناژ ورودی (*t/h*)، فیدر (*Feeder*)،

[1] Abdollahi et al.
[2] Chehreghani et al.
[3] Vise and khodabandeh
[4] Vanderborght and Brodmann
[5] Masjedi Khak et al.
[6] Mojody et al.
[7] Bagheri et al.
[8] Altun
[9] Bastami et al.
[10] Asadi and Enayatollahi
[11] Bahrami et al.


ذباح و همکاران / تصمیم‌گیری و تحقیق در عملیات، دوره ۷، شماره ویژه، پاییز ۱۴۰۱، صفحه: ۱۰-۱

آیدی (*ID Fan*)، کوره (*Klin*)، پیش‌گرمکن (*preheater*)، کولر (*cooler*)، میزان سوخت مصرفی (*Nm3/h*) و درنهایت کیفیت (*Quality*) آهک تولیدی به‌عنوان خروجی شبکه می‌باشد.





**جدول ۱- نمونه‌ای از متغیرهای ورودی کوره پخت آهک و میزان سوخت مصرفی در ۹ سیکل زمانی.**

**Table1- An example of the input variables of lime kiln and the amount of fuel consumed in 9 time cycles.**

| ساعت | تناژ ورودی | فیدر | آیدی | کوره | پیش‌گرمکن | کولر | کیفیت | میزان سوخت |
|---|---|---|---|---|---|---|---|---|
| 3 | 16 | 10/2 | 790 | 14 | 13 | 18 | 0/97 | 2000 |
| 4 | 16 | 10/3 | 790 | 14 | 13 | 18 | 0/95 | 2000 |
| 5 | 16 | 10/6 | 790 | 15 | 13/5 | 18 | 0/94 | 2000 |
| 6 | 16 | 11 | 790 | 15 | 13/5 | 18 | 0/93 | 2000 |
| 7 | 16 | 11 | 790 | 14 | 13/5 | 18 | 0/95 | 2000 |
| 8 | 16 | 11 | 790 | 15 | 13/5 | 18 | 0/98 | 1906 |
| 9 | 17 | 11/5 | 792 | 16 | 13/5 | 18 | 0/97 | 2000 |

منظور از تولید آهک، تبدیل سنگ آهک (*CaC03*) به آهک زنده (*Cao*) می‌باشد. به این عمل تکلیس (*Calcination*) گفته می‌شود. برای انجام تکلیس بایستی سنگ آهک را تا دمای حدود ۱۱۵۰ درجه سانتی‌گراد حرارت داد. در ابتدا سنگ آهک با ابعادی بین ۲۰ تا ۶۰ میلی‌متر وارد پیش‌گرمکن می‌گردد. پیش‌گرمکن ابزاری است که به‌منظور گرم کردن و آماده‌سازی اولیه مواد استفاده می‌شود و دارای انواع گوناگونی است که در سیستم حاضر به شکل کوره‌ی دوار می‌باشد. تاثیر دور پیش‌گرمکن بر پروسه به صورتی است که عمل انتقال مواد در طول پیش‌گرمکن که به شکل لوله‌ای استوانه‌ای می‌باشد با چرخش آن اتفاق می‌افتد. نتیجه اینکه هرچقدر سرعت دوران پیش‌گرمکن بیشتر باشد: ۱- ماند مواد و میزان انباشت مواد (بار مرده) نیز در آن کمتر خواهد بود. بایستی میزان دور بهتر با توجه به تناژ ورودی طوری تعیین گردد که بیشترین انتقال انرژی از گاز داغ به سنگ انجام شود؛ که این عدد به‌صورت تجربی به دست می‌آید. سپس مواد وارد کوره می‌گردد و دقیقا مشابه پیش گرمکن بایستی مقدار دوری برای کوره در نظر گرفت که بهینه باشد. درنهایت مواد پخته‌شده پس از خروج از کوره وارد کولر می‌گردد. در کولر عملیات بازیافت حرارت صورت می‌پذیرد به این معنی که فن کولر با دمیدن بر آهک داغ باعث سرد شدن آن می‌گردد و هوایی که پس از برخورد با آهک داغ، حرارت آن بالا رفته به‌عنوان هوای ثانویه و جهت تعیین اکسیژن موردنیاز برای سوخت مجددا به کوره بازمی‌گردد. در این مرحله نیز میزان دور کولر سرعت خروج بار از کولر و همچنین میزان انباشتگی بار در کولر را تعیین می‌کند که بازبایستی با توجه به تناژ ورودی عددی بهینه باشد. آی دی فن عملیات مکش در سیستم به‌منظور خروج گاز دی‌اکسید کربن و گازهای حاصل از احتراق (میزان مکش در سیستم بایستی به مقداری تعیین گردد که در گاز خروجی *CO* وجود نداشته باشد) می‌باشد. میزان سوخت به معنی مقدار گاز مصرفی (انرژی) می‌باشد که باکیفیت محصول خروجی رابطه مستقیم دارد. با توجه به این مورد که مصرف سوخت برای تولیدکننده دارای هزینه می‌باشد بایستی مقدار سوخت در کمترین مقدار بوده تا جایی که به کیفیت محصول آسیب نزند. **شکل ۱** بیانگر چرخه طبیعی آهک می‌باشد.

