

Vol. 13/ No. 50/Winter 2024

Research Article

# Diagnosis of Bearing Defects based on the Analysis of Vibration Images Using the RKEM SIFT Descriptor Method

Zohreh Hashempour, PhD Student<sup>1</sup>  | Hamed Agahi, Associate Professor<sup>2\*</sup>  | Azar Mahmoodzadeh, Assistant Professor<sup>3</sup> 

<sup>1</sup>Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran  
zohrehhashempour66@yahoo.com

<sup>2</sup>Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran  
agahi@iaushiraz.ac.ir

<sup>3</sup>Department of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran  
mahmoodzadeh@iaushiraz.ac.ir

**Correspondence**

Hamed Agahi, Associate Professor of Electrical Engineering, Shiraz Branch, Islamic Azad University, Shiraz, Iran  
agahi@iaushiraz.ac.ir

**Received:** 24 December 2022

**Revised:** 19 March 2023

**Accepted:** 17 May 2023

## Abstract

Bearings are vital components of rotating machines, therefore, in this article, a new method for detecting bearing faults is proposed. Different from other classical signal processing methods, the method proposed in this paper converts one-dimensional vibration signals into two-dimensional signals (images), then image processing methods are used for analysis to achieve the purpose of classifying. Converted images from vibration signals often have certain texture features and each descriptor extracts different features, some features are weak and others are strong. In this article, the method of removing additional key points of SIFT (RKEM SIFT) is used. In addition, for each descriptor, the best features are selected using the non-linear principal component analysis method. Finally, the selected features are combined and four classification methods are applied to achieve the best classification performance and after comparison, the best classification method is selected. The performance of the proposed algorithm is evaluated on the standard bearing data set of Case Western Reserve University. The simulation results show that the proposed method performs better than other methods of fault finding of rolling bearings.

**Keywords:** Convert Signal-to-image, RKEM SIFT and Kernel-PCA method.


## Highlights

- Convert signal into image to achieve a better diagnoses of bearing fault.
- Using the RKEM-SIFT method according to extract useful features of vibration images.
- Using the Kernel-PCA in order to choose the best features.
- Using four different classification methods and then choosing the best diagnostic method among them.

**Citation:** Z. Hashempour, H. Agahi, and A. Mahmoodzadeh, "Diagnosis of Bearing Defects based on the Analysis of Vibration Images Using the RKEM SIFT Descriptor Method," *Journal of Southern Communication Engineering*, vol. 13, no. 50, pp. 67–84, 2023, doi: 10.30495/jce.2023.1975837.1185 (in Persian).

## مقاله پژوهشی

## تشخیص عیوب یاتاقان مبتنی بر تحلیل تصاویر ارتعاشی به روش توصیفگر آرکم سیفت

زهره هاشم پور<sup>۱</sup> | حامد آگاهی<sup>۲\*</sup> | آذر محمودزاده<sup>۳</sup> 

## چکیده:

یاتاقان‌ها اجزای حیاتی ماشین‌های دوار هستند از این رو در این مقاله یک روش جدید را برای تشخیص عیوب یاتاقان‌ها پیشنهاد می‌شود. متفاوت از سایر روش‌های کلاسیک پردازش سیگنال، روش پیشنهادی این مقاله، سیگنال‌های ارتعاشی یک بعدی را به سیگنال دوبعدی (تصویر) تبدیل می‌کند، سپس از روش‌های پردازش تصویر برای تجزیه و تحلیل استفاده می‌شود تا به هدف طبقه‌بندی عیوب رخ داده در یاتاقان برسد. تصاویر تبدیل شده از سیگنال‌های ارتعاشی اغلب ویژگی‌های بافت خاصی دارند و هر توصیفگر ویژگی‌های متفاوتی را استخراج می‌کند که برخی از ویژگی‌ها ضعیف و برخی دیگر قوی هستند. در این مقاله به منظور استخراج ویژگی، روش حذف نقاط کلیدی اضافی سیفت (RKEM-SIFT) استفاده شده است. علاوه بر این، برای هر توصیفگر، بهترین ویژگی‌ها با استفاده از روش تجزیه و تحلیل مؤلفه اصلی غیرخطی انتخاب می‌شوند. در نهایت، ویژگی‌های انتخاب شده باهم ترکیب می‌شوند و برای دستیابی به بهترین عملکرد در طبقه‌بندی چهار روش طبقه‌بندی اعمال شده و بعد از مقایسه بهترین روش طبقه‌بندی انتخاب می‌شود. عملکرد الگوریتم پیشنهادی بر روی مجموعه داده‌های بلبرینگ استاندارد دانشگاه کیس وسترن رزرو ارزیابی شده است. نتایج شبیه‌سازی نشان می‌دهد که روش پیشنهادی نسبت به روش‌های دیگر خطایابی یاتاقان‌های غلتشی عملکرد بهتری دارد.

**کلید واژه‌ها:** تبدیل سیگنال ارتعاشی به تصویر، روش RKEM-SIFT، تجزیه و تحلیل مؤلفه اصلی غیرخطی

<sup>۱</sup> دانشجوی دکتری مهندسی برق، گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران،  
zohrehashempour66@yahoo.com

<sup>۲</sup> دانشیار، گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران،  
agahi@iaushiraz.ac.ir

<sup>۳</sup> استادیار، گروه مهندسی برق، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران،  
mahmoodzadeh@iaushiraz.ac.ir

نویسنده مسئول

\* حامد آگاهی، دانشیار، گروه مهندسی برق، واحد شیراز،  
دانشگاه آزاد اسلامی، شیراز، ایران،  
agahi@iaushiraz.ac.ir

تاریخ دریافت: ۳ دی ۱۴۰۱

تاریخ بازنگری: ۲۸ اسفند ۱۴۰۱

تاریخ پذیرش: ۲۷ اردیبهشت ۱۴۰۲

<https://doi.org/10.30495/jce.2023.1975837.1185>

## ۱- مقدمه

یاتاقان نقش مهمی در ماشین‌های دوار دارد و همچنین یکی از منابع اصلی خرابی تجهیزات مکانیکی است. از کارافتادن یاتاقان‌های غلتشی اغلب به دلایل مختلفی مانند بارهای سنگین غیرمنتظره، عدم روغن‌کاری و آب‌بندی صحیح است [۱]. آمارها حاکی از آن است که تقریباً ۳۰ درصد از خرابی‌های ماشین‌های دوار ناشی از یاتاقان‌های آسیب‌دیده است. بنابراین، تشخیص خطای یاتاقان و کاهش ضررهای مالی و تولیدی احتمالی حیاتی است [۲]. در طول چند دهه گذشته، بسیاری از محققان کار خود را بر روی تشخیص عیوب یاتاقان متمرکز کرده‌اند. این روش‌ها را می‌توان بسته به روش تشخیص آن‌ها به سه دسته تقسیم کرد، که شامل روش مبتنی بر داده، روش مبتنی بر مدل و روش مبتنی بر سیگنال است [۳-۴]. با این وجود، پردازش سیگنال همیشه بخش مهمی در این سه دسته است. تکنیک‌های پردازش سیگنال را می‌توان به حوزه زمان، فرکانس و حوزه زمان-فرکانس طبقه‌بندی کرد [۵]. ویژگی‌های

سیگنال‌های ارتعاشی را می‌توان از حوزه زمان، حوزه فرکانس و حوزه فرکانس زمانی استخراج کرد. در حوزه فرکانس، تبدیل فوریه محبوب‌ترین ابزار است. در حالی که در حوزه زمان-فرکانس علاوه بر روش تبدیل فوریه زمان کوتاه ویژگی‌ها را می‌توان با تبدیل بسته موجک، تبدیل موجک پیچیده دو درختی استخراج کرد.

