



# پیش‌بینی غلظت عناصر با استفاده از تکنیک طیف‌نمایی القائید لیزری با بهره‌گیری از روش‌های آماری شبکه عصبی مصنوعی، میانگین متحرک خودبرگشت تجمعی و رگرسیون بردار پشتیبان و ترکیب آنها

محسن رضائی<sup>۱</sup>، پروین کریمی<sup>۲</sup> و فاطمه رضائی<sup>۳\*</sup>

۱. گروه مهندسی صنایع، دانشگاه علم و فناوری مازندران، بهشهر

۲. گروه فیزیک، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران

۳. دانشکده فیزیک، دانشگاه خواجه نصیرالدین طوسی، تهران

پست الکترونیکی: fatemehrezaei@kntu.ac.ir

(دریافت مقاله: ۱۴۰۰/۸/۲۶؛ دریافت نسخه نهایی: ۱۴۰۰/۱۲/۲۲)

## چکیده

در این مقاله، با استفاده از تکنیک طیف‌سنجی فروشکست القائید لیزری، غلظت‌های عناصر موجود در آلیاژهای استاندارد آلومینیوم به طور کمی اندازه‌گیری شده است. لیزر تپی Nd:YAG در طول موج ۱۰۶۴ nm روی نمونه‌های استاندارد آلومینیوم تابیده شده است و با استفاده از پلاسمای ایجاد شده، تحلیل‌ها انجام شده است. از بین روش‌های مختلف تحلیل جهت برآورد غلظت عناصر موجود در نمونه‌های آلومینیم، روش‌های شبکه عصبی مصنوعی، الگوریتم تخمین‌گر بردار پشتیبان، میانگین متحرک خودبرگشت تجمعی، مدل رگرسیون بردار پشتیبان مبتنی بر کرنل و مدل ترکیبی KSVR-ARIMA برای پیش‌بینی غلظت عناصر آهن، مس، روی، منگنز و سیلیس مورد استفاده قرار گرفته‌اند و نتایج به دست آمده از این روش‌ها با هم مقایسه شده‌اند. نتایج به دست آمده نشان می‌دهد که روش ترکیبی KSVR-ARIMA، بهترین مقادیر پیش‌بینی را با کمترین خطای اغلب عناصر اشاره شده گزارش می‌کند.

**واژه‌های کلیدی:** طیف‌نمایی فروشکست القائید لیزری، آلومینیوم، شبکه عصبی مصنوعی، آریما، رگرسیون بردار پشتیبان

## ۱. مقدمه

### مطالعات آزمایشگاهی بسیاری با استفاده از این روش صورت

پذیرفت، به‌طوری‌که در دو دهه اخیر پیشرفت‌های بسیاری با بهره‌گیری از این روش به دست آمده است. این تکنیک طیف‌نمایی، یک تپ توان بالای لیزر را برای ایجاد پلاسما روی نمونه (در هر نوعی از فاز ماده) به کار می‌گیرد. با تحلیل طیفی

طیف‌سنجی فروشکست القائید لیزری (LIBS<sup>۱</sup>) یک تکنیک تحلیل گسیل اتمی پیشرفته در تحلیل و شناسائی عناصر است. این روش پس از کشف لیزر معرفی شد و از آن زمان به بعد،

۱. Laser induced breakdown spectroscopy

در این مقاله به مطالعه تحلیل کمی آلیاژ آلومینیوم با استفاده از پنج روش آماری شبکه عصبی مصنوعی (ANN<sup>۳</sup>)، رگرسیون بردار پشتیبان (SVR<sup>۴</sup>)، میانگین متحرک خودبرگشته تجمعی (ARIMA<sup>۵</sup>) و رگرسیون بردار پشتیبان کرنلی (KSVR<sup>۶</sup>) و ترکیب آنها پرداخته شده است و روش مطلوب گزارش شده است.

## ۲. چیدمان آزمایش

شکل ۱ طرح کلی نشان دهنده چیدمان آزمایش است. در این آزمایش، از یک لیزر پیپی Nd:YAG با طول موج ۱۰۶۴ nm، نرخ تکرار ۱۰ Hz و پهنه‌ای تپ ۶ نانوثانیه استفاده شده است. قطر باریکه خروجی ۲/۳ mm و مدد آن در حالت TEM<sub>00</sub> قرار دارد. تپ لیزر توسط یک عدسی با فاصله کانونی ۲۰ cm روی سطح نمونه متتمرکز شده و پلاسمائی در سطح نمونه تولید می‌شود. در این تحقیق، نمونه موردنظر برای آزمایش، هفت نمونه آلیاژ متفاوت آلومینیوم استاندارد است. عناصر سازنده این آلیاژها، عناصر Zn, Mg, Mn, Cu, Si و Fe است که خطهای طیفی قوی آنها به ترتیب عبارت است از:

$Zn (334/50 \text{ nm})$ ,  $Mn (257/61 \text{ nm})$ ,  $Mg (285/21 \text{ nm})$ ,  
 $Cu (324/75 \text{ nm})$ ,  $Si (288/15 \text{ nm})$ ,  $Fe (274/64 \text{ nm})$

در جدول ۱ نمونه‌های مختلف آلیاژ استاندارد آلومینیوم با عناصر سازنده آن نشان داده شده است. نمونه‌های استاندارد آلومینیوم از شرکت استاندارد رازی خریداری شده‌اند. برای محاسبه نسبت طیف‌های عناصر به نوفه، خطوط قوی آلومینیوم، به عنوان عنصر غالب انتخاب شدند که شامل ۴ خط قوی آلومینیوم در طول موج‌های ۳۹۶, ۱۵, ۳۹۴, ۴۰ nm و ۳۰۹, ۲۷ nm هستند. با تکرار آزمایش‌ها، مشاهده شد که برای چهار عنصر Si, Mn, Mg, Cu زمان تأخیری بهینه تقریباً ۶۰۰۰ تا ۶۵۰۰ نانوثانیه است ولی برای دو عنصر Fe و Zn زمان تأخیری بهینه، ۲۰۰۰ نانوثانیه است. بعد از تنظیم چیدمان اولین آزمایش با زمان تأخیری ۶۰۰۰ نانوثانیه، مجموعاً ۸۹ طیف و با زمان