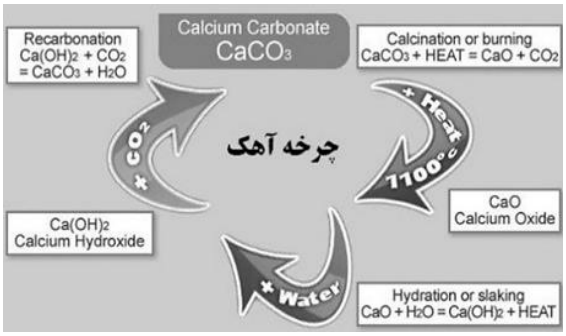


**شکل ۱- چرخه طبیعی آهک.**

**Figure 1- The natural cycle of lime.**

به‌منظور تحلیل دقیق‌تر پارامترهای ورودی، ضریب همبستگی هر یک از ورودی‌ها محاسبه و در **جدول ۲** ثبت شده است.

جدول ۲- بررسی تاثیر هر یک از ورودی‌ها نسبت به کیفیت آهک.

Table 2- Investigating the effect of each of the inputs on the quality of lime.

| ورودی | ضریب همبستگی |
|---|---|
| ورودی | -0/06 |
| کولر | 0/10 |
| پیش‌گرمکن | -0/20 |
| کوره | 0/21 |
| آی دی فن | 0/38 |
| فیدر | 0/14 |
| تناژ ورودی | 0/30 |
| سوخت | -0/04 |

نتایج تحلیل، نشان می‌دهد که بیشترین ضریب همبستگی، مربوط به فیدر می‌باشد. به‌منظور مشاهده پراکندگی نمونه‌ها و انجام عملیات پیش‌پردازش و حذف نمونه‌های اضافی، نمودار میانگین هر پارامتر، در طی دوره ۲۰ روزه در **شکل ۲** ترسیم‌شده است. این شکل گرچه نمی‌تواند به‌طور کامل قابلیت تفکیک‌پذیری سیستم و نقش آن‌ها را نشان دهد، اما یک نگرش کلی نسبت به تاثیر ورودی‌ها در میزان مصرف سوخت را نشان می‌دهد. به‌عنوان‌مثال، با توجه به شکل هفتم که بیانگر نسبت کیفیت آهک به میزان مصرف سوخت است، می‌توان دریافت که با مصرف سوخت کمتر از ۱۷۰۰ می‌توان به کیفیت‌های بالاتر از ۹۰٪ رسید. ضمن اینکه وجود نویز در بیشتر ویژگی‌ها نمایان است. نویز، داده دارای خطا و مخرب است که می‌تواند فرایند مدل‌سازی را با اخلال مواجه کند؛ بنابراین با حذف این داده می‌توان نتیجه بهتری را در مدل‌سازی فرایند به دست آورد. برای مثالی دیگر می‌تواند به نمودار پراکندگی دوم که مربوط به تناژ است اشاره کرد. همان‌طور که این شکل نشان می‌دهد هرچقدر تناژ ورودی بیشتر باشد، مصرف سوخت بیشتر است.

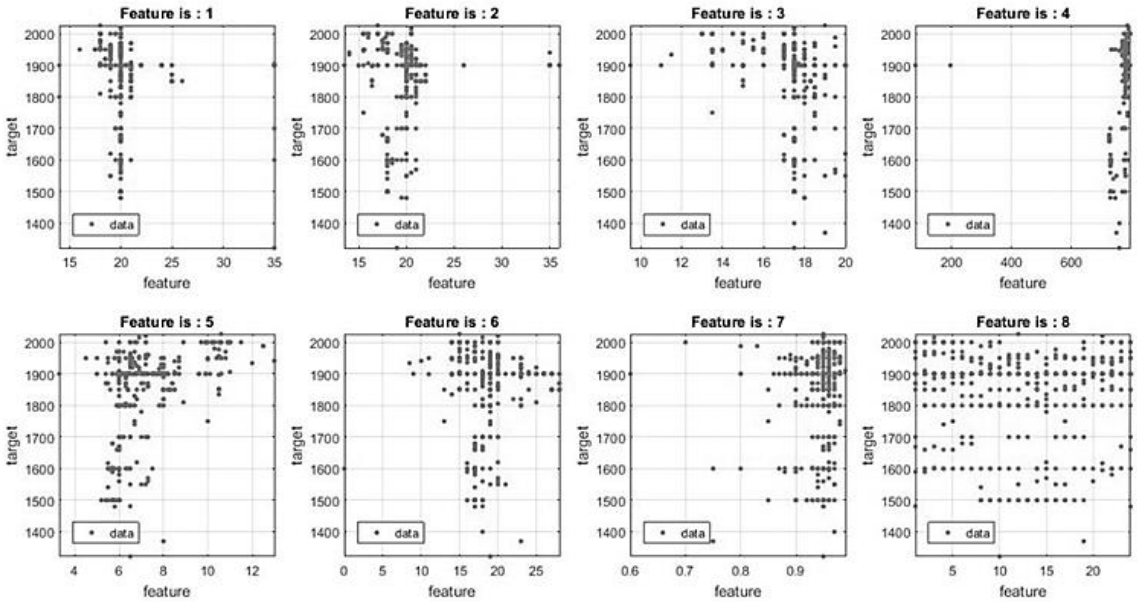


شکل ۲- بررسی پراکندگی هر یک از ویژگی‌ها، نسبت به مصرف سوخت.