در تشخیص عیب یاتاقان، انواع مختلفی از خطاها به‌طور مکرر اتفاق می‌افتد، از جمله گسل‌های رینگ بیرونی، گسل‌های رینگ درونی و خطاهای عنصر غلتشی [۶-۸]. هدف اصلی تشخیص عیب این است که مشخص شود آیا وضعیت یاتاقان طبیعی است یا خیر. امروزه سیستم‌های نظارت بر سلامت دستگاه معمولاً برای تجزیه و تحلیل عملکرد یاتاقان‌های غلتشی در حین عملکرد سیستم‌های مکانیکی مورد استفاده قرار می‌گیرند. از این رو، برخی از حسگرها بر روی ماشین‌های دوار نصب می‌شوند [۹]. این حسگرها ارتعاشات ماشین را حس می‌کنند، آن‌ها را به سیگنال‌های الکتریکی تبدیل می‌کنند و به سیستم‌های نظارتی منتقل می‌کنند. با این وجود، نظارت مؤثر بر عملکرد ماشین پیچیدگی‌های زیادی دارد. به‌عنوان مثال، ارتعاشات مختلف در موتورهای القایی وجود دارد. این ارتعاشات معمولاً غیرمنتظره، غیرخطی و ناپایدار هستند. بنابراین، سیگنال‌های ترکیب شده با نویز و سیگنال‌های ارتعاشی غیرمنتظره مخلوط می‌شوند. با توجه به پیچیدگی این سیگنال‌ها، استفاده از الگوریتم‌های یادگیری ماشینی برای تجزیه و تحلیل سیگنال‌ها و تشخیص خرابی‌ها در اسرع وقت ضروری است [۱۰]. در [۱۱] محقق برای تبدیل سیگنال به تصویر از نمودار بازگشتی<sup>۱</sup> (RP) استفاده می‌کند. نمودار بازگشتی، به‌عنوان مثال، توسعه نمودارهای گرافیکی دوبعدی که بازخورد حالت‌ها را نشان می‌دهد، یک روش مهم برای تشخیص تغییرات دینامیکی است. این می‌تواند تناوب‌های پنهان در یک سیگنال را در دامنه بازخورد که به راحتی شناسایی نمی‌شوند، کشف کند و روش مهمی برای تجزیه و تحلیل ویژگی‌های دوره‌ای، آشفتگی و غیر ثابت سری‌های زمانی باشد. پس از تبدیل سیگنال به تصویر، ویژگی‌های مهم از تصویر استخراج می‌شود. در [۱۲] محققان بر روی خطاهای رخ داده در سیم‌پیچ‌های استاتور در موتورهای القایی تمرکز کرده‌اند که برای این منظور، یک رویکرد مبتنی بر فیلتر کالمن، برای به دست آوردن اثر جریان موتور<sup>۲</sup> (MCS) و اثر ولتاژ موتور<sup>۳</sup> (MVS) را بکار برده‌اند و انحراف استاندارد سیگنال باقیمانده (یعنی تفاوت بین سیگنال‌های اندازه‌گیری شده و تخمینی) را به‌عنوان یک شاخص تشخیص خطا در نظر گرفته‌اند. نتایج حاصل نشان می‌دهد که شاخص در نظر گرفته شده با توجه به شدت‌های مختلف خطا، عملکرد قوی برای مقاومت‌های خطای مختلف دارد. علاوه بر آن، می‌تواند با مشکلات کیفیت ولتاژ مانند کاهش ولتاژ، تورم ولتاژ<sup>۴</sup>، ولتاژ منبع تغذیه نامتعادل<sup>۵</sup> و آلودگی هارمونیک در ولتاژ تغذیه<sup>۶</sup> مقابله کند و همچنین در برابر طیف وسیعی از تغییرات بار مصونیت دارد. در نهایت، روش ذکر شده می‌تواند در سطح بالایی از شرایط نویز عمل کند. در [۱۳] به‌منظور تشخیص عیوب موتورهای القایی یک روش ساده برای شناسایی و طبقه‌بندی خطا معرفی شده است. رویکرد پیشنهادی مبتنی بر تجزیه و تحلیل سیگنال جریان گذرای راه‌اندازی از طریق همگنی سیگنال فعلی و تحلیل گشتاور مرکزی مرتبه چهارم (کشیدگی)<sup>۷</sup> است. این ویژگی‌ها برای آموزش یک شبکه عصبی مصنوعی پیش‌خور و پس‌انتشار که به‌عنوان طبقه‌بندی‌کننده در نظر گرفته می‌شوند استفاده می‌شود. از نتایج تجربی به‌دست آمده در مقاله ذکر شده، نشان داده شده است که طرح وارد شده به اطمینان بالایی در تشخیص و تمایز بین پنج شرایط موتور القایی، یعنی یک موتور در شرایط فیزیکی خوب<sup>۸</sup>، یک موتور با یک میله روتور شکسته<sup>۹</sup> دست یافته، یک موتور با دو میله روتور شکسته، یک موتور با آسیب در قسمت بیرونی یاتاقان<sup>۱۰</sup> و یک موتور با بار مکانیکی نامتعادل<sup>۱۱</sup> است.

<sup>1</sup> Recurrence plot (RP)

<sup>2</sup> motor current signatures

<sup>3</sup> motor voltage signatures

<sup>4</sup> voltage swell

<sup>5</sup> unbalanced supply voltage

<sup>6</sup> harmonic contamination in the supply voltage

<sup>7</sup> The fourth central moment (kurtosis) analysis

<sup>8</sup> physical condition

<sup>9</sup> broken rotor bars<sup>1</sup>

<sup>10</sup> The bearing outer race

<sup>11</sup> Unbalanced mechanical load

دستیابی به تشخیص عیب مؤثر در ماشین‌آلات دوار در صنایع همیشه یک موضوع مهم و چالش‌برانگیز است. در سال‌های اخیر، یادگیری عمیق روشی با دقت بالا و قابل اعتماد برای تشخیص عیب مبتنی بر داده است. با این حال، آموزش الگوریتم‌های یادگیری عمیق به تعداد زیادی داده واقعی نیاز دارد که عموماً گران و زمان‌بر است. برای مقابله با این موضوع، در [۱۴] یک طبقه‌بندی کننده با تقویت داده‌های مبتنی بر مدل پیشنهاد شده است که برای تشخیص عیب یاتاقان استفاده می‌شود. برای این منظور، ابتدا یک مدل دینامیکی برای توصیف سیستم یاتاقان با تنظیم پارامترهای مدل، مانند سرعت، بار، اندازه خطا و انواع مختلف خطا ایجاد شده است. سپس می‌توان مقادیر زیادی داده تحت شرایط عملیاتی مختلف تولید کرد. مجموعه داده آموزشی توسط داده‌های شبیه‌سازی شده ساخته شد که برای آموزش طبقه‌بندی کننده اعمال می‌شود. علاوه بر این، به منظور کاهش فاصله بین داده‌های شبیه‌سازی و داده‌های واقعی، از سیگنال‌های پوششی به جای سیگنال‌های اصلی در فرآیند آموزش استفاده شده است. ضمناً روش ذکر شده را می‌توان به سایر سیستم‌های مکترونیک با یک مدل دینامیکی قطعی گسترش داد.

در [۱۵] یک روش یادگیری عمیق مؤثر به نام رمزگذار خودکار حذف نویز انباشته<sup>۱</sup> را بررسی می‌کند، که نشان داده شده است برای شناسایی وضعیت سلامت خاص برای سیگنال‌های حاوی نویز محیط و نوسانات شرایط کاری مناسب است. در ضمن، روش تشخیص خطا مبتنی بر حذف نویز انباشته شامل سه مرحله متوالی است: حالت‌های سلامت ابتدا به گروه‌های آموزشی و آزمایشی برای مدل حذف نویز انباشته تقسیم می‌شوند، سپس یک ساختار سلسله مراتبی عمیق با یک قانون انتقالی آموزش حریصانه، لایه به لایه ایجاد می‌شود. که در آن نمایش پراکندگی و تخریب داده‌ها برای به دست آوردن ویژگی‌های مرتبه بالا با استحکام بهتر در یادگیری تکرار اعمال می‌شود. داده‌های اعتبار سنجی در نهایت برای تأیید نتایج تشخیص خطای حذف نویز انباشته، که در آن روش‌های شناسایی وضعیت سلامت موجود برای مقایسه است، استفاده می‌شود. در [۱۶] محقق جهت خطایابی از یک روش بدون نظارت جهت خطایابی استفاده کرده است. این روش تحت عنوان رمزگذار خودکار موجک عمیق<sup>۲</sup> با یادگیری ماشین افراطی<sup>۳</sup> برای تشخیص هوشمند خطای یاتاقان‌های غلتشی است. در این مقاله در مرحله اول، تابع موجک به عنوان تابع فعال‌سازی غیرخطی برای طراحی رمزگذار خودکار موجک<sup>۴</sup> استفاده می‌شود، که می‌تواند به‌طور مؤثر ویژگی‌های سیگنال را ضبط کند. ثانیاً، یک رمزگذار خودکار موجک عمیق با چندین رمزگذار خودکار موجک در نظر گرفته شده تا توانایی یادگیری ویژگی بدون نظارت را افزایش دهد. در نهایت روش‌های ماشین‌های بردار پشتیبان<sup>۵</sup>، یادگیری ماشین افراطی و سافت مکس به عنوان طبقه‌بندی کننده برای شناسایی دقیق خطاهای مختلف یاتاقان استفاده شده است.