نور گسیل شده از پلاسما می‌توان عناصر و ترکیبات شیمیایی موجود در نمونه را آشکارسازی کرد. به دلیل نقش پلاسما در این روش، گاهی به این روش "طیف‌ستنجی پلاسمای لیزری" نیز گفته می‌شود. تحلیل طیفی نور گسیل شده مانند یک "اثر انگشت" برای عناصر موجود در نمونه است. علاقه به این روش به دلیل ویژگی‌های خاص آن است که آن را از روش‌های متداول نظریه APXS<sup>۱</sup> که تحلیل با آنها ساعتها طول می‌کشد، متمایز ساخته است. چیدمان آزمایش در این روش بسیار ساده است، مطالعه روی نمونه در فشار و دمای اتاق بدون احتیاج به پیش آماده‌سازی ماده می‌تواند صورت گیرد و مقدار بسیار کمی از ماده (در حد  $\mu\text{g}$  یا ng) برای تجزیه و تحلیل عنصری نمونه کافی خواهد بود. تجزیه و تحلیل آنی و سریع عناصر در مواد و همچنین مشخصه غیر تتماسی این روش در مواردی که امکان بررسی و عنصری آنها از نزدیک میسر نیست، از مزایای دیگر این روش است. بیشترین مقداری که در این روش می‌توان آشکارسازی کرد در مرتبه ppm است. استفاده از تپ‌های فوق کوتاه ps و fs، تغییر فشار، تغییر ترکیبات گاز احاطه کننده پلاسما، تغییر دمای نمونه و همچنین تغییر خصوصیات لیزری از جمله کارهای صورت گرفته در این زمینه هستند. علاوه بر این، استفاده از تپ‌های دوتائی ns و ns-fs باعث افزایش قابل توجهی در شدت گسیل اتمی شده است. دقت این تکنیک وابسته به همگنی نمونه و شرایط دیگر نظری فضای اطراف، پارامترهای فیزیکی و ترکیب ماتریس نمونه است. اگر این شرایط به خوبی کنترل شود دقت این تکنیک بسیار بالا خواهد بود. به طور کلی، روش LIBS تکنیکی مؤثر در اندازه‌گیری‌های کمی و کیفی طیف‌های گسیل شده از عناصر مختلف در اثر پلاسمای ایجاد شده ناشی از کندگی لیزر است [۱]. کاربردهای گسترده این روش در زمینه‌های مختلفی از جمله بیولوژی [۲]، باستان شناسی [۳]، تحلیل فلزات [۴-۶]، زمین شناسی [۷]، سنگ و خاک و رسوبات [۸]، زیست پزشکی [۹] و مخلوط‌های گازی و آئروسل‌ها [۱۰] گزارش شده است.

<sup>۳</sup>. Artificial neural network

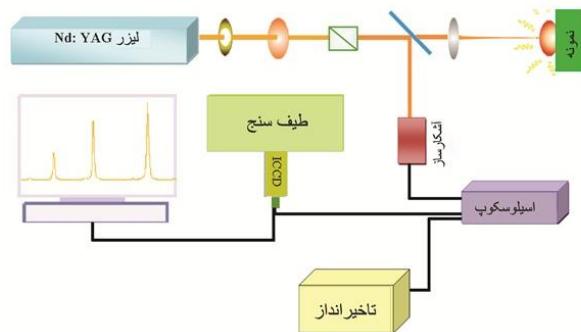
<sup>۴</sup>. Support vector regression

<sup>۵</sup>. Autoregressive integrated moving average

<sup>۶</sup>. Kernelized support vector regression

<sup>۱</sup>. Alpha particle X-ray spectrometer

<sup>۲</sup>. X-ray fluorescence



شکل ۱. نمایی از چیدمان آزمایش LIBS جهت اندازه‌گیری غلظت نمونه‌های آلومینیوم.

جدول ۱. نمونه‌های استاندارد آلیاژ آلومینیوم با ذکر غلظت عناصر سازنده آنها.

شماره نمونه	Si	Fe	Cu	Mn	Mg	Zn	Al
۹۹/۱۲۰	۰/۰۹۸	۰/۰۱۸	۰/۰۴۵	۰/۲۴	۰/۱۹	۰/۲۸	۱۱۰۰
۹۴/۱۴۷	۰/۰۲۹	۰/۶۵	۰/۲۲۵	۳/۴۳	۰/۵۸۲	۰/۸۹۵	۲۰۱۷
۹۵/۷۳۱	۰/۳۶	۱/۰۹	۱/۶۸	۰/۳۳	۰/۵۱۷	۰/۲۳۰	۳۰۰۴
۹۳/۷۳۷	۰/۱۸	۰/۲۵	۰/۰۷	۰/۳۰	۰/۷۵	۴/۵۵	۴۰۴۳
۹۸/۲۰۰	۰/۰۲۰	۱/۱۶	۰/۲۴	۰/۰۷	۰/۱۸	۰/۰۹۷	۵۳۵۷
۹۶/۲۱۱	۰/۳۲	۱/۰۳	۰/۴۴	۰/۳۶	۰/۴۱	۰/۹۳	۶۰۱۰
۸۹/۹۵۱	۴/۱۵	۴/۳۴	۰/۱۷	۰/۶۷	۰/۳۲	۰/۱۸	۷۰۷۹

طیف‌سنج در حدود ۰/۰۲ nm و بازه طیف‌گیری ۲۰۰ nm تا ۸۰۰ nm است که در این بازه، شدت عناصر و یون‌های مختلف Al, Si, Fe, Cu, Mn, Mg, Zn در بازه طیفی ۲۵۰-۴۰۰ nm قابل اندازه‌گیری هستند.

### ۳. محاسبات آماری

به طور کلی، روش‌های آماری متعددی از قبیل شبکه عصبی، رگرسیون خطی چندگانه (MLR<sup>۱</sup>)، تحلیل مؤلفه‌های اصلی (PCA<sup>۲</sup>)، میانگین متحرک خود برگشت تجمعی، مدل رگرسیون بردار پشتیبان و روش‌های ترکیبی جهت پیش‌بینی پارامترهای مجهول به کار می‌روند. در این پژوهش، از پنج مدل آماری میانگین متحرک خود برگشت تجمعی یا آریما، شبکه عصبی مصنوعی، مدل رگرسیون بردار پشتیبان (خطی و کرنلی) و