Figure 2- Investigation of the scatter of each feature in relation to fuel consumption.

محور افقی ویژگی و محور عمودی، میزان مصرف سوخت می‌باشد که به ترتیب از چپ به راست و از بالا به پایین عبارت‌اند از ۱- کولر-سوخت، ۲- تناژ ورودی-سوخت، ۳- فیدر-سوخت، ۴- آی دی فن-سوخت، ۵- پیش‌گرمکن-سوخت، ۶- کوره-سوخت، ۷- کیفیت آهک-سوخت و ۸- زمان-سوخت.

## ۲-۲- نرمال‌سازی داده‌ها

با توجه به آن‌که، ورود داده‌ها به شکل خام باعث کاهش سرعت و دقت شبکه می‌شود، برای پیشگیری از چنین شرایطی و همچنین به لحاظ یکسان کردن ارزش داده‌ها برای شبکه عصبی، نرمالیزه کردن داده‌ها، قبل از اعمال به شبکه انجام شده است. عمل نرمال‌سازی داده‌ها مطابق **رابطه (۱)** انجام گرفته است.

$$xn = \frac{x - x_{min}}{x_{max-x_{mlm}}}. \quad (۱)$$

در این رابطه، $X$ داده‌های نرمال نشده، $X_n$ داده‌های نرمال شده و $X_{max}$ و $X_{min}$ حداقل و حداکثر داده‌های ورودی می‌باشند. معمولا دو معیار مختلف به‌منظور ارزیابی کارایی هر شبکه و توانایی آن برای پیش‌گویی دقیق، استفاده می‌شود. مجذور خطا (*RMSE*) و ضریب همبستگی *R2* که نشانگر میزان بازده شبکه می‌باشد مطابق **روابط (۲)** و **(۳)** محاسبه می‌شوند:

$$RMSE = \sqrt{\frac{\sum_{i=l}^{n}(y_i - y_i)^2}{N}}. \quad (۲)$$

$$R2 = 1 - \frac{\sum(Y_I - \widehat{Y}_I)^2}{\sum(-\overline{Y})^2}. \quad (۳)$$

در این رابطه $y_i$ نتایج مشاهداتی، $y_i$ نتایج محاسباتی و $N$ تعداد کل مشاهدات است. *RMSE* اختلاف این دو مقدار را نشان می‌دهد. کمترین مقدار *RMSE*، بالاترین صحت پیشگویی را نشان می‌دهد. لذا هرچه این مقدار به صفر و *R2* به یک نزدیک‌تر شود، مدل ارایه‌شده به واقعیت نزدیک‌تر است. در این مطالعه شبکه‌های عصبی مصنوعی متفاوتی، با ساختار پرسپترون چندلایه مورداستفاده قرار گرفتند. پارامترهای ورودی به‌عنوان متغیرهای در نظر گرفته شده است. به‌منظور افزایش دقت اندازه‌گیری خطا، از روش اعتبارسنجی متقابل (*kfold*) استفاده شده است. به‌این‌ترتیب که داده‌های آموزش بدون جایگذاری به $k$ قسمت تقسیم‌شده و از $k$-1 نمونه به‌عنوان داده آموزشی و از بقیه به‌عنوان داده آزمون استفاده می‌شود. **شکل ۳** نحوه تقسیم‌بندی نمونه‌ها به ۵ قسمت ($k$=5) را نشان می‌دهد.

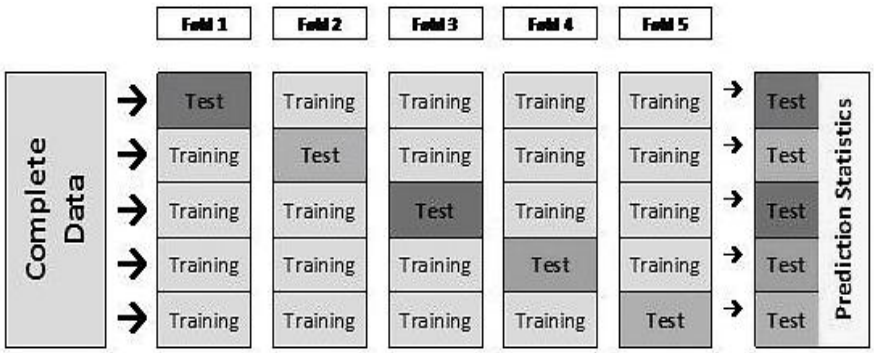


**شکل ۳- تقسیم داده‌ها به ۵ قسمت و استفاده از ۴ قسمت به‌عنوان داده‌های آموزش و یک قسمت به‌عنوان داده‌های آزمون.**
**Figure 3- Divide the data into 5 fold and use 4 fold as training data and one as test data.**