در این مقاله ابتدا با استفاده از روش‌های حذف نویز موجود، نویز احتمالی سیگنال حذف شده سپس از آنجایی که سیگنال ارتعاشی به دست آمده از سنسورها، در ساعات متمادی و تحت شرایط مختلف دریافت شده، دارای حجم زیادی است، اگر بخواهیم کل سیگنال را مورد ارزیابی قرار دهیم بار محاسباتی بالایی را متحمل می‌شود، از این رو سیگنال به بخش‌های کوچک‌تری تقسیم شده و زیر بخش‌ها مورد ارزیابی قرار می‌گیرد. نوآوری که در این مقاله برای تشخیص خطای یاتاقان در نظر گرفته شده است این است که به منظور تشخیص محل رخ داد خطا به جای تجزیه و تحلیل بر روی سیگنال، ابتدا سیگنال ارتعاشی که یک بعدی است به یک تصویر تبدیل شده که دوبعدی بوده و از آنجایی که الگوریتم‌های وسیعی برای تجزیه و تحلیل تصویر و همچنین استخراج ویژگی تصویر وجود دارد، می‌توان استفاده کرد و تشخیص بهتری را برای سالم بودن یا معیوب بودن یاتاقان داشت. برای تبدیل سیگنال به تصویر در این مقاله ما از روش نرمالیزه کردن که در ادامه توضیح داده خواهد شد استفاده کرده‌ایم. در مورد بحث استخراج ویژگی از تصاویر، روش‌های مختلفی مانند ماتریس هم رخداد سطح خاکستری<sup>۶</sup> [۱۷]، الگوهای باینری محلی<sup>۷</sup> [۱۸]، تبدیل ویژگی ثابت مقیاس<sup>۸</sup>

<sup>1</sup> stacked denoising autoencoder

<sup>2</sup> deep wavelet auto-encoder

<sup>3</sup> extreme learning machine

<sup>4</sup> Wavelet auto-encoder

<sup>5</sup> Support vector machines (SVM)

<sup>6</sup> Gray-Level Co-Occurrence Matrix (GLCM)

<sup>7</sup> Local Binary Pattern (LBP)


<sup>8</sup> The scale-invariant feature transform (SIFT)

[۱۹] و غیره وجود دارد. از آنجایی که هر الگوریتم ویژگی‌های متفاوتی را استخراج می‌کند برخی از ویژگی‌ها ممکن است در یک الگوریتم انتخاب شده و در الگوریتم‌های دیگر نادیده گرفته شوند. روش سیفت یکی از روش‌های کاربردی و مفید برای استخراج ویژگی است، ولی از آنجایی که این روش بار محاسباتی بالایی دارد ما از روش حذف نقاط کلیدی اضافی سیفت [۲۰] به منظور استخراج ویژگی تصاویر استفاده کرده‌ایم که این روش تا حدی قابل قبولی بر کاستی‌های روش سیفت ابتدایی نائل آمده است. پس از استخراج ویژگی از تصاویر مرحله کاهش بعد را داریم، از آنجایی که ویژگی‌های زیادی ممکن است از الگوریتم‌های استخراج ویژگی حاصل شود که گاهی همه ویژگی‌ها مفید نبوده این مرحله می‌تواند با حذف ویژگی‌های غیرضروری بار محاسباتی را کمتر کند و همچنین در نتیجه حاصله نیز تأثیر به‌سزایی داشته باشد. در مرحله آخر طبقه‌بندی را خواهیم داشت. هدف نهایی از روش پیشنهادی این است که تشخیص دهیم سیگنالی که در ورودی داشته‌ایم مربوط به یک سیگنال ارتعاشی سالم بوده یا معیوب و در صورت تشخیص معیوب بودن سیگنال این عیب مربوط به کدام قسمت از یاتاقان بوده است. توضیح کامل گام‌های گفته شده در زیر بخش‌های بعدی کامل‌تر توضیح داده خواهد شد.

الگوریتم پیشنهادی به شرح زیر سازمان‌دهی شده است:

- استفاده از الگوریتم‌های پردازش تصویر برای تشخیص زودهنگام عیوب در یاتاقان‌های غلتشی.
- تبدیل سیگنال ارتعاشی به تصویر دوبعدی برای ایجاد یک روش جدید برای تشخیص زودهنگام خطا.
- استفاده از الگوریتم‌های استخراج ویژگی جهت استخراج ویژگی‌های کلیدی تصویر ارتعاشی.
- انتخاب بهترین ویژگی‌ها برای بهبود عملکرد طبقه‌بندی کننده.
- طبقه‌بندی ویژگی‌های نهایی به منظور تشخیص نوع و محل وقوع خطا در یاتاقان.

بقیه مقاله به شرح زیر است. در بخش ۲ مراحل روش پیشنهادی (روش تبدیل سیگنال به نویز، استخراج ویژگی و کاهش بعد و مرحله طبقه‌بندی) توضیح داده شده است. در بخش ۳ ارزیابی عملکرد پیشنهادی توضیح داده شده است. آزمایش‌ها و نتایج در بخش ۴ ارائه شده است و در نهایت نتیجه‌گیری تحقیق را در بخش ۵ خواهیم داشت. ضمناً فلوجارت روش پیشنهادی در شکل ۱ قابل مشاهده است.




شکل ۱: فلوجارت روش پیشنهادی

Figure 1. Flowchart of the proposed method

## ۲- روش‌شناسی

در این بخش الگوریتم پیشنهادی برای تشخیص عیب در یاتاقان معرفی شده است. ابتدا از فیلتر میانگین برای پیش‌پردازش تصویر استفاده شده است. یکی از رویکردهای جدید برای تشخیص خطای سیگنال‌های ارتعاشی، تبدیل سیگنال‌های یک بعدی به سیگنال‌های دوبعدی است.

در این مقاله برای این منظور دامنه هر نمونه سیگنال ارتعاش را در محدوده  $[-۱، ۱]$  نرمالیزه کرده و سپس، همان‌طور که در شکل ۱ نشان داده شده، دامنه نرمالیزه شده هر نمونه به شدت پیکسل مربوطه در تصویر مرتبط می‌شود [۲۱].



شکل ۲: ساخت تصویر ارتعاشی [۱۵]

Figure 2. Creating a vibrating image [15]

بعد از اینکه سیگنال ارتعاشی از حالت یک بعدی به دوبعدی، یعنی تصویر تبدیل شد، ویژگی‌ها با استفاده از توصیفگر حذف نقاط کلیدی اضافی سیفت<sup>۱</sup> استخراج می‌شوند و بهترین ویژگی‌ها برای هر توصیفگر با استفاده از تحلیل مؤلفه اصلی کرنل<sup>۲</sup> به‌طور جداگانه انتخاب می‌شوند. در پایان از چند الگوریتم طبقه‌بندی کننده برای طبقه‌بندی سیگنال‌ها و تشخیص خطاها استفاده می‌شود. جزئیات الگوریتم پیشنهادی در زیر بخش‌های بعدی توضیح داده شده است.

## ۲-۱-۲- پیش‌پردازش

قبل از استفاده از هر توصیفگر ویژگی، باید کنتراست تصویر را بهبود دهیم. در واقع، عملکرد الگوریتم‌های استخراج ویژگی بدون بهبود کیفیت تصویر کاهش می‌یابد. برای تصاویر با کیفیت پایین، برخی از الگوریتم‌ها ممکن است ویژگی‌های کافی را استخراج نکنند. در این تحقیق کیفیت تصویر را با استفاده از روش تنظیم شدت تصویر بهبود می‌دهیم. این روش مقادیر شدت تصویر ورودی را به مقادیر جدید نگاشت می‌کند. در ادامه از روش حذف نقاط کلیدی اضافی سیفت برای مرحله استخراج ویژگی استفاده شده است.

## ۲-۲- استخراج ویژگی

### ۲-۲-۱- الگوریتم سیفت

تبدیل ویژگی تغییرناپذیر مقیاس (سیفت) [۱۹] یکی از کاربردی‌ترین الگوریتم‌ها در استخراج نقطه کلیدی است. الگوریتم سیفت در حالت کلی دارای سه مرحله شناسایی ویژگی، ایجاد توصیفگرها و تطبیق است.

### ۲-۲-۱-۱- شناسایی ویژگی‌ها

مرحله شناسایی (استخراج) ویژگی خود شامل سه گام الف) استخراج اکستریم‌های فضای مقیاس، ب) بهبود دقت موقعیت و حذف اکستریم‌های ناپایدار و ج) تخصیص جهت به هر ویژگی می‌باشد.

### الف) استخراج اکستریم‌های فضای مقیاس

اولین قدم در مرحله استخراج ویژگی الگوریتم سیفت شناسایی موقعیت‌هایی از تصویر است که مستقل از تغییر مقیاس هستند. برای این منظور ویژگی‌های پایدار تصویر در مقیاس مختلف آن با استفاده از فضای مقیاس<sup>۳</sup> استخراج می‌شوند. فضای مقیاس نمایش ساختارهای تصویر در مقیاس‌های مختلف بوده و متشکل از مجموعه‌ای از تصاویر گوسی و تفاضل گوسی<sup>۴</sup> در ابعاد مختلف است که در لایه‌های مختلفی تحت عنوان اکتاو مرتب شده‌اند. شکل ۲ فضای مقیاس ایجاد شده را نشان می‌دهد. در ابتدا به‌منظور افزایش تعداد ویژگی‌های پایدار تصویر، ابعاد تصویر با استفاده از درون‌یابی خطی دو برابر شده و به‌عنوان تصویر سطح اکتاو اول در نظر گرفته می‌شود. سپس تصویر سطح اول در یک روند تکراری با کرنل گوسی پیچش داده می‌شود تا تصاویر گوسی فضای مقیاس در هر اکتاو ایجاد شود. برای تصویر ورودی، تصاویر گوسی فضای مقیاس با استفاده از تابع کرنل گوسی (رابطه ۱) به‌صورت رابطه ۲ محاسبه می‌شود،

$$G(x, y, \sigma) = 1 / (2\pi\sigma^2) e^{-(x^2+y^2)/2\sigma^2} \quad (1)$$

<sup>1</sup> Redundant Keypoint Elimination Method (RKEM-SIFT)

<sup>2</sup> Kernel Principal component analysis (Kernel PCA)

<sup>3</sup> Scale Space

<sup>4</sup> Difference Of Gaussian (DOG)


$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \tag{2}$$

که در این رابطه  $\sigma$  بیانگر مقیاس هر تصویر بوده و مقدار اولیه آن برابر  $\sigma_0 = 1/6$  است و با استفاده از یک پارامتر ثابت  $k$  در یک روند افزایش در سطوح مختلف هر اکتاو افزایش می‌یابد. تصاویر تفاضل گوسی با استفاده از تفاضل دو تصویر گوسی مجاور با توجه به رابطه ۳ محاسبه می‌شود،

$$D(x, y, \sigma) = L(x, y, k\sigma) - L(x, y, \sigma) \tag{3}$$


همان‌طور که در شکل ۲ ملاحظه می‌شود مقیاس تصویر کوچک‌تر به‌عنوان تصویر گوسین حاصل در نظر گرفته می‌شود. بعد از ایجاد هر اکتاو، تصویر گوسی که مقیاس آن دو برابر مقیاس تصویر اصلی است، انتخاب شده و ابعاد آن با نمونه‌برداری مجدد نصف شده و به‌عنوان تصویر ابتدایی اکتاو بعدی در نظر گرفته می‌شود و این فرایند تکرار می‌شود.