تأخیری ۲۰۰۰ نانوثانیه مجموعاً ۸۷ طیف حاصل شد. در طول آزمایش، نمونه در جهت عمود بر پرتو لیزر حرکت کرده و هر تپ به نقطه جدیدی از نمونه برخورد می‌کند. به منظور انجام محاسبات آماری، سطح زیر نمودار طیف‌ها برای هر خط مورد تحلیل محاسبه می‌شود و تابش زمینه از آنها کسر می‌شود و بدین ترتیب، بهترین رگرسیون به دست می‌آید. این سطح زیر نمودار به عنوان شدت خط طیفی لحاظ می‌شود. غلظت نمونه‌ها از آنجا که استاندارد هستند، کاملاً مشخص است که در جدول ۱ مقادیر آنها ذکر شده است. انرژی تپ اندازه‌گیری شده ۵۰ mJ است. نور تابش شده از پلاسمای از طریق یک عدسی با فاصله کانونی ۳۵ mm به داخل یک فیرنوری متمرکز شده و از طریق فیرنر به یک طیف‌سنج از نوع اشل (Echelle) مجهز به دوربین ICCD، جهت تجزیه و تحلیل اطلاعات طیفی انتقال می‌یابد. در این آزمایش‌ها، زمان نورگیری برابر با ۵ میکروثانیه است. قدرت تفکیک‌پذیری

۱. Multiple linear regression

۲. Principal component analysis

پارامترهای مدل است که می‌توان از روش حداقل مربعات استفاده کرد. در صورت غیرخطی بودن مدل نسبت به پارامترها، از روش‌های تخمین غیرخطی استفاده می‌شود. مرحله سوم: فرایند تشخیص است که در این مرحله، مدل از نظر برآش در مورد باقی‌ماندهای مدل با انجام آزمون ایستایی کنترل می‌شود. در صورت نامناسب بودن، مدل باید تصحیح شود و روش‌های تشخیصی برای بهبود کارکرد مدل مورد استفاده قرار گیرد. مرحله چهارم: پیش‌بینی کوتاه مدت سری‌های زمانی است که با مدل نهایی بدست آمده مورد بررسی قرار می‌گیرد. لازم به ذکر است که نکته مهم در این روش این است که ARIMA یک روش تکرار است به طوری که اگر مدل اولیه تشخیص درست عمل نکند، باید دوباره به مرحله سوم، تشخیص آزمایشی، بازگشته و مدل جدید و بهتری را بدست آورد و در ادامه پارامترهای مدل جدید را تخمین زد که با توجه به آنها کارا و مناسب بودن مدل بررسی می‌شود. این چرخه چهار مرحله‌ای تا زمانی که مدل مناسب برای پیش‌بینی بازه‌های سری زمانی در آینده یافت نشود، ادامه خواهد یافت. البته این روش برای داده‌های ناپیوسته، پیوسته و مقطعی هم کاربرد دارد به طوری که باید در فاصله‌های زمانی مساوی، مورد استفاده قرار گیرد. در توصیف محاسبات به کار رفته در این مدل باید گفت، این مدل همان ARMA است با این تفاوت که جزء تفاضل‌گیری هم به آن افزوده شده است که از رابطه زیر پیروی می‌کند:

$$X_t = \alpha_0 X_{t-d} + \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_p X_{t-p} - \beta_1 \varepsilon_{t-1} - \beta_2 \varepsilon_{t-2} - \dots - \beta_q \varepsilon_{t-q}, \quad (1)$$

در رابطه (1)،  $\alpha_0, \alpha_1, \dots, \alpha_p$  ضرایب ثابت رگرسیون خودکار و  $\beta_1, \dots, \beta_q$  ضرایب ثابت مدل میانگین متحرک هستند. در مدل ARIMA(p,d,q) با درجه تفاضل‌گیری d، پارامتر مرتبه خودرگرسیون را با p و پارامتر میانگین متحرک را با q نمایش می‌دهند که با سعی و خطا به دست می‌آیند [۱۱].

### ۳. مدل‌های KSVR و SVR

مدل رگرسیون بردار پشتیبان (SVR) الگوریتم رگرسیون مبتنی

ترکیب آریما با KSVR. جهت پیش‌بینی غلطت عناصر سازنده آلیاژهای مختلف آلومینیوم استفاده شده است.

در این پژوهش، یک نمونه استاندارد به عنوان مجهول استفاده شده است که غلطت آن پیش‌بینی می‌شود. در کلیه این روش‌ها، با استفاده از شش نمونه استاندارد مدنظر، شبکه عصبی یا آریما، SVR و مدل ترکیبی ساخته می‌شود. ورودی این روش‌ها، شدت‌های خطوط طیفی مورد تحلیل است که همان سطح زیر نمودار کسر شده از تابش زمینه است و خروجی غلطت عناصر است.

### ۳. ۱. مدل ARIMA

در علم آمار چندین مدل برای شبیه‌سازی داده‌های مرتب شده بر حسب زمان مورد استفاده قرار می‌گیرد. چهار مدل خود بازگشت (AR<sup>(۱)</sup>، میانگین متحرک (MA<sup>(۲)</sup>، میانگین متحرک خودبازگشت (ARIMA<sup>(۳)</sup>) و میانگین متحرک خودبازگشت تجمعی (ARIMA<sup>(۴)</sup>) از معروف‌ترین روش‌های مورد استفاده هستند [۱۱].

روش میانگین متحرک خود بازگشت تجمعی یکی از متداول‌ترین مدل‌های تحلیل پیش‌بینی در سری‌های زمانی است [۱۲]. این روش برای اولین بار در سال ۱۹۷۰ توسط جی. ای. پی باکس و جی. ام جنکینز ارائه شد [۱۱]. در برخی از روش‌های آماری، داده‌ها و مشاهدات از همدیگر مستقل هستند ولی در زمینه‌های دیگری همچون تجارت و اقتصاد، مهندسی و علوم پایه، بیشتر داده‌ها به شکل سری‌های زمانی دیده می‌شوند. این داده‌ها به طور متوالی به هم وابسته هستند و اندازه‌گیری این وابستگی در بازه‌های زمانی مساوی صورت می‌گیرد. مراحل تجزیه و تحلیل سری‌های زمانی شامل شناسایی تکراری، برآورد، تشخیص و پیش‌بینی است [۱۳]. این مراحل به طور مختصر بدین شرح است: مرحله اول: تمرکز بر شناسایی داده‌های ایستا است. جهت سنجش ایستایی و حذف روندهای ایستا است. مرحله دوم: تخمین فولر تعیین یافته استفاده کرد [۱۴]. در صورت ایستا نبودن با متمایز کردن، داده اولیه را می‌توان ایستا کرد. مرحله سوم: تخمین