## ۳-۲- کیفیت‌سنجی آهک به وسیله شبکه‌های عصبی مصنوعی

به فرایند استخراج دانش ناشناخته، درست و بالقوه مفید از داده، داده‌کاوی گفته می‌شود. داده‌ها اغلب حجیم؛ اما بدون ارزش می‌باشند. دانش نهفته در داده‌ها آن‌ها را قابل‌استفاده می‌کند. روش‌های داده‌کاوی را می‌تواند به‌صورت بدون ناظر (*Unsupervised learning*) و با ناظر (*Supervised learning*) در نظر گرفت. در این پژوهش ازآنجایی‌که فرایند مدل‌سازی از نوع با ناظر است یعنی خروجی مدل مشخص است، لذا از شبکه‌های عصبی مصنوعی و نیز شبکه فازی-عصبی، به‌منظور پیش‌بینی کیفیت آهک تولیدی کوره استفاده شده است. مدل‌سازی به کمک شبکه عصبی پرسپترون چندلایه (*Multi-layer perceptron*) در مرحله اول این پژوهش و مدل‌سازی به کمک سیستم‌های فازی عصبی در مرحله دوم استفاده شده است. ازآنجایی‌که معماری شبکه عصبی ازنظر تعداد نرون‌ها در لایه‌ها، می‌تواند درنتیجه مدل‌سازی نقش اساسی داشته باشد، لذا حدود ۲۰ شبکه عصبی پرسپترون چندلایه موردبررسی قرار گرفت تا بهترین معماری به دست آید. **شکل ۴**، ساختار شبکه عصبی مورداستفاده در این پژوهش که از نوع ۳ لایه است را نشان می دهد. تابع خروجی شبکه در لایه آخر، با **رابطه (۴)** محاسبه می‌شود که در آن $h$ و $o$ به ترتیب نشان‌دهنده تعداد لایه نهان و لایه خروجی بوده و منظور از $w$ همان وزن‌های لایه‌ها می‌باشد:

$$O_i = sgm\left(\sum_m sgm\left(\sum_l x_i w_{lm}^h\right) w_{mi}^o\right). \quad (۴)$$

پردازش مدل شبکه عصبی شامل مراحل ورود داده، تحلیل و نمایش مساله، تعیین معماری شبکه و تعیین روش آموزش شبکه می‌باشد. برای ایجاد مدل شبکه عصبی از نرم‌افزار متلب (*Matlab 2019*) استفاده شده است. شبکه عصبی پیش‌خور (*Feed forward Neural Network*) که در این پژوهش مورد استفاده قرار گرفته است، یک شبکه عصبی مصنوعی است که در آن اتصال میان واحدهای تشکیل‌دهنده آن، یک چرخه را تشکیل نمی‌دهند. ورودی‌های مدل شبکه عصبی حاضر عبارت است از ساعت، تناژ ورودی (*t/h*)، فیدر

(*Feeder*)، آی‌دی (*ID Fan*)، کوره (*Klin*)، پیش‌گرمکن (*preheater*)، کولر (*cooler*)، میزان سوخت (*Nm3*) و کیفیت (*Quality*) به‌عنوان خروجی شبکه می‌باشد. سایر پارامترهای شبکه عصبی در این پژوهش در **جدول ۳** درج شده است.

**جدول ۳- پارامترهای شبکه عصبی با در نظر گرفتن کلیه پارامترهای ورودی (i متغیر بین ۱۰ تا ۱۰۰ نرون).**

**Table 3- Neural network parameters taking into account all input parameters. i between 10 and 100 neurons.**

| کمترین خطای (RMSE) | پارامترهای آموزش | الگوریتم آموزش | معماری شبکه عصبی |
|---|---|---|---|
| 0/017 | Learning Rate:0.05 | Feed forward back propagation | 10-8-i-1 |

در این مطالعه، معماری‌های متفاوتی به‌منظور دستیابی به بهترین ساختار شبکه عصبی مورد آزمایش قرار گرفت. **شکل ۵** خطای محاسبه‌شده در معماری‌های مختلف را نشان می‌دهد. بهترین معماری مربوط به زمانی است که تعداد ۱۰ نرون در لایه مخفی اول و تعداد ۱۶ نرون، در لایه مخفی دوم وجود دارد. پس از تقسیم‌بندی داده‌ها به روش اعتبار سنجی متقابل (*kfold*)، نمونه‌ها به شبکه عصبی اعمال گردید. در هر بار تکرار از ٤٥٢ نمونه ٣٦٢ نمونه به‌عنوان داده آموزش (*Train*) و ۹۰ نمونه به‌عنوان داده آزمون (*Test*) مورداستفاده قرار گرفت. این عملیات در ۱۰ تکرار مختلف بررسی گردید که میانگین خطا برای هر تکرار محاسبه و در **شکل ٦** نشان داده شده است. تمامی قسمت‌ها به‌طور جداگانه به شبکه‌های عصبی مختلف طراحی‌شده در مرحله قبل تحویل داده شد و میانگین خطای تمام آن‌ها محاسبه گردید. درمجموع میانگین دقت شبکه در تمامی آزمون‌ها ۰/۰٦٦٥ به دست آمد.