هدف از ایجاد فضای مقیاس، استخراج ویژگی‌هایی هست که مستقل از مقیاس هستند. بنابراین جهت استخراج موقعیت‌های پایدار میان‌تصاویر گوسین، در هر اکتاو هر پیکسل با هشت پیکسل همسایه خود و نه پیکسل در همسایگی تصویر گوسین بالایی و پایینی مقایسه می‌شود و در صورتی که اکستریم باشد، به‌عنوان یک ویژگی کاندید<sup>۱</sup> ذخیره می‌شود. قابل توجه است که تصاویر سطح اول و آخر در هر اکتاو بررسی نمی‌شود. در نهایت برای هر ویژگی استخراج شده بر اساس مقیاس تصویر گوسین که از آن استخراج شده است، پارامتر مقیاس انتخاب می‌شود. در مرحله بعد، باید اکستریم‌های ناپایدار را حذف کرد.



شکل ۳: فضای مقیاس در الگوریتم سیفت [۱۹]

Figure 3. Scale space in Sift algorithm [19]



شکل ۴: استخراج اکستریم تصاویر تفاضل گوسی در الگوریتم سیفت [۱۹]

Figure 4. Extreme extraction of DOG images in Sift algorithm [19]

<sup>1</sup> Candidate

**ب) بهبود دقت موقعیت و حذف اکسترم‌های ناپایدار**

در این مرحله ویژگی‌هایی که کنتراست پایینی داشته و بر روی لبه قرار دارند حذف می‌شوند. الگوریتم با انجام درون‌یابی از داده مجاور هر نقطه کلیدی، محل دقیق آن‌ها را تعیین می‌کند. درون‌یابی با استفاده از بسط سری تیلور درجه دوم از تابع تفاضلی گوسی فضای مقیاس  $D(x,y,\sigma)$  با نقطه کلیدی کاندیدا انجام می‌شود. بسط تیلور مطابق رابطه ۴ محاسبه می‌شود،

$$D(X) = D + \frac{\partial D^T}{\partial X} X + \frac{1}{2} X^T \frac{\partial^2 D}{\partial X^2} X \quad (4)$$

که  $D$  و مشتقات آن در نقطه کلیدی ارزیابی می‌شود و  $X(x,y,\sigma)$  مقدار ثابت این نقطه است. به‌منظور تعیین موقعیت اکسترم  $\bar{X}$  از رابطه بالا نسبت به  $X$  مشتق گرفته و برابر صفر قرار داده می‌شود و مقدار  $\bar{X}$  مطابق رابطه ۵ به دست می‌آید،

$$X = -\frac{\partial^2 D^{-1}}{\partial X^2} \times \frac{\partial D}{\partial D} \quad (5)$$

سپس به بررسی مقدار ثابت  $\bar{X}$  پرداخته می‌شود که اگر بزرگ‌تر از  $0.5$  باشد، موقعیت نقطه کلیدی کاندیدا تغییر می‌کند و درون‌یابی برای این نقطه انجام می‌شود و در غیر این صورت مقدار ثابت به نقطه کلیدی کاندیدا اضافه شده و اندازه‌ی تابع نیز در این موقعیت اکسترم با استفاده از رابطه ۶ بیان می‌شود،

$$D(X) = D + \frac{1}{2} \times \frac{\partial D^T}{\partial X} X \quad (6)$$

بدین ترتیب موقعیت مکانی ویژگی در حد زیر پیکسل محاسبه می‌شود و میزان مقیاس دقیق آن نیز برآورده می‌شود. اندازه قدر مطلق تابع در موقعیت اکسترم،  $|D(\bar{X})|$  به‌عنوان میزان کنتراست هر ویژگی در نظر گرفته شده و برای حذف ویژگی‌های ناپایدار مورداستفاده قرار می‌گیرد. مطابق با پیشنهاد لاوو ویژگی‌های که میزان کنتراست آن‌ها از یک مقدار آستانه ( $T_c=0.3$ ) کمتر باشد، ناپایدار و حساس به نویز بوده و حذف می‌شوند. در این مرحله، بعد از حذف ویژگی‌هایی که کنتراست پایینی دارند لازم است ویژگی‌هایی که بر روی لبه‌ها قرار دارند، حذف شوند، چون حساس به نویز و تغییرات کوچک در همسایگی خود بوده است. برای این منظور از نسبت میان مقادیر ویژه هسیان برای تشخیص و حذف نقاط واقع بر روی لبه‌ها استفاده می‌شود. ماتریس هسیان، ماتریس مشتق‌های جزئی مرتبه دوم نسبت به  $x$  و  $y$  بوده و مطابق رابطه ۷ قابل برآورد است،

$$H = \begin{bmatrix} D_{xx} & D_{xy} \\ D_{yx} & D_{yy} \end{bmatrix} \quad (7)$$

که در این رابطه  $D_{xx}$  مشتق دوم نقاط کاندیدا نسبت به  $x$  روی گوسین  $D_{xy}$  مشتق دوم نقاط کاندیدا نسبت به  $x$  و  $y$  روی تصویر گوسین بوده و  $D_{yy}$  مشتق دوم نقاط کاندیدا نسبت به  $y$  روی تصویر گوسین است. فرض شده است که  $\alpha$  مقدار ویژه بزرگ و  $\beta$  مقدار ویژه کوچک ماتریس هسیان است. بنابراین نسبت این مقادیر ویژه مطابق رابطه ۸ به دست می‌آید،

$$r = \frac{\alpha}{\beta} \quad (8)$$

مطابق پیشنهاد لاوو باید نقاطی که میزان  $r$  برای آن‌ها بیشتر از  $10$  است حذف شوند. بعد از حذف ویژگی‌های ناپایدار، باید به هر یک از ویژگی‌های پایدار باقی‌مانده یک جهت تخصیص داده شود که در ادامه توضیح داده خواهد شد.

**ج) تخصیص جهت**

در مرحله تخصیص جهت به هر ویژگی، به‌منظور انجام عمل تطبیق، برای هر یک از ویژگی‌هایی که از مرحله قبل استخراج شده‌اند یک پارامتر جهت تعیین می‌شود. ابتدا یک پنجره دایره‌ای شکل در اطراف هر ویژگی در تصویر گوسی مربوط به آن انتخاب می‌شود. مقدار شعاع دایره، سه برابر مقیاس هر ویژگی در نظر گرفته می‌شود. سپس مقادیر اندازه و جهت گرادیان برای پیکسل‌های درون ناحیه محاسبه شده و مقادیر اندازه آن‌ها با استفاده از یک تابع گوسی با انحراف معیار یک و نیم برابر مقیاس آن وزن‌دهی می‌شوند.



اندازه گرادیان و جهت گرادیان برای هر پیکسل با استفاده از فاصله و زاویه پیکسل‌های همسایگی آن به ترتیب مطابق روابط ۹ و ۱۰ محاسبه می‌شود،

$$m = \sqrt{(L(x+1, y) - L(x-1, y))^2 + (L(x, y+1) - L(x, y-1))^2} \quad (9)$$

$$\theta(x, y) = \tan^{-1} \left( \frac{L(x, y+1) - L(x, y-1)}{L(x+1, y) - L(x-1, y)} \right) \quad (10)$$

سپس، یک نمودار به‌عنوان هیستوگرام جهت ایجاد می‌شود و جهت مربوط به بیشینه ستون هیستوگرام و جهت‌هایی که ۸۰ درصد جهت بیشینه هستند، به‌عنوان جهت مربوط به این ویژگی استخراج شده و با یک بردار با چهار مؤلفه نشان داده می‌شود.