۱. Auto regressive

۲. Moving average

۳. Autoregressive moving average

آن دارد که کاملاً با محاسبات کامپیوتری متفاوت است. مغز انسان مانند یک پردازنده موازی، پیچیده و غیرخطی است که توانایی اداره کردن نرون‌ها، به عنوان اعضای تشکیل دهنده اش را دارد مغز انسان ساختار بسیار قوی دارد و توانایی ساخت و ایجاد قوانینی در درون خود را دارد که به تجربه اشاره می‌کند. یک نرون مانند یک مغز شکل پذیر است و ویژگی شکل پذیری و هماهنگی با محیط اطرافش را دارد. در یک حالت عمومی، شبکه عصبی مصنوعی یک ماشین پردازنده و به عنوان یک مدل از راهی است که مغز یک عملکرد خاص را اجرا می‌کند. اجرای شبکه از طریق فرایندی که به یادگیری اطلاق می‌شود، انجام می‌شود و دستورالعملی که برای اجرای یادگیری به کار می‌گیرد الگوریتم یادگیری<sup>۲</sup> نامیده می‌شود. این عملکرد برای تغییر وزن‌ها (سیناپس- اتصالات بین نرون‌ها) برای رسیدن به یک طراحی مطلوب است. حتی شبکه ممکن است که تپولوژی خود را تغییر دهد تا به این هدف دست یابد. به این طریق که نرون‌ها می‌توانند بمیرند و شدت قدرت سیناپس‌ها نیز تغییر کند. با توجه به قابلیت اکتشاف روابط غیرخطی بین متغیرها، شبکه عصبی مصنوعی یک روش کارا جهت پیش‌بینی در مقایسه با روش‌های خطی سنتی است [۱۹].

#### ۴. مدل ترکیبی KSVR-ARIMA

امروزه، استفاده از مدل‌های ترکیبی، کمک شایانی در کاهش زمان، افزایش دقت و پیش‌بینی‌های دقیق‌تر کرده است. در این تحقیق، پس از محاسبات غلظت با استفاده روش‌های آماری مجزای ARIMA و KSVR، غلظت عناصر آلیاژ آلومینیوم با استفاده از ترکیب این دو مدل نیز برآورد شده است. یعنی ابتدا، با مدل KSVR نتایج پیش‌بینی به دست می‌آید، سپس اختلاف این مقادیر پیش‌بینی نسبت به مقادیر باقی‌مانده در نظر می‌شود. نتایج به دست آمده به عنوان مقادیر باقی‌مانده در نظر گرفته می‌شود. در ادامه، مقادیر باقی‌مانده با مدل ARIMA پیش‌بینی می‌شود. سپس مقادیر پیش‌بینی شده با دو روش ARIMA و KSVR با هم جمع می‌شوند و مقدار پیش‌بینی نهایی را تشکیل می‌دهند. در نهایت، برای اندازه‌گیری خط،

بر کرنل است که بر اساس روش ماشین بردار پشتیبان (SVM) ساخته شده است [۱۵]. ماشین‌های بردار پشتیبان برای مسائل طبقه‌بندی به کار می‌روند و بعد از آنها الگوریتم آنها برای کار با مسائل رگرسیون یا تخمین داده‌ها توسعه یافته است که به این الگوریتم جدید، رگرسیون بردار پشتیبان می‌گویند. در این روش، مجموعه‌ای از داده‌ها به شکل  $(x_1, y_1), \dots, (x_n, y_n)$  به عنوان آموزش داده می‌شوند که در این تحقیق،  $x_n$ ها ورودی‌های طیف  $y_n$ ها شدت‌های مربوطه هستند و  $n$  تعداد نمونه‌ها است.

در مدل SVR غیرخطی، داده‌ها به فضایی با ابعاد بزرگ‌تر توسط تابع کرنل انتقال می‌یابند. تابع تخمین‌گر می‌تواند توسط تابع کرنل به صورت تابعی بین ورودی و خروجی با کمترین خطای ممکن ارتباط برقرار کند [۱۶].

$$y = \sum_{i=1}^l (\alpha_n - \alpha_n^*) K(x_n, x_i) + b, \quad (2)$$

در معادله بالا،  $b$  جمله سووییده،  $K$  تابع کرنل،  $\alpha_n$  و  $\alpha_n^*$  ضرایب غیرمنفی برای هر مشاهده  $x_n$  هستند. به طور کلی، تابع کرنل می‌تواند به صورت خطی، گوسی و چندجمله‌ای باشد. به عنوان مثال، کرنل چندجمله‌ای از معادله زیر به دست می‌آید:

$$K(x_n, x_i) = (x_n \cdot x_i)^d \quad d=2, 3, \dots \quad (3)$$

همچنین، کرنل گوسی به صورت تابع زیر نمایش داده می‌شود [۱۷]:

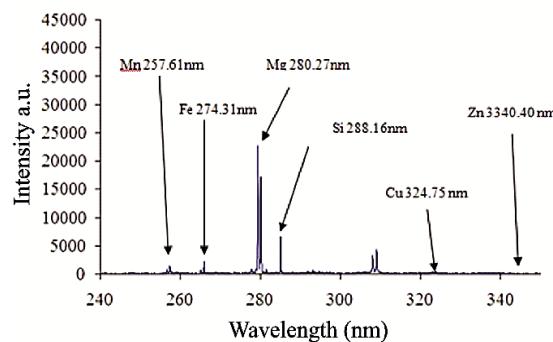
$$K(x_n, x_j) = \exp\left(-\frac{\|x_n - x_j\|^2}{2\sigma^2}\right), \quad (4)$$

در روابط بالا،  $x_n$  و  $x_j$  بردارهای پشتیبان  $n$ ام و  $j$ ام هستند و  $\sigma$  پهنه‌ای تابع کرنل است. لازم به ذکر است که در این پژوهش، جهت یافتن بهترین تابع کرنل، از آزمون خطأ و آزمایش استفاده شده است.

#### ۳. مدل شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی (ANN) ابزارهای محاسبات ریاضیاتی هستند که برای بسیاری از مسائل واقعی و پیچیده مورد استفاده قرار می‌گیرند [۱۸]. شبکه‌های عصبی مصنوعی عموماً اشاره به شبکه‌های عصبی برگرفته شده از مغز انسان و نحوه محاسبات در

۱. Support vector machine



شکل ۲. نمونه‌ای از طیف آلیاژ آلمینیوم با عناصر سازنده آن در طول موج‌های مختلف.