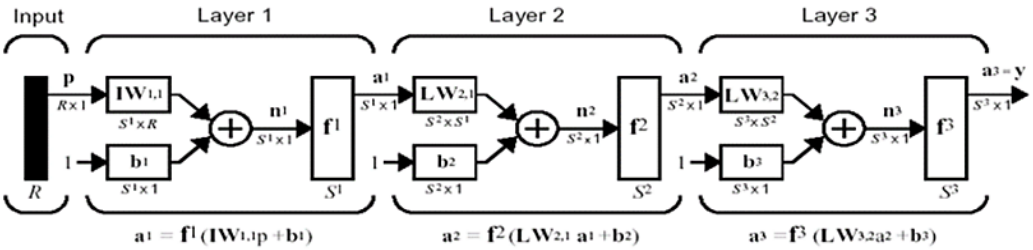


$$a_3 = f^3\,(LW_{3,2}\, f^2\,(LW_{2,1} f^1\,(IW_{1,1}p + b_1) + b_2) + b_3 = y$$

**شکل ۴- معماری شبکه عصبی پرسپترون ۳ لایه مورد استفاده در این مطالعه.**

**Figure 4- 3 layer perceptron neural network architecture used in this study.**

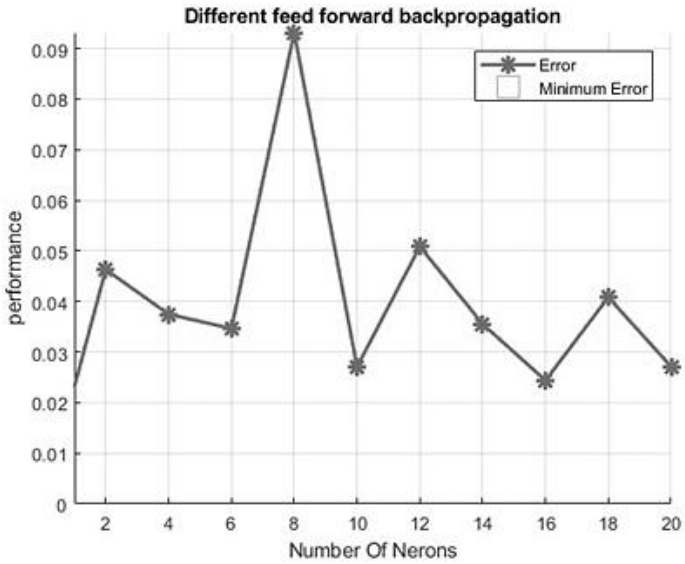


**شکل ۵- تغییرات خطا با توجه به نوع معماری شبکه.**

**Figure 5- Error changes according to the type of network architecture.**

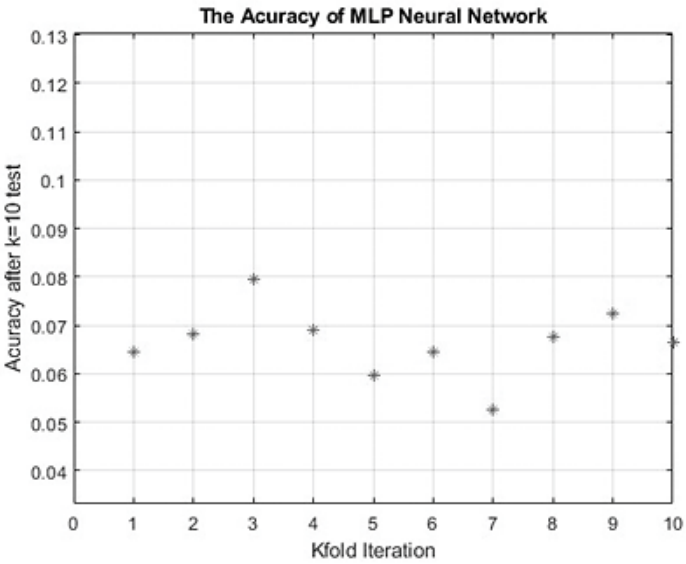


شکل ۶- میانگین خطای عصبی به روش Kfold در ۱۰ تکرار و k=5.