### ۲-۱-۲-۲- ایجاد توصیفگرها

بعد از استخراج نقاط کلیدی، الگوریتم سیفت توصیفگر ویژگی‌ها را به‌عنوان ابزاری برای تطبیق میان تصاویر تولید می‌کند. با ایجاد توصیفگرها مطابق با مقیاس و جهت هر ویژگی، این توصیفگرها نسبت به تغییر مقیاس و چرخش مقاوم می‌شوند. همچنین، این توصیفگر در مقابل سایر تغییرات نظیر تغییرات روشنایی و تغییرات ناشی از زاویه دید<sup>۱</sup> تصویربرداری تا حد ممکن مقاوم است. برای ایجاد توصیفگر در الگوریتم استاندارد سیفت، در ابتدا یک ناحیه به‌صورت یک شبکه‌ی ۴×۴ در اطراف هر ویژگی در تصویر گوسی مربوط به آن، در نظر گرفته می‌شود. ابعاد این ناحیه، مطابق با مقیاس هر ویژگی و به‌گونه‌ای انتخاب می‌شود که هر سلول به‌صورت مربعی با ضلع معادل با سه برابر مقیاس ویژگی باشد. سپس مختصات شبکه معادل با جهت اصلی ویژگی موردنظر چرخانده می‌شود. آنگاه، مقادیر اندازه و جهت گرادیان پیکسل‌های درون ناحیه‌ای چرخیده، محاسبه و جهت گرادیان‌ها نیز معادل با جهت اصلی ویژگی موردنظر چرخش داده می‌شود. در ادامه، یک تابع گوسی با مقیاس معادل نصف پهناى شبکه، به‌منظور وزن دهی مقادیر گرادیان‌ها استفاده می‌شود. سپس برای سلول در شبکه، یک هیستوگرام از جهت گرادیان‌های وزن دهی شده پیکسل‌های درون آن مشابه با هیستوگرام جهت ایجادشده در مرحله تخصیص جهت، ایجاد می‌شود. به‌منظور اجتناب از اثرات مرزهای میان سلول‌ها و همچنین مرز میان محدوده‌های زوایا در هیستوگرام، یک درون‌یابی سه خطی<sup>۲</sup> برای توزیع مقدار گرادیان در ایجاد این هیستوگرام انجام می‌گیرد. در نهایت توصیفگر سیفت به‌صورت یک بردار با ۱۲۸ مؤلفه ایجاد می‌شود. به‌منظور کاهش اثرات تغییرات روشنایی، اندازه‌ی این توصیفگر نرمالیزه می‌شود. در ادامه، با هدف کاهش اثرات ناشی از تغییر زاویه تصویربرداری که به‌صورت مقادیری با گرادیان بالا ظاهر می‌شود، یک آستانه ۰/۲ برای مقادیر توصیفگر در نظر گرفته‌شده و فرآیند نرمالیزه کردن توصیفگر مجدداً تکرار می‌شود.

### ۲-۱-۲-۳- تطبیق

پس از ایجاد یک توصیفگر برای هر ویژگی، می‌بایست این توصیفگرها در دو تصویر باهم تطبیق داده شوند. معمولاً از فاصله اقلیدسی برای این هدف استفاده می‌شود. آنگاه از یک معیار مناسب برای تطبیق صحیح استفاده می‌شود. به‌طور کلی سه معیار برای تطبیق توصیفگرها در دو تصویر وجود دارد: (۱) تطبیق مبتنی بر آستانه، (۲) تطبیق مبتنی بر نزدیک‌ترین همسایه، (۳) تطبیق مبتنی بر نسبت اولین و دومین نزدیک‌ترین همسایه که در ادامه، هر یک از این معیارها به‌طور مختصر بررسی می‌شوند.

#### • تطبیق مبتنی بر آستانه

اگر فاصله بین توصیفگرهای دو نقطه کلیدی کمتر از مقدار آستانه موردنظر باشد، دو نقطه کلیدی تطبیق می‌یابند. مهم‌ترین نقص این روش این است که یک توصیفگر ممکن است دارای چندین تطبیق باشد.

#### • تطبیق مبتنی بر نزدیک‌ترین همسایه

<sup>1</sup> Viewpoint

<sup>2</sup> Tri-Linear Interpolation

دو ناحیه برای مثال A و B تطبیق می‌یابند اگر توصیفگر  $D_B$  نزدیک‌ترین همسایه به توصیفگر  $D_A$  باشد و فاصله بین این دو توصیفگر کمتر از آستانه موردنظر باشد. با این روش یک توصیفگر تنها یک تطبیق دارد.

• تطبیق مبتنی بر نسبت اولین و دومین نزدیک‌ترین همسایه

این روش تقریباً مشابه تطبیق مبتنی بر نزدیک‌ترین همسایه است در این روش دو نقطه کلیدی A و B تطبیق می‌یابند به شرطی که رابطه ۱۱ برقرار باشد:

$$\frac{\|D_A - D_B\|}{\|D_A - D_C\|} < t \quad (11)$$

در این رابطه،  $D_B$  توصیفگر اولین نزدیک‌ترین همسایه به توصیفگر  $D_A$  است و  $D_C$  توصیفگر دومین نزدیک‌ترین همسایه به توصیفگر  $D_A$  است. اگر فاصله بین اولین نزدیک‌ترین همسایه تا توصیفگر نسبت به فاصله دومین نزدیک‌ترین همسایه تا توصیفگر از حد آستانه کوچک‌تر باشد، عمل تطبیق انجام می‌شود. در الگوریتم سیفت معمولاً از روش تطبیق مبتنی بر نسبت اولین و دومین نزدیک‌ترین همسایه استفاده می‌شود.

## ۲-۲-۲- الگوریتم حذف نقاط کلیدی اضافی سیفت

یکی از کاستی‌های سیفت و اصلاحات آن این است که نقاط کلیدی اضافی را به همراه موارد مهم استخراج می‌کنند. اگر نقطه کلیدی به نقطه کلیدی دیگر بسیار نزدیک باشد و مجموع فواصل آن تا سایر نقاط کلیدی کوچک‌تر باشد، اضافی نامیده می‌شود. حذف یک نقطه کلیدی اضافی، سرعت الگوریتم‌ها را علاوه بر دقت تطبیق تصویر افزایش می‌دهد. برای حذف نقاط کلیدی اضافی از الگوریتم سیفت، می‌توان از روش حذف نقاط کلیدی اضافی در استفاده نمود. برای انجام این کار، فاصله بین نقاط کلیدی محاسبه می‌شود. سپس اگر فاصله کمتر از یک آستانه از پیش تعریف شده باشد، نقطه اضافی بر اساس شاخص افزونگی کنار گذاشته می‌شود. جزئیات روش به شرح زیر است:

مرحله اول: نقاط کلیدی با استفاده از الگوریتم سیفت در تصویر مرجع شناسایی و استخراج می‌شوند که تعداد نقاط کلیدی استخراج شده بر اساس پیچیدگی مکان‌های تصویر است. در ساختارهای پیچیده، تعداد بیشتری از نقاط کلیدی وجود دارد.

مرحله دوم: فاصله منتهن و اقلیدسی بین هر نقطه کلیدی و سایر نقاط کلیدی در تصویر مرجع به ترتیب مطابق رابطه ۱۲ و ۱۳ محاسبه می‌شود.

$$d_1(P_m, P_n) = \sum_{i=1}^L |P_m(i) - P_n(i)| \quad (12)$$

$$d_2(P_m, P_n) = \sqrt{\sum_{i=1}^L (|P_m(i) - P_n(i)|)^2} \quad (13)$$

در این معادلات،  $P_m(i)$  و  $P_n(i)$  به ترتیب به ترتیب  $i$  امین مختصات نقاط کلیدی  $P_m$  و  $P_n$  هستند و  $L$  بعد نقاط کلیدی در تصویر است. علاوه بر این، مجموع فواصل بین هر نقطه کلیدی و سایر نقاط کلیدی در تصویر مطابق با رابطه ۱۴ ذخیره می‌شود.

$$SD(P_m) = \sum_{j=1}^N d(P_m, P_j) \quad (14)$$

در این معادله،  $N$  تعداد نقاط کلیدی در تصویر و  $d(P_m, P_n)$  فاصله بین دو نقطه بر اساس روابط ۱۱ یا ۱۲ است. رابطه  $RI$  نقطه کلیدی  $P_m$  بر اساس رابطه ۱۴ تعریف شده است. بنابراین در مکانی با ساختار پیچیده، فاصله کمتر بین نقاط کلیدی، احتمال افزونگی بیشتری را به همراه دارد و عملاً ساختار پیچیده تصویر نیز در نظر گرفته می‌شود طبق رابطه ۱۵،

$$RI(P_m) = \frac{1}{SD(P_m)} \quad (15)$$

مرحله سوم: یک مقدار آستانه باید برای حذف نقاط کلیدی اضافی انتخاب شود. افزایش مقدار آستانه منجر به افزایش سرعت الگوریتم می‌شود، اما اگر مقدار آستانه بیش از اندازه بالا شود، می‌تواند بر دقت تطبیق تأثیر منفی بگذارد و آن را کاهش دهد. مرحله چهارم: اگر فاصله بین نقاط کلیدی (به جز فاصله هر نقطه از خودش) کمتر از مقدار آستانه باشد، باید نقاط کلیدی اضافی حذف شوند. در بین این نقاط، نقطه کلیدی که RI آن بالاتر یا مقدار فاصله آن کوچک‌تر است حذف می‌شود. مجموع مقدار فاصله کوچک‌تر متعلق به نقطه کلیدی اضافی‌تر است زیرا نزدیک به نقاط کلیدی بیشتری است و حذف آن کیفیت روش را بهبود می‌بخشد. مرحله پنجم: تمامی مراحل فوق به صورت مستقل بر روی تصاویر دریافتی انجام می‌شود.