نمایش عناصر سازنده آن در شکل ۲ نشان داده شده است.

برای روش آریما، بایستی داده‌ها ایستا و مانا باشند. بدین منظور از آزمون دیکی‌فولر تعمیم یافته استفاده می‌شود تا شاخص  $p$  برآورد شود که نتایج آن در جدول ۲ ارائه شده است. شایان ذکر است که اگر شاخص  $p$  کمتر از  $0.05$  باشد، داده‌ها قابل قبول و مانا هستند؛ مثل داده‌های مربوط به عناصر Si و Zn. اگر شاخص  $p$  بیشتر از  $0.05$  باشد، داده‌ها مانا نیستند. لذا، از روش تفضیل‌گیری استفاده می‌شود، یعنی داده‌ها را از داده اولیه کم کرده که به آن تفضیل مرتبه اول می‌گویند و اگر نتیجه مطلوب حاصل نشد از تفضیل مرتبه دوم استفاده می‌شود تا به داده‌های مانا دست یابیده شود. بایستی خاطرنشان کرد که در محاسبات این مقاله، تفضیل مرتبه اول، جهت نائل شدن به داده‌های مانا کافی بوده است.

پس از ماناسازی داده‌ها، نتایج مربوط به پیش‌بینی غلظت و محاسبه خطاهای MAE و MSE در روش آماری میانگین متاخرک خودبرگشت تجمعی (ARIMA) در جدول ۳ برای عنصر نوعی Mn ارائه شده است. لازم به ذکر است که مقدار غلظت واقعی مربوط به نمونه آزمون برای این عنصر برابر با  $44\%$  بوده است. همانطور که بهوضوح در این جدول مشاهده می‌شود، کمترین خطای با بیشینه دقت مربوط به ARIMA(0,1,1) است که با رنگ قرمز نشان داده شده است.

در این تحقیق، از مدل شبکه عصبی پرسپترون از نوع پیش‌خور پس انتشار جهت پیش‌بینی غلظت عناصر بهره برده شده است. بهمنظور انتخاب الگوریتم یادگیری برای آموزش

مقدارهای پیش‌بینی شده نهایی با مقادیر واقعی ارزیابی می‌شوند.

#### ۴. معیارهای ارزیابی خطای

در این مطالعه، برای مقایسه قدرت پیش‌بینی و انتخاب بهترین روش، از معیارهای مختلفی برای ارزیابی خطای جمله خطای میانگین مربعی (MSE<sup>۱</sup>)، ریشه میانگین مربعی خطای (RMSE<sup>۲</sup>) و میانگین قدر مطلق خطای (MAE<sup>۳</sup>) استفاده می‌شود که به صورت‌های زیر تعریف می‌شوند [۲۰]:

خطای میانگین مربعی (MSE)

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - f_i)^2, \quad (5)$$

ریشه میانگین مربعی خطای (RMSE) [۲۱]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - f_i)^2}, \quad (6)$$

میانگین قدر مطلق خطای (MAE) [۲۲]:

$$MSE = \frac{1}{n} \sum_{i=1}^n |y_i - f_i|, \quad (7)$$

که در رابطه‌های بالا،  $y_i$  و  $f_i$  به ترتیب، داده‌های پیش‌بینی شده، داده‌های واقعی و نیز  $n$  تعداد داده‌ها است.

#### ۵. نتایج و بحث

نمونه‌ای از طیف‌های حاصل از آلیاژهای آلمینیوم استاندارد با

۱. Mean square error

۲. Root mean square error

۳. Mean absolute error

جدول ۲. شاخص  $p$  و داده‌های اولیه و نیز تفاضل مرتبه اول برای عناصر با  $p < 0.05$ .

عناصر	مقادیر شاخص $p$	
	داده های اولیه	اولین تفاضل
Mn	۰/۰۷۵	۰/۰۰۳
Si	۰/۰۴۷	-
Zn	۰/۰۴۲	-
Fe	۰/۴۱۷	۰/۰۰۱
Cu	۰/۰۶۲	۰/۰۰۱
Mg	۰/۱۷۱	۰/۰۰۸

جدول ۳. نتایج پیش‌بینی غلظت عنصر Mn با غلظت واقعی در آلیاژ آلومینیوم و محاسبه خطاهای پیش‌بینی با استفاده از مدل آریما.

مدل‌های آریما	غلظت پیش‌بینی شده	مقادیر خطأ	
		MSE	MAE
ARIMA(0,1,0)	۰/۳۵۷	۰/۰۰۶	۰/۰۸۳
ARIMA(0,1,1)	۰/۴۱۴	۰/۰۰۱	۰/۰۲۶
ARIMA(0,1,2)	۰/۴۰۳	۰/۰۰۱	۰/۰۳۷
ARIMA(1,1,0)	۰/۲۷۱	۰/۰۲۸	۰/۱۶۹
ARIMA(1,1,1)	۰/۱۴۷	۰/۰۸۵	۰/۲۹۳
ARIMA(1,1,2)	۰/۳۲۴	۰/۰۱۳	۰/۱۱۶
ARIMA(2,1,0)	۰/۲۸۷	۰/۰۲۳	۰/۱۵۳
ARIMA(2,1,1)	۰/۲۶۷	۰/۰۲۹	۰/۱۷۳
ARIMA(2,1,2)	۰/۲۵۳	۰/۰۳۴	۰/۱۸۷

خطای شبکه نسبت به پارامترهای آن است، به دست آمده و وزن‌ها به روز می‌شوند. سپس مجددًا خطای شبکه به دست می‌آید و این الگوریتم بارها تکرار می‌شود تا جایی که کمترین کارایی به دست آید و یا به حداقل تعداد انجام آموزش منجر شود.

جهت انتخاب بهترین توابع انتقال، با استفاده از رویکرد سعی و خطا و پس از بارها تکرار آزمایش‌ها، بهترین توابع انتقال برای هر یک از عناصر در نظر گرفته شده‌اند که نتایج در جدول ۴ نشان داده شده است.