**Figure 6- Mean Kfold neural error in 10 replications and k = 5.**

## ۴-۲- کیفیت‌سنجی آهک با استفاده از سیستم فازی عصبی (ANFIS)

سیستم‌های فازی، سیستم‌هایی هستند که برای ایجاد نگاشت غیرخطی از ورودی به خروجی مورداستفاده قرار می‌گیرند. این نوع از شبکه‌ها برای مدل‌هایی که نمی‌توان توصیف دقیقی برای آن‌ها یافت، کاربرد دارند. ویژگی بسیار مهم آن‌ها، این است که نیازی به فرمول یا مدل ریاضی، برای طراحی ندارند، بنابراین در مورد طراحی سیستم‌هایی که نتوان عملکرد آن‌ها را به‌صورت مدل ریاضی بیان کرد، مانند مدل‌سازی کیفیت‌سنجی آهک بسیار مفید و مناسب به نظر می‌رسند. در این فاز از مطالعه به‌منظور کیفیت‌سنجی آهک از شبکه عصبی-فازی استفاده شده است. ازآنجایی‌که پارامترهای مفروض به‌منظور پیش‌بینی کیفیت آهک، طبق **جدول ۱** شامل ۸ فاکتور است، لذا تعداد ورودی متغیرها در لایه اول ۸ می‌باشد. لایه آخر خروجی شبکه (*f*) است که هدف آن به حداقل رساندن اختلاف خروجی به‌دست‌آمده از شبکه و خروجی واقعی است که کیفیت آهک را پیش‌بینی می‌کند. آموزش شبکه عصبی-فازی به‌صورت یادگیری با ناظر است. ساختار شبکه عصبی-فازی از نوع الگوریتم آموزش هیبرید و شبکه انفیس به کار گرفته شده در این پژوهش دارای تابع عضویت از نوع "*linear*" در لایه خروجی و تابع عضویت از نوع "*gaussmf*" در لایه ورودی می‌باشد.

برای هریک از ویژگی‌ها یک متغیرهای زبانی بین ۲ تا ٦ تابع عضویت در نظر گرفته شده است. به‌عنوان نمونه **شکل ۷** متغیر پیش‌گرمکن کوره (*preheater*) را نشان می‌دهد که شامل ۵ تابع عضویت است؛ مانند مرحله اول، پس از تقسیم‌بندی داده‌ها به روش *kfold* نمونه‌ها به شبکه فازی عصبی اعمال گردید. در هر بار تکرار از ٤٥٢ نمونه ٣٦٢ نمونه به‌عنوان داده آموزش (*Trian*) و ۹۰ نمونه به‌عنوان داده آزمون (*Test*) مورداستفاده قرار گرفت. **شکل ۸** میانگین خطای محاسبه‌شده در هر مرحله را نشان می دهد.

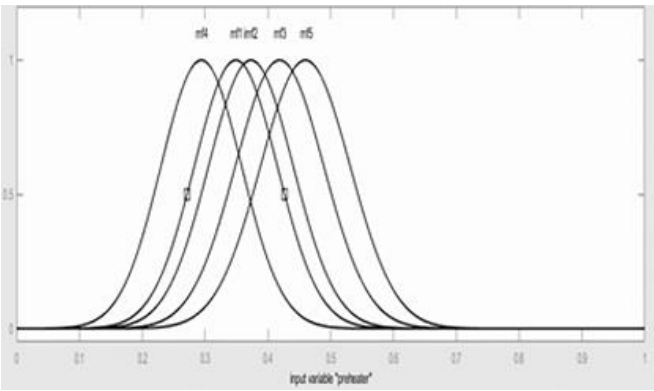

شکل ۷- توابع عضویت متغیر پیش گرمکن کوره.

**Figure 7- Variable membership preheater furnace membership functions.**

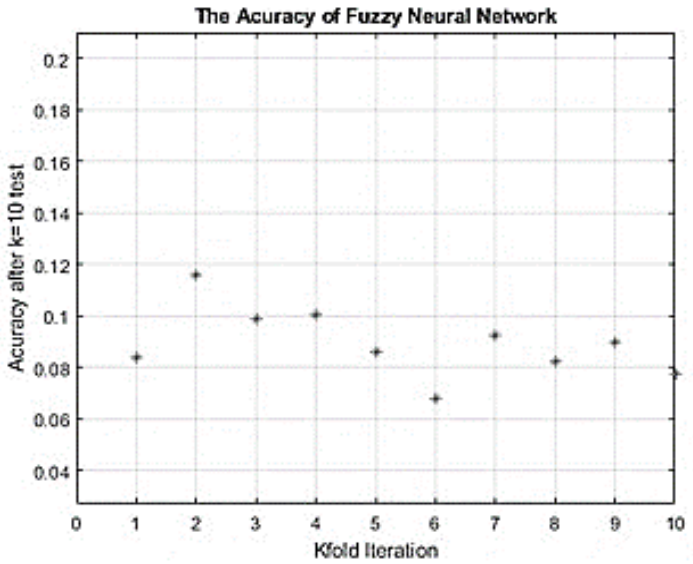


شکل ۸- میانگین خطای مدل عصبی- فازی به روش اعتبار سنجی متقابل در ۱۰ تکرار و k=5.