## ۲-۳- کاهش ابعاد فضای ویژگی

روش تحلیل مؤلفه اصلی دارای اهداف بسیاری از جمله یافتن روابط بین مشاهدات، استخراج مهم‌ترین اطلاعات از داده‌ها، تشخیص و حذف موارد پرت و کاهش ابعاد داده‌ها تنها با حفظ اطلاعات مهم است. همه این اهداف با یافتن فضای مؤلفه اصلی که جهت حداکثر واریانس داده‌های داده شده را نشان می‌دهد، به دست می‌آیند. فضای مؤلفه اصلی از اجزای اصلی متعامد، یعنی محورها یا بردارها تشکیل شده است. اجزای اصلی با حل ماتریس کواریانس یا با استفاده از تجزیه ارزش منفرد<sup>۱</sup> محاسبه می‌شوند [۲۲]. برای ورودی در روش تحلیل مؤلفه اصلی روابط ۱۶ و ۱۷ را داریم،

$$\text{cov}(x) = \frac{1}{N} \sum_{i=1}^N x_i \quad (16)$$

$$\text{cov}(x) = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x}_i)(x_i - \bar{x}_i)^T \quad (17)$$

که در این رابطه  $x$  بار میانگین و  $\text{cov}(x)$  ماتریس کواریانس است. در ادامه بردار ویژه و مقادیر ویژه ماتریس کواریانس  $\lambda_1, \lambda_2, \dots, \lambda_D$  محاسبه می‌شود. باید توجه داشت که مقادیر ویژه مرتب شده‌اند، به طوری که  $\lambda_1 \geq \lambda_2 \geq \dots \geq 0$  برای هر  $x$  نمایش جدید آن به صورت رابطه ۱۸ است:

$$y = (\xi_1^T (x - \bar{x}), \xi_2^T (x - \bar{x}), \dots, \xi_d^T (x - \bar{x}))^T \quad (18)$$

و  $x$  را می‌توان به عنوان ابعاد کمتر  $d$  به صورت رابطه ۱۹ نگاشت کرد.

$$x \approx \bar{x} + (\xi_1^T (x - \bar{x}))\xi_1 + (\xi_2^T (x - \bar{x}))\xi_2 + \dots + (\xi_d^T (x - \bar{x}))\xi_d \quad (19)$$

روش تحلیل مؤلفه اصلی در حالتی که بتوان داده‌ها را به صورت خطی تفکیک کرد مفید خواهد بود. اما ممکن است با حالت‌هایی مواجه شویم که تفکیک داده‌ها به صورت خطی امکان‌پذیر نباشند، در این حالت به سراغ تحلیل مؤلفه اصلی غیر خطی (کرنل) می‌رویم. تابع مربوط به تحلیل مؤلفه اصلی در حالت غیر خطی به صورت رابطه ۲۰ تعریف می‌شود،

$$K(X) = \phi(X) \times \phi^T(X) \quad (20)$$

که این تابع دقیقاً همان کاری را انجام می‌دهد که ماتریس کواریانس در حالت خطی انجام می‌دهد و این بدان معنی است که می‌توان مقادیر ویژه و بردارهای ویژه ماتریس را محاسبه کرد. این مقادیر، اجزای اصلی جدید فضای  $m$  بعدی هستند که در آن متغیرهای اصلی خود را به آن نگاشت کرده‌ایم.

## ۲-۴- طبقه‌بندی

با توجه به طبقه‌بندی ویژگی‌های استخراج شده از تصویر ارتعاش، ۱۰ کلاس در نظر گرفته می‌شود که شامل یک کلاس برای یاتاقان در حالت نرمال و نه نوع کلاس برای خطاهای مختلف یاتاقان است. این خطاها شامل سه خطای مختلف برای هر یک از رینگ‌های داخلی، بیرونی و ساچمه است. در پایگاه داده، این سه خطا بر اساس قطر گسل و مقادیر ۷ میلی اینچ، ۱۴ میلی اینچ و ۲۱ میلی

<sup>۱</sup> SVD

اینچ در نظر گرفته شده است که به صورت دستی در یاتاقان ایجاد شده و سیگنال ارتعاشی ناشی از هر یک از این ده کلاس ثبت و ذخیره شده است. برای مرحله طبقه بندی الگوریتم های زیادی وجود دارد. برای ارزیابی بهتر در این مقاله از چهار روش مختلف استفاده شده است که شامل روش میانگین حداقل مربعات خطی<sup>۱</sup> [۲۳] روش تخمین رگرسیون خطی مبتنی بر چگالی هسته<sup>۲</sup> [۲۴]، روش طبقه بندی خطی لجستیک<sup>۳</sup> [۲۵] و روش درخت تصمیم گیری<sup>۴</sup> [۲۶] است.

روش میانگین حداقل مربعات خطی روشی در تحلیل رگرسیون است که برای حل دستگاه معادلاتی به کار می رود که تعداد معادله هایش بیش از تعداد مجهول هایش است و در واقع برای درون یابی چند جمله ای های مرتبه بالاتر استفاده می شود.

برای مدل های رگرسیون خطی با خطاهای غیرعادی توزیع شده، برآورد حداقل مربعات<sup>۵</sup> در مقایسه با برآورد حداکثر درست نمایی<sup>۶</sup> کارایی خود را از دست می دهد بنابراین یک ایده این است که تابع درست نمایی با استفاده از تخمین چگالی هسته ناپارامتری چگالی خطا بر اساس برخی تخمین پارامترهای اولیه تقریب زده شود. این تقریب خوبی خواهد بود چرا که به ازای خطاهای غیرعادی و همچنین حجم نمونه کم نیز کارآمد خواهد بود.

از طرفی زمانی که هدف سنجش رابطه بین یک متغیر مستقل (با مقدارهای پیوسته) با یک متغیر وابسته با مقدارهای کیفی باشد رگرسیون خطی جوابگو نخواهد بود و به جای آن از رگرسیون لجستیک استفاده می شود. رگرسیون طبقه بندی خطی لجستیک یک تکنیک طبقه بندی معروف است که معمولاً در آمار، یادگیری ماشین و حوزه دانش داده کاوی برای یادگیری پاسخی با ماهیت باینری استفاده می شود.

درخت تصمیم، روشی در یادگیری ماشین برای ساختار بندی (یا شکل دهی یا سازمان دهی) به الگوریتم است. یک الگوریتم درخت تصمیم برای تقسیم ویژگی های مجموعه داده از طریق تابع هزینه مورد استفاده قرار می گیرد.

### ۳- ارزیابی عملکرد الگوریتم

برای ارزیابی عملکرد الگوریتم پیشنهادی، سه معیار در این مقاله بررسی شده است. اولین معیار، معیار دقت<sup>۷</sup> است که نزدیک بودن اندازه گیری ها به یک مقدار خاص را نشان می دهد. دقت پایین باعث تفاوت بین یک نتیجه و یک مقدار واقعی می شود. مورد دوم معیار تشخیص پذیری<sup>۸</sup> است که نشان دهنده نسبت منفی هایی است که به درستی شناسایی شده اند. آخرین معیار، معیار حساسیت<sup>۹</sup> که کسری از مقدار کل نمونه های مربوطه است که واقعاً بازیابی شده اند. دقت (P) به عنوان تعداد مثبت های واقعی تقسیم بر تعداد کل مثبت های واقعی و مثبت های کاذب در نظر گرفته شده است. این معیارها به صورت روابط ۲۱ تا ۲۴ محاسبه می شوند [۲۷].

$$A = \frac{TP + TN}{TP + FN + TN + FP} \quad (21)$$

$$SP = \frac{TN}{TN + FP} \quad (22)$$

$$S = R = \frac{TP}{TP + FN} \quad (23)$$

$$P = \frac{TP}{TP + FP} \quad (24)$$

<sup>1</sup> Minimum least square linear classifier

<sup>2</sup> Kernel Density-Based Linear Regression Estimate

<sup>3</sup> Logistic linear classifier

<sup>4</sup> Decision Tree Algorithm

<sup>5</sup> LSE

<sup>6</sup> MLE

<sup>7</sup> Accuracy(A)

<sup>8</sup> Specificity (Sp)

<sup>9</sup> Sensitivity(S)

که در این رابطه TP مثبت صحیح<sup>۱</sup> است به این معنا که نمونه‌ای صحیح است و درست هم تشخیص داده شده است، TN منفی صحیح<sup>۲</sup> است یعنی نمونه‌ای اشتباه بوده و درست هم تشخیص داده شده است، FP مثبت کاذب<sup>۳</sup> یعنی نمونه‌ای صحیح نیست و به اشتباه درست تشخیص داده شده است و FN منفی کاذب<sup>۴</sup> یعنی نمونه‌ای صحیح بوده و به اشتباه منفی تشخیص داده شود.

#### ۴- آزمایشات و نتایج

در این بخش به بررسی عملکرد الگوریتم پیشنهادی در پایگاه داده استاندارد می‌پردازیم. یکی از پرکاربردترین پایگاه‌های داده برای بررسی و ارزیابی روش‌های تشخیص و شناسایی خطا، پایگاه یاتاقان نورد دانشگاه کیس وسترن رزرو<sup>۵</sup> است که در [۲۸] موجود است. سنسورهای ارتعاشی بر بدنه موتور نصب شده است.