با مروری بر ادبیات این حوزه می‌توان دریافت که به‌ندرت اتفاق می‌افتد که شبکه‌ای بیش از یک لایه مخفی نیاز داشته باشد [۲۴]. همچنین تعداد نرون‌های لایه مخفی را می‌توان با

شبکه طراحی شده، از الگوریتم «لونبرگ-مارکوارت» استفاده شده که بهترین الگوریتم آموزشی توصیه شده است [۲۳]. الگوریتم لونبرگ-مارکوارت توسط لونبرگ و در سال ۱۹۴۴ ارائه شده است. این الگوریتم بر مبنای الگوریتم‌های نیوتون و گرادیان نزولی است. این روش یکی از قدرتمندترین الگوریتم‌ها برای آموزش شبکه‌های عصبی مصنوعی است که نسبت به سایر الگوریتم‌های آموزشی بسیار سریع‌تر به سمت همگرایی می‌رود. این الگوریتم بر مبنای تکرار و با توجه به کمینه کردن مجموع مربعات خطاهای کار می‌کند. مراحل این الگوریتم به این صورت است که ابتدا ورودی‌ها به شبکه ارائه شده و وزن‌های اولیه به دست می‌آید. سپس خروجی شبکه و خطأ محاسبه می‌شود. بعد ماتریس ژاکوبین که مشتق مرتبه اول

جدول ۴. بهترین توابع انتقال لایه‌های شبکه برای عناصر مختلف

توابع انتقال		
لایه پنهان		لایه خروجی
Mn	خطی	خطی
Si	خطی	خطی
Zn	لگاریتم سیگموئید	تائزانت سیگموئید
Fe	خطی	خطی
Cu	تائزانت سیگموئید	خطی
Mg	لگاریتم سیگموئید	لگاریتم سیگموئید

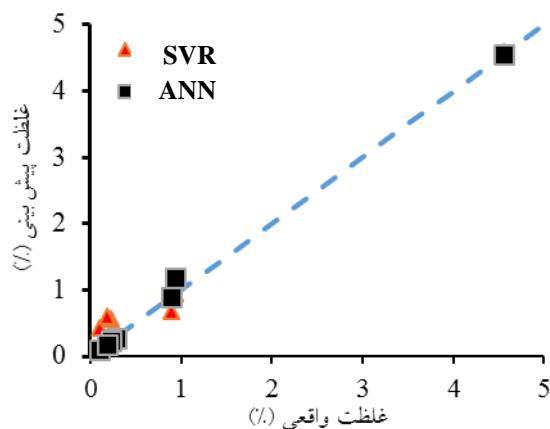
جدول ۵. انتخاب تعداد نرون‌های لایه پنهان برای عناصر مختلف.

تعداد نرون‌های لایه پنهان											
	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	
Mg	MSE	۱/۷۱۰	۱/۹۹۵	۱/۷۲۵	۱/۳۷۸	۱/۳۹۳	۱/۳۷۸	۱/۴۰۶	۱/۳۸۶	۱/۳۸۱	۱/۴۹۱
	MAE	۱/۲۴۷	۱/۳۱۳	۱/۳۱۳	۱/۱۷۴	۱/۱۸۰	۱/۱۷۴	۱/۱۸۵	۱/۱۷۷	۱/۱۷۵	۱/۲۰۹
Fe	MSE	۰/۰۱۶	۰/۰۲۱	۰/۰۲۹	۰/۰۳۳	۰/۰۴۰	۰/۰۴۰	۰/۰۳۳	۰/۰۶۶	۰/۰۹۰	۰/۰۷۷
	MAE	۰/۰۹۳	۰/۱۱۰	۰/۱۱۳	۰/۱۴۹	۰/۱۰۹	۰/۱۶۳	۰/۱۴۸	۰/۲۱۵	۰/۲۴۲	۰/۲۱۳
Si	MSE	۰/۱۴۲	۰/۳۳۰	۰/۴۷۸	۰/۸۷۳	۱/۸۰۷	۱/۲۳۶	۱/۸۶۹	۲/۶۵۰	۲/۳۳۸	۲/۰۴۶
	MAE	۰/۳۰۶	۰/۴۸۴	۰/۴۶۷	۰/۸۳۶	۰/۹۰۵	۰/۹۳۶	۱/۱۱۰	۱/۲۲۷	۱/۲۱۰	۱/۲۳۰
Mn	MSE	۰/۰۶۳	۰/۳۳۸	۰/۴۶۲	۰/۳۳۵	۰/۵۲۴	۰/۴۰۹	۰/۸۶۲	۱/۱۰۸	۰/۵۴۹	۰/۸۳۵
	MAE	۰/۲۰۷	۰/۴۵۳	۰/۵۰۵	۰/۴۴۴	۰/۵۰۴	۰/۵۱۹	۰/۶۶۸	۰/۷۸۷	۰/۵۴۱	۰/۷۳۳
Cu	MSE	۰/۰۴۰	۰/۰۵۶	۰/۰۳۳	۰/۰۶۲	۰/۰۴۹	۰/۰۷۷	۰/۰۹۳	۰/۱۰۷	۰/۰۸۹	۰/۱۰۳
	MAE	۰/۱۸۰	۰/۲۱۲	۰/۱۴۸	۰/۲۲۲	۰/۱۸۰	۰/۲۴۹	۰/۲۷۲	۰/۳۱۰	۰/۲۶۸	۰/۲۸۳
Zn	MSE	۰/۱۰۵	۰/۴۵۷	۱/۰۳۶	۰/۴۰۴	۱/۰۴۸	۱/۰۳۴	۱/۴۷۹	۰/۲۴۱	۰/۵۶۴	۰/۰۸۴
	MAE	۰/۳۱۲	۰/۴۳۶	۰/۵۸۲	۰/۴۲۶	۰/۵۳۰	۰/۵۲۷	۰/۷۰۵	۰/۳۵۳	۰/۴۴۷	۰/۲۸۸

مربوط به این روش در جدول ۵ نشان داده شده است. به طور مشابه از رویکرد رگرسیون بردار پشتیان (SVR) جهت پیش‌بینی غلظت عناصر استفاده شده است. نتایج مربوط به پیش‌بینی این روش در مقایسه با روش شبکه عصبی برای عنصر Si به عنوان نمونه، در شکل ۳ نشان داده شده‌اند. همان‌طور که این شکل نشان می‌دهد نتایج پیش‌بینی این دو روش برای برخی از نقاط تقریباً مشابه هم بوده و روی هم منطبق شده‌اند.

استفاده از رویکرد سعی و خطابه دست آورد [۲۵]. نتایج مربوط به انتخاب تعداد نرون‌های لایه مخفی برای عناصر مختلف در جدول ۵ نشان داده شده است. به عنوان مثال برای عناصر Mg و Fe به ترتیب به ازای ۶ و ۱ نرون، کمترین خطاب حاصل شده است.