**Figure 8- Mean fuzzy neural error by cross-validation method in 10 replications and k = 5.**

## ۳- یافته‌های پژوهش

در این مطالعه ٤٥٢ داده مربوط به کارخانه آهک از طریق برگه‌های لاگ شیت (*Log Sheet*) جمع‌آوری گردید؛ هر یک از نمونه‌ها شامل ۸ ویژگی مندرج در **جدول ۱** است. از این تعداد نمونه ٪۸۰ به روش *kfold* جداسازی و به‌منظور آموزش به دو شبکه عصبی مصنوعی و شبکه فازی عصبی تحویل گردید؛ از ٪۲۰ باقیمانده جهت آزمون شبکه‌ها استفاده شده و میانگین خطا ثبت گردید. نتایج به‌دست‌آمده نشان می‌دهد که استفاده از هر دو مدل می‌تواند با دقت مطلوبی کیفیت آهک را پیش‌بینی نماید هرچند که دقت شبکه عصبی-فازی بیشتر می‌باشد. **جدول ٤** این واقعیت را نشان می‌دهد.

جدول ۴- نتایج حاصل از پیش‌بینی کیفیت آهک در کوره با استفاده از شبکه عصبی و فازی عصبی.

**Table 4- Results of predicting the quality of lime in the furnace using neural and fuzzy neural networks.**

| ساعت | کیفیت | تناژ ورودی | فیدر | آی‌دی فن | کوره | پیش گرمکن | کولر | میزان سوخت مصرفی | پیش بینی کیفیت آهک (شبکه عصبی) | پیش بینی کیفیت آهک (فازی-عصبی) |
|---|---|---|---|---|---|---|---|---|---|---|
| 7 | 0/95 | 14 | 11 | 790 | 13/5 | 16 | 18 | 2000 | 0/94 | 0/95 |
| 11 | 0/95 | 16 | 10/6 | 780 | 14 | 17 | 18 | 1950 | 0/93 | 0/94 |
| 12 | 0/95 | 15 | 10/6 | 787 | 19 | 17 | 18 | 2026 | 0/94 | 0/93 |
| 18 | 0/87 | 17 | 5/7 | 730 | 17/5 | 18 | 20 | 1600 | 0/83 | 0/88 |
| 20 | 0/90 | 14 | 5 | 737 | 14 | 15/6 | 16 | 1950 | 0/91 | 0/90 |
| 17 | 0/96 | 17 | 6 | 730 | 17/5 | 18 | 20 | 1700 | 0/96 | 0/97 |
| 12 | 0/95 | 20 | 6/7 | 770 | 17/5 | 35 | 19 | 1900 | 0/92 | 0/97 |
| 13 | 0/94 | 20 | 6/7 | 770 | 17/5 | 35 | 19 | 1900 | 0/95 | 0/94 |
| 22 | 0/94 | 16 | 5/5 | 782 | 18 | 19 | 20 | 1936 | 0/96 | 0/93 |
| 23 | 0/96 | 17 | 6 | 786 | 18 | 18 | 20 | 1971 | 0/94 | 0/97 |

**شکل ۹** خروجی مدل فازی و خروجی واقعی و انحراف معیار خطا را نشان می‌دهد. درمجموع میانگین دقت پس از ۱۰ بار آزمون ۰٫۰٥٤ به دست آمد.

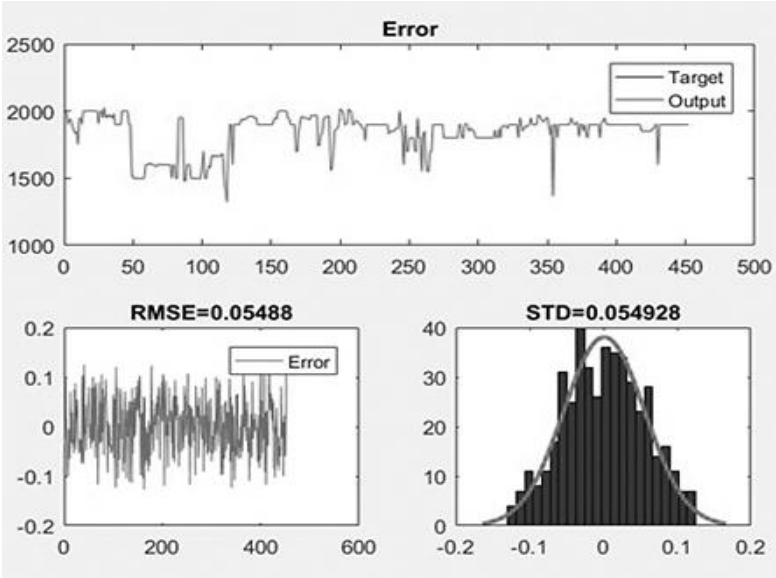


شکل ۹- نمودار میزان خطا و انحراف معیار و کمترین مربعات خطا در شبکه فازی عصبی.
**Figure 9- Error rate and standard deviation and least squares of error in neural fuzzy network.**