در این پایگاه داده چهار نوع سیگنال ارتعاشی وجود دارد که شامل سیگنال نرمال و خطاهای رینگ داخلی، رینگ بیرونی و ساچمه در سه قطر گسل مختلف است. بنابراین، ده نوع سیگنال و در نتیجه ده کلاس برای طبقه‌بندی وجود دارد. علاوه بر این، داده‌ها برای چهار سرعت چرخش مختلف ۱۷۳۰ دور در دقیقه، ۱۷۵۰ دور در دقیقه، ۱۷۷۲ دور در دقیقه و ۱۷۹۷ دور در دقیقه جمع‌آوری شده است. بنابراین، ما از چهار پایگاه داده مختلف برای ارزیابی الگوریتم پیشنهادی استفاده کرده‌ایم.

در این مقاله از داده‌های مربوط به یاتاقان سمت انتهای درایو با فرکانس نمونه‌برداری ۱۲ کیلوهرتز استفاده شده است. جدول ۱ انواع این سیگنال‌ها را نشان می‌دهد که برای همه پایگاه‌های داده مشابه هستند. برای ارزیابی عملکرد الگوریتم پیشنهادی، یک نویز گاوسی با میانگین ۰/۱ و واریانس یک به سیگنال‌ها اضافه شده است. سپس از فیلتر میانگین برای حذف نویز از سیگنال‌ها استفاده می‌شود. سیگنال‌های ارتعاشی در شکل‌های ۴ تا ۷ در حالت نویزدار و بدون نویز در حوزه زمان نشان داده شده‌اند. شکل ۵ سیگنال نرمال نویزدار و بدون نویز را در حوزه زمان نشان می‌دهد. شکل ۶ سیگنال‌های خطای ساچمه را در سرعت ۱۷۹۷ دور بر دقیقه نشان می‌دهد. شکل‌های ۷ و ۸ گسل‌های مختلف رینگ داخلی و خارجی را در سرعت ۱۷۹۷ دور بر دقیقه نشان می‌دهند. در ادامه با استفاده از روش تبدیل سیگنال به تصویر مطرح‌شده در بخش دو بر اساس روش نرمالیزه کردن، سیگنال در حالت‌های مختلف به تصویر تبدیل می‌شود.

جدول ۱: انواع سیگنال  
Table 1. types of signals

| شماره کلاس | انواع سیگنال     | قطر خطا (اینچ) |
|------------|------------------|----------------|
| ۱          | حالت نرمال       | ۰              |
| ۲          | خطای رینگ داخلی  | ۰/۰۰۷          |
| ۳          | خطای رینگ داخلی  | ۰/۰۱۴          |
| ۴          | خطای رینگ داخلی  | ۰/۰۲۱          |
| ۵          | خطای رینگ بیرونی | ۰/۰۰۷          |
| ۶          | خطای رینگ بیرونی | ۰/۰۱۴          |
| ۷          | خطای رینگ بیرونی | ۰/۰۲۱          |
| ۸          | خطای ساچمه       | ۰/۰۰۷          |
| ۹          | خطای ساچمه       | ۰/۰۱۴          |
| ۱۰         | خطای ساچمه       | ۰/۰۲۱          |

<sup>1</sup>True positive


<sup>2</sup>False positive

<sup>3</sup>True negative

<sup>4</sup>False negative

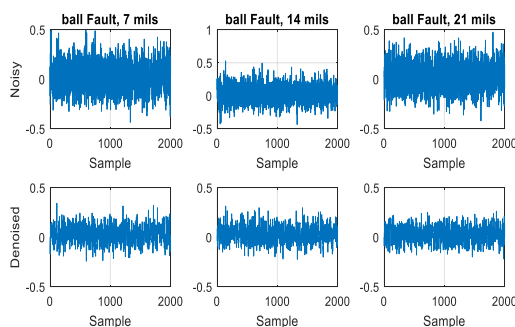
<sup>5</sup>CWRU

شکل ۹ تبدیل سیگنال به تصویر را در حالت نرمال به ازای حالتی که سیگنال با نویز آغشته نشده و حالتی که خطایی به ازای قطر گسل‌های ۷، ۱۴ و ۲۱ میلی اینچ بر روی ساچمه به وجود آمده نشان داده شده است. شکل ۱۰ نیز تبدیل سیگنال به تصویر را به ازای رینگ داخلی و خارجی در حالت قطر گسل ۷، ۱۴ و ۲۱ میلی اینچ نشان می‌دهد.




شکل ۵: سیگنال نرمال در حالت نویزی و غیرنویزی در حوزه زمان

Figure 5. Noisy and denoised ball fault signals for normal signal in time domain



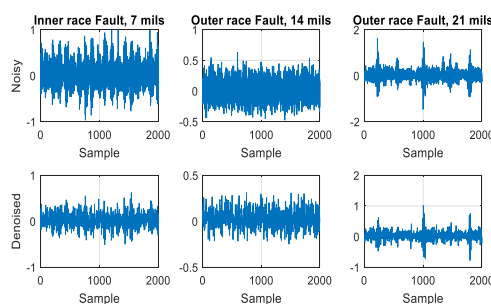
شکل ۶: سیگنال خطای ساچمه در حالت نویزی و غیر نویزی در حوزه زمان به ازای طول گسل‌های ۷، ۱۴ و ۲۱ میلی اینچ

Figure 6. Noisy and denoised ball fault signals for ball fault signal in time domain for faults with diameter of 7,14,21 milli inches




شکل ۷: سیگنال خطای رینگ داخلی در حالت نویزی و غیر نویزی در حوزه زمان به ازای طول گسل‌های ۷، ۱۴ و ۲۱ میلی اینچ

Figure 7. Noisy and denoised ball fault signals for inner race fault signal in time domain for faults with diameter of 7,14,21 milli inches




شکل ۸: سیگنال خطای رینگ بیرونی در حالت نویزی و غیر نویزی در حوزه زمان به ازای طول گسل‌های ۷، ۱۴ و ۲۱ میلی اینچ

Figure 8. Noisy and denoised ball fault signals for outer race fault signal in time domain for faults with diameter of 7,14,21 milli inches




شکل ۹: تبدیل سیگنال به تصویر در حالت نرمال و خطای ساچمه  
Figure 9. convert signal to image in normal and ball fault



شکل ۱۰: تبدیل سیگنال به تصویر در حالت خطاهای رینگ داخلی و خارجی  
Figure 10. convert signal to image in inner and outer race fault

شکل ۱۱ منحنی مشخصه عملکرد سیستم<sup>۱</sup> را نشان می‌دهد. این منحنی نرخ مثبت صحیح<sup>۲</sup> را در برابر نرخ مثبت کاذب<sup>۳</sup> نشان می‌دهد. مشاهده می‌شود که با افزایش نرخ مثبت کاذب، نرخ مثبت صحیح نیز افزایش می‌یابد. همچنین، نتایج حاصل از عملکرد الگوریتم‌های طبقه‌بندی در جدول ۲ نشان داده شده است. همان‌طور که در این جدول مشاهده می‌شود، "روش میانگین حداقل مربعات خطی" بهترین عملکرد را دارد.



شکل ۱۱: منحنی ROC  
Figure 11. ROC curve

<sup>1</sup> ROC  
<sup>2</sup> TPR  
<sup>3</sup> FPR

جدول ۲: عملکرد الگوریتم‌های طبقه‌بندی: (الف) روش میانگین حداقل مربعات خطی، (ب) روش تخمین رگرسیون خطی مبتنی بر چگالی هسته، (ج) روش طبقه‌بندی خطی لجستیک، (د) روش درخت تصمیم‌گیری

Table 2. Performance of classification algorithms: (a) Minimum least square linear classifier (b) Kernel Density-Based Linear Regression Estimate (c) Logistic linear classifier (d) Decision Tree Algorithm

| دقت   | حساسیت | صحت   | معیار F | الگوریتم |
|-------|--------|-------|---------|----------|
| ۹۸/۴۸ | ۹۸/۵۸  | ۲۵/۰۱ | ۸/۳۳    | (الف)    |
| ۸۷/۴۵ | ۹۵/۲۶  | ۹/۰۹  | ۶/۴۵    | (ب)      |
| ۷۶/۶۲ | ۸۲/۹۴  | ۵/۲۶  | ۶/۹۰    | (ج)      |
| ۷۲/۲۹ | ۷۳/۹۳  | ۱۶/۶۷ | ۲۵/۵۸   | (د)      |

به‌منظور ارزیابی عملکرد روش پیشنهادی، نتیجه حاصله از معیار دقت با چهار روش خطایابی ارائه شده در مقالات دیگر مقایسه شده است که نتایج مربوطه در جدول ۳ قابل مشاهده است. همان‌طور که مشاهده می‌شود روش پیشنهادی عملکرد بهتری را در زمینه خطایابی یاتاقان دارد.