طبق رویکردهای مطرح شده، در این تحقیق نیز برای هر یک از عناصر، پارامترهای مورد نیاز مربوط به طراحی شبکه عصبی جهت پیش‌بینی غلظت آنها به دست آمدند. نتایج نهایی



شکل ۳. مقایسه روش‌های شبکه عصبی و رگرسیون بردار پشتیبان جهت پیش‌بینی غلظت عنصر Si.

جدول ۶. نتایج مربوط به محاسبه خطوط غلظت پیش‌بینی شده برای عناصر مختلف آلیاژ آلمینیوم با استفاده از روش آماری KSVR با بهره‌گیری از کرnel‌های مختلف.

عناصر	غلظت واقعی	خطی				چند جمله‌ای				گوسی			
		غلظت پیش‌بینی شده	مقادیر خطوط		غلظت پیش‌بینی شده	مقادیر خطوط		غلظت پیش‌بینی شده	مقادیر خطوط		MSE	MAE	
			MSE	MAE		MSE	MAE		MSE	MAE			
Mn	۰/۴۴	۰/۹۰۵	۰/۲۱۶	۰/۴۶۵	۰/۴۰۵	۰/۰۰۱	۰/۰۳۵	۰/۱۷۶	۰/۰۶۹	۰/۲۶۳			
Si	۰/۹۳	۱/۰۳۸	۰/۰۱۱	۰/۱۰۸	۱/۰۳۸	۰/۰۱۱	۰/۱۰۸	۰/۴۷۴	۰/۲۰۷	۰/۴۵۵			
Zn	۰/۳۲	۱/۰۴۲	۰/۵۲۲	۰/۷۲۲	۰/۸۰۶	۰/۲۳۶	۰/۴۸۶	۰/۲	۰/۰۱۴	۰/۱۱۹			
Fe	۰/۴۱	۰/۶۸۹	۰/۰۷۸	۰/۲۷۹	۰/۴۲۳	۰/۰۰۱	۰/۰۱۳	۰/۴۲۱	۰/۰۰۱	۰/۰۱۱			
Cu	۰/۳۶	۰/۱۸۵	۰/۰۳	۰/۱۷۴	۰/۸۴	۰/۲۳	۰/۴۸	۰/۴۰۴	۰/۰۰۲	۰/۰۴۴			
Mg	۱/۰۳	۱/۲۵۹	۰/۰۵۲	۰/۲۲۹	۱/۲۵۹	۰/۰۵۲	۰/۲۲۹	۰/۷۸۷	۰/۰۵۸	۰/۲۴۲			

مربوط به عنصر Zn با کرnel خطی است. دلیل این خطای بالا نیز، غلظت نسبتاً زیاد این عنصر است که نیاز به تصحیح خودجذبی در محاسبه شدت‌ها دارد که این امر سبب افزایش دقت تحلیل‌های آماری می‌شود [۴].

جدول ۷، نتایج مربوط به محاسبه خطاهای مربوط به کلیه روش‌های SVR، شبکه عصبی، آریما، KSVR و ترکیب این دو را نشان می‌دهد تا بهترین روش را به عنوان روش دقیق تحلیل کمی معرفی کند. همچنین، در این جدول مقادیر مربوط به غلظت‌های واقعی و پیش‌بینی شده درج شده تا دقت روش‌ها برآورد شود. با مقایسه خطاهای محاسبه شده و غلظت‌های پیش‌بینی شده، می‌توان چنین نتیجه گرفت که مدل

خطاهای مربوط به روش آماری KSVR با سه مدل کرnel خطی، چندجمله‌ای و گوسی مربوط به کلیه عناصر با ذکر غلظت پیش‌بینی شده در جدول ۶ نشان داده شده است. همانطور که در این جدول مشاهده می‌شود برای عنصر Mn بهترین دقت، متعلق به کرnel چندجمله‌ای است. به علاوه، کرnel‌های خطی و چندجمله‌ای در عناصر Si و Mg نتایج مشابهی ارائه می‌دهند. به علاوه، بهترین کرnel برای عناصر Zn و Cu گوسی است. در این جداول بهترین نتایج با رنگ قرمز نشان داده شده اند. شایان ذکر است که کمترین خطأ مربوط به عنصر آهن با کرnel گوسی است. دلیل این امر غلظت نسبتاً پایین آهن در آلیاژ مدنظر است. همچنین، بیشترین خطأ

جدول ۷. مقایسه‌ای بین مقادیر پیش‌بینی شده و خطاهای کلیه روش‌های ANN، SVR، ARIMA و KSVR-ARIMA به منظور برآورد دقیق‌ترین روش جهت تحلیل کمی در تکنیک LIBS

روش آماری	Mn				Si			
	غلاظت پیش‌بینی		غلاظت	مقادیر خطا	غلاظت پیش‌بینی		غلاظت	مقادیر خطا
	شده	واقعی	MSE	MAE	شده	واقعی	MSE	MAE
ANN	۰/۵۰۶		۰/۰۶۳	۰/۲۰۶	۱/۱۸۳		۰/۱۴۲	۰/۳۰۵
SVR	۰/۲۰۷		۰/۰۵۴	۰/۲۳۳	۰/۹۵۰		۰/۰۰۰۴	۰/۰۲۰
KSVR	۰/۴۰۵	۰/۴۴	۰/۰۰۱	۰/۰۳۵	۱/۰۳۹	۰/۹۳	۰/۰۱۱	۰/۱۰۸
ARIMA	۰/۴۱۴		۰/۰۰۰۶	۰/۰۲۶	۱/۰۰۲		۰/۰۰۵	۰/۰۷۲
KSVR-ARIMA	۰/۴۳۹		۱E-۰۶	۱E-۰۳	۱/۰۰۲		۰/۰۰۵	۰/۰۷۱
روش آماری	Fe				Cu			
	غلاظت پیش‌بینی		غلاظت	مقادیر خطا	غلاظت پیش‌بینی		غلاظت	مقادیر خطا
	شده	واقعی	MSE	MAE	شده	واقعی	MSE	MAE
ANN	۰/۴۳۴		۰/۰۱۶	۰/۰۹۳	۰/۲۲۰		۰/۰۳۳	۰/۱۴۷
SVR	۰/۵۸۱		۰/۰۲۹	۰/۱۷۰	۰/۵۰۱		۰/۰۲۰	۰/۱۴۱
KSVR	۰/۴۲۲	۰/۴۱	۰/۰۰۰۱	۰/۰۱۱	۰/۴۰۵	۰/۳۶	۰/۰۰۲	۰/۰۴۴
ARIMA	۰/۴۱۰		۷E-۰۸	۳E-۰۴	۰/۳۵۷		۹E-۰۶	۰/۰۰۳
KSVR-ARIMA	۰/۴۱۰		۷E-۰۸	۳E-۰۴	۰/۳۴۸۸۷۶		۰/۰۰۰۱۲	۰/۰۱۱۱۲
روش آماری	Zn				Mg			
	غلاظت پیش‌بینی		غلاظت	مقادیر خطا	غلاظت پیش‌بینی		غلاظت	مقادیر خطا
	شده	واقعی	MSE	MAE	شده	واقعی	MSE	MAE
ANN	۰/۰۳۲		۱/۳۷۸	۰/۲۸۸	۲/۲۰۴		۰/۰۳۳	۱/۱۷۴
SVR	۱/۸۷۳		۰/۰۵۲	۱/۵۵۳	۱/۲۵۹		۰/۰۲۰	۰/۲۲۹
KSVR	۰/۲۰۰	۰/۳۲	۰/۰۵۲	۰/۱۱۹	۱/۲۶۰	۱/۰۳	۰/۰۰۲	۰/۲۳۰
ARIMA	۰/۳۳۳		۰/۰۳۵	۰/۰۱۳	۱/۲۱۷		۹E-۰۶	۰/۱۸۷
KSVR-ARIMA	۰/۳۱۹		۹E-۰۴	۰/۰۰۱	۱/۰۶۰		۰/۰۰۰۱۲	۰/۰۳