## ۴- بحث و نتیجه‌گیری

هرکدام از شبکه‌های عصبی و سیستم‌های فازی دارای نواقص خاص خود هستند. وقتی سیستمی تنها با شبکه عصبی طراحی می‌شود، مدل درواقع شبیه جعبه سیاهی است که نیاز به تعریف شدن دارد و یک فرآیند کاملا محاسباتی و سنگین خواهد بود. از طرف دیگر، در طراحی سیستم‌های فازی نیاز به فهم عمیقی از متغیرهای فازی و توابع عضویت و همچنین انتخاب صحیح قوانین فازی است. شبکه‌های عصبی-فازی به بهترین نحو این دو سیستم را (سیستم عصبی و سیستم فازی) ترکیب می‌کند. در این پژوهش سعی شد برای تخمین کیفیت آهک از روش‌های مختلف داده‌کاوی با تکیه بر شبکه‌های عصبی و فازی عصبی استفاده شود. در اولین مرتبه مدل‌سازی از یک شبکه عصبی پرسپترون چندلایه با الگوریتم پس انتشار خطا استفاده شد؛ و کلیه ۸ فاکتور مربوط به ورودی‌ها به شبکه عصبی اعمال گردید. در مرحله دوم مدل‌سازی از شبکه‌های عصبی-فازی استفاده شد. همچنین معماری‌های مختلف شبکه عصبی ازنظر تعداد نرون‌ها و لایه‌ها و نیز معماری‌های مختلف شبکه فازی عصبی ازنظر تعداد قوانین برای حصول بهترین نتیجه موردبررسی قرار گرفت. اهمیت پیش‌بینی ازآن‌جهت است که اگر اپراتور بتواند کیفیت آهک را قبل از اعمال ورودی‌ها به کوره پخت تشخیص دهد، می‌تواند با تنظیم دقیق پارامترها در مصرف سوخت صرفه‌جویی قابل‌توجهی نماید.

## تعارض با منافع

نویسندگان اعلام می‌دارند که هیچ تعارض منافعی در پژوهش حاضر وجود ندارد.

## منابع

Abdollahi Sharif, J., Alilu, M., & Kazemi, F. (2019). Study The Role of mineral additives on grind ability and quality of cement clinker. *Concrete research*, *12*(2), 111-125. (**In Persian**). DOI: 10.22124/jcr.2019.11891.1322

Altun, O. (2016). Simulation aided flow sheet optimization of a cement grinding circuit by considering the quality measurements. *Powder technology*, *301*, 1242-1251.

Asadi, A., & Enayatollahi, E. (2016). Prediction of fragmentation by blasting operation in mines- case study: Gol-e-Gohar iron mine, *6*(18), 17-30. (**In Persian**). https://geojournal.islamshahr.iau.ir/article_524528.html?lang=en

Bagheri, M., Babaei Meybodi, N., & Enzebati, A. H. (2018). Modeling and optimizing a multi-objective flow shop scheduling problem to minimize energy consumption, completion time and tardiness. *Journal of decisions and operations research*, *3*(3), 204-222. DOI: 10.22105/dmor.2018.81214

Bahrami, A., Abdollahi Sharif, J., Alilu, M., & Kazemi, F. (2019). Study the role of mineral additives on grind ability and quality of cement clinker. *Concrete research*, *12*(2), 111-125. DOI: 10.22124/jcr.2019.11891.1322

Bastami, R., Aghajani Bazzazi, A., Hamidian Shoormasti, H., Ahangari, K. (2020). Prediction of blasting cost in limestone mines using gene expression programming model and artificial neural networks. *Journal of mining and environment*, *11*(1), 281-300. https://www.sid.ir/paper/256380/fa

Chehreghani, S., Dadrasi, M., Alipour, A., Mokhtarian, M., & Hoseynzade, H. (2019). Investigating the possibility of mechanized mining by continuous surface miner machines in Rashakan limestone mine of Urmia cement plant based on Rock Mass Excavatability index rating method. *New findings in applied geology*, *13*(25), 85-96. DOI: 10.22084/nfag.2018.14697.1276

Masjedi khak, P., Modirrousta, S., Nami, H., Kabiri, K., Khazaie Kuhper, M. (2021). Studying the chemical composition of sgraffiato pottery: a case study of the Shahkoh Alamut site. *Archaeological researches of Iran (archaeological journal)*, *11*(28), 135-151. (**In Persein**). https://www.sid.ir/paper/388946/fa

Mojody, S., Amindoost, A., & Nikbakht, M. (2017). Ranking of the approaches to reduce electrical energi consumption using AHP topsis in Esfahan sepahan cement Co. *Journal of decisions and operations research*, *2*(1), 17-34. DOI: 10.22105/dmor.2017.50226

Vanderborght, B., & Brodmann, U. (2001). The cement $Co_2$ protocol: $Co_2$ emissions monitoring and reporting protocol for the cement industry pastes and mortars. *Cement and concrete research*, *33*, 1765–17703.

Vise, S., & khodabandeh, N. (2005). Effect of application of limestone powder on the properties of building bricks. *Amirkabir journal of science and research*, *35*(2), 1. (**In Persin**). https://ajsr.aut.ac.ir/article_2188.html?lang=fa