خطای روش آریما و مدل ترکیبی یکسان شده است. به علاوه، با استی خاطرنشان کرد که دقت روش ARIMA در مقایسه با روش‌های ANN، SVR و KSVR بیشتر بوده است که بهتر است از مدل آریما جهت انجام تحلیل‌های کمی پس از تکنیک پیشنهادی KSVR-ARIMA استفاده شود.

نتایج بهتری را نسبت به سایر روش‌های KSVR-ARIMA پیشنهادی در این تحقیق پیش‌بینی کرده است؛ به جز برای عنصر Si و Cu که به ترتیب روش‌های ARIMA و SVR نتیجه بهتری را برای آنها نشان داده‌اند. به علاوه، عنصر Fe نزدیک‌ترین مقدار را نسبت به غلاظت واقعی اش در میان کلیه عنصر گزارش کرده است. همچنین، در این جدول مشاهده می‌شود که برای عنصر

جز Cu و Si دارد که برای عنصر Cu بهترین روش پیش‌بینی غلظت، مدل ARIMA و برای Si مدل SVR به دست آمده است. همچنین، برای عنصر Fe بهترین نتایج پیش‌بینی نسبت به سایر عناصر، در تمامی روش‌ها حاصل شده است.

### تشکر و قدردانی

از آقای دکتر سیدحسن توسلی بابت زحمات علمی و استفاده از داده‌های مربوط به تجهیزات آزمایشگاهی ایشان سپاس‌گزاریم.

### ۶. نتیجه‌گیری

در این تحقیق، با استفاده از روش طیف‌سنجی فروشکست القائیده لیزری، غلظت‌های عنصرهای موجود در هفت نمونه آلومینیوم مورد اندازگیری کمی قرار گرفت. برای پیش‌بینی غلظت عناصر، از SVR، ANN، ARIMA و KSVR-ARIMA انتخاب شد و نتایج به دست آمده از پنج روش با یکدیگر مقایسه شدند. نتایج کلی KSVR-ARIMA پیش‌بینی غلظت نشان می‌دهند که مدل ترکیبی KSVR-ARIMA کمترین مقدار خطأ و بهترین مقادیر پیش‌بینی را در تمام عناصر به

### مراجع

1. A.W. Mizolek, V Palleschi, and I Schechter, *Crit Rev Anal Chem.* **27** (2006) 257.
2. J Kaiser, *et al.*, *Surf. Sci. Rep.* **67** (2012) 233.
3. J Peng, *et al.*, *TrAC Trends Anal Chem.* **85** (2016) 260.
4. F Rezaei, P Karimi, and S H Tavassoli, *Appl Phys B.* **114** (2014) 591.
5. F Rezaei, P Karimi, and S H Tavassoli, *Appl Opt.* **52** (2013) 5088.
6. G Galbacs, *et al.*, *Spectrochim. Acta B* **63** (2008) 591.
7. R Harmon, R Russo, and R Hark, *Spectrochim. Acta Part B.* **87** (2013) 11.
8. M V Belkov, *et al.*, *Spectrochim. Acta B.* **64** (2009) 899.
9. V K Singh and A K Rai, *Lasers Med. Sci.* **26** (2011) 673.
10. M E Asgill and D W Hahn, *Spectrochim. Acta B* **64** (2009) 1153.
11. G E P Box, G M Jenkins and G C Reinsel, “Time Series Analysis”, 4th Edition, Wiley press (2013).
12. S L Ho, M Xie, and T N Goh, *Comput Ind Eng.* **42** (2002) 371.
13. R E Abdel-Aal and A Z Al Garni, *Energy* **22** (1997) 1059.
14. D A Dickey and W A Fuller, *J Am Stat Assoc.* **74** (1979) 427.
15. U N Chowdhury, *Int. J. Comput. Sci.* **15** (2017) 27.
16. X Ma, *et al.*, *J. Spectrosc.* **2018** (2018) 1.
17. Q Shi, *et al.*, *J. Anal. At. Spectrom.* **30** (2015) 2384.
18. A Sözen and T Menlik, S Ünvar, *Expert Syst Appl.* **35** (2008) 1533.
19. T Zheng, *et al.*, *Tour Anal.* **17** (2012) 459.
20. E D'Andrea, *et al.*, *IEEE International Instrumentation and Measurement Technology Conference (I2MTC) Proceedings IEEE* (2015) 2049.
21. R B Anderson, *et al.*, *Icarus.* **215** (2011) 608.
22. E D'Andrea, *et al.*, *Spectrochim. Acta B.* **99** (2014) 52.
23. S K Chaharsooghi and M Rezaei, *Int. J. Serv. Oper. Manag.* **25** (2016) 120.
24. M Rezaei, *et al.*, *Int. J. Environ. Sci. Technol.* **17** (2020) 3241.
25. H Shayeghi and H A Shayanfar, *Int J Electr Power Energy Syst.* **28** (2006) 503.