جدول ۳: مقایسه الگوریتم پیشنهادی با دیگر روش‌های خطایابی یاتاقان

Table 3. Comparison of the proposed algorithm with other bearing fault methods

| معیار دقت | روش طبقه‌بندی            | شماره مرجع   |
|-----------|--------------------------|--------------|
| ۹۱/۶۷     | حذف نویز انباشته         | [۱۵]         |
| ۹۲/۸      | ماشین بردار پشتیبان      | [۱۶]         |
| ۹۵/۲۰     | یادگیری ماشین افراطی     | [۱۶]         |
| ۹۵/۳      | سافت مکس                 | [۱۶]         |
| ۹۵/۴۸     | میانگین حداقل مربعات خطی | روش پیشنهادی |

## ۵- نتیجه‌گیری

در این مقاله یک الگوریتم جدید برای تشخیص عیب یاتاقان غلتشی معرفی شده است. در این روش سیگنال ارتعاش با استفاده از فیلتر میانگین حذف می‌شود. سپس این سیگنال با استفاده از روش نگاشت سیگنال یک بعدی به سیگنال دوبعدی که یک تصویر در این مقاله یک الگوریتم جدید برای تشخیص عیب یاتاقان غلتشی معرفی شده است. در این روش سیگنال ارتعاش با استفاده از فیلتر میانگین حذف می‌شود. سپس این سیگنال با استفاده از روش نگاشت سیگنال یک بعدی به سیگنال دوبعدی که یک تصویر است تبدیل شد. نکته جدید این تحقیق استفاده از توصیفگر حذف نقاط کلیدی اضافی سیفت (RKEM-SIFT) برای استخراج ویژگی‌ها از سیگنال است. سپس از تحلیل مؤلفه اصلی غیرخطی برای انتخاب بهترین ویژگی‌ها استفاده شد. این ویژگی‌ها در چندین الگوریتم طبقه‌بندی برای طبقه‌بندی سیگنال‌های عادی و سیگنال‌های خطا اعمال می‌شوند. نکته قابل توجه در روش پیشنهادی این است که برخلاف روش‌های دیگر مطرح‌شده در مقالات که تنها سیگنال را به ازای دو کلاس حالت نرمال و حالت خطا به‌دست آورده‌اند، در روش پیشنهادی ۱۰ کلاس مختلف در نظر گرفته می‌شود و در آخر می‌توان قطر خطا را به ازای طول گسل‌های مختلف تشخیص داد. به‌عبارت‌دیگر، روش پیشنهادی می‌تواند سیگنال‌های نرمال و غیر نرمال را تعیین کرده و انواع و قطر خطا را نیز تشخیص دهد. نتایج شبیه‌سازی نشان می‌دهد که این روش یک تکنیک قدرتمند برای تشخیص عیب در یاتاقان‌های غلتشی است.

## مراجع

- [1] J. Dybala and R. Zimroz, "Rolling bearing diagnosing method based on Empirical Mode Decomposition of machine vibration signal," *Applied Acoustics*, vol. 77, pp. 195-203, 2014, doi: 10.1016/j.apacoust.2013.09.001.



- [2] L. Jiang, J. Xuan and T. Shi, "Feature extraction based on semi-supervised kernel Marginal Fisher analysis and its application in bearing fault diagnosis," *Mechanical Systems and Signal Processing*, vol. 41, no. 1-2, pp. 113-126, 2013, doi: 10.1016/j.ymsp.2013.05.017.
- [3] M. R. Shahriar, T. Ahsan and U. Chong, "Fault diagnosis of induction motors utilizing local binary pattern-based texture analysis," *EURASIP Journal on Image and Video Processing*, vol. 2013, Article Number: 29, 2013, doi: 10.1186/1687-5281-2013-29.
- [4] P. Wang, H. Yuan, H. Wang, X. Cao and X. Wang, "Rolling Element Bearing Fault Diagnosis Based on Symptom Parameter Wave of Acoustic Emission Signal," *Advanced Science Letters*, vol. 13, no. 1, pp. 667-670, 2012, doi: 10.1166/asl.2012.3889.
- [5] H. Yuan, F. Li and H. Wang, "Using Evaluation and Leading Mechanism to Optimize Fault Diagnosis Based on Ant Algorithm," *Energy Proscenia*, vol. 1, no. 6, pp. 112-116, 2012, E-ISSN: 2224-2678.2015.
- [6] Z. Dong, H. Wang, W. Shuming and W. Hou, "Intelligence diagnosis method based on particle swarm optimized neural network," *WSEAS Transactions on Systems*, vol. 12, no. 12, pp. 667-677, 2013, E-ISSN: 2224-2678.
- [7] B. Li, M. -Y. Chow, Y. Tipsuwan and J. C. Hung, "Neural-network-based motor rolling bearing fault diagnosis," in *IEEE Transactions on Industrial Electronics*, vol. 47, no. 5, pp. 1060-1069, Oct. 2000, doi: 10.1109/41.873214.
- [8] H. Wang, W. Hou, G. Tang and H. Yuan, "Fault Detection Enhancement in Rolling Element Bearings via Peak-Based Multiscale Decomposition and Envelope Demodulation," *Mathematical Problems in Engineering*, vol. 2014, Article Number: 329458, pp. 1-11, 2014, doi: 10.1155/2014/329458.
- [9] X. Li, H. Pan, J. Cheng and J. Cheng, "Non-parallel least squares support matrix machine for rolling bearing fault diagnosis," *Mechanism and Machine Theory*, vol. 145, pp.1-20, 2020, doi: 10.1016/j.mechmachtheory.2019.103676.
- [10] Y. Yang, C. Li , D. Jiang and K. Behdinan, "Nonlinear vibration signatures for localized fault of rolling element bearing in rotor-bearing-casing system," *International Journal of Mechanical Sciences*, vol. 173, p. 105449, 2020, doi: 10.1016/j.ijmecsci.2020.105449.
- [11] Y. Cheng, B. Zhou, Ch. Lu and C. Yang "Fault Diagnosis for Rolling Bearings under Variable Conditions Based on Visual Cognition," *Materials*, vol. 10, no. 6, p. 582, 2017, doi: 10.3390/ma10060582.
- [12] A. Namdar, H. Samet, M. Allahbakhshi, M. Tajdinian and T. Ghanbari, "A robust stator inter-turn fault detection in induction motor utilizing Kalman filter-based algorithm," *Measurement*, vol. 187, p. 110181, 2022, doi: 10.1016/j.measurement.2021.110181.
- [13] L. Martinez-Herrera, R. Ferrucho-Alvarez, M. Ledesma-Carrillo, I. Mata-Chavez and M. Lopez-Ramirez, "Multiple Fault Detection in Induction Motors through Homogeneity and Kurtosis Computation," *Energies*, vol. 15, no. 4, p. 1541, 2022, doi: 10.3390/en15041541.
- [14] L. Qian, Q. Pan, Y. Lv and X. ZhaO, "Fault Detection of Bearing by Resnet Classifier with Model-Based Data Augmentation," *Machines*, vol. 10, no. 7, p. 521, 2022, doi: 10.3390/machines10070521.
- [15] C. Lu, Z.-Y. Wang, W.-L. Qin, and J. Ma, "Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification," *Signal Process*, vol. 130, pp. 377–388, Jan. 2017, doi: 10.1016/j.sigpro.2016.07.028.
- [16] S. Haidong, J. Hongkai, L. Xingqiu, and W. ShuaiPeng, "Intelligent fault diagnosis of rolling bearing using deep wavelet auto-encoder with extreme learning machine," *Knowl.-Based Syst.*, vol. 140, pp. 1–14, 2018, doi: 10.1016/j.knosys.2017.10.024.

- [17] R. M. Haralick, K. Shanmugam and I. Dinstein, "Textural Features for Image Classification," in IEEE Transactions on Systems, Man, and Cybernetics, vol. SMC-3, no. 6, pp. 610-621, Nov. 1973, doi: 10.1109/TSMC.1973.4309314.
- [18] T.Ojala, M. Pietikainen and D. Harwood, "Performance evaluation of texture measures with classification based on Kullback discrimination of distributions," in IAPR international conference on pattern recognition, Conference A: Computer Vision & Image Processing, Israel, 9-13 October 1994, pp. 582- 585, doi: 10.1109/ICPR.1994.576366.
- [19] D.G. Lowe, "Distinctive image features from scale-invariant keypoints," Int. J. Comput. Vision , vol. 60, pp. 91-110, 2004, doi: 10.1023/B:VISI.0000029664.99615.94.
- [20] Z. Hossein-Nejad and M. Nasri, "RKEM: Redundant Key-point Elimination Method in Image Registration," IET Image Processing, vol. 11, pp. 273-284, 2017, doi: 10.1049/iet-ipr.2016.0440.
- [21] D. Hoang and H. Kang, "Rolling element bearing fault diagnosis using convolutional neural network and vibration image," Cognitive System Research, vol. 53, pp. 42-50, 2019, doi: 10.1016/j.cogsys.2018.03.002.
- [22] A. Tharwat, "principal component analysis- a tutorial," International Journal of Applied Pattern Recognition, vol. 3, no. 3, pp. 197-240, 2016, doi: 10.1504/IJAPR.2016.079733.
- [23] J. Ye, "Least squares linear discriminant analysis," Machine Learning, Proceedings of the Twenty-Fourth International, vol. 227, pp. 1087-1093, June 2007, doi: 10.1145/1273496.1273633.
- [24] M. Zhou and W. Yao, "Kernel Density-Based Linear Regression Estimate," Communications in Statistics Theory and Methods, vol. 42, no. 24, 2013, doi:10.1080/03610926.2011.650269.
- [25] A. Widodo and S. Handoyo, "The classification performance using logistic regression and support vector machine," Journal of Theoretical and Applied Information Technology, vol. 95, no. 19, 2017.
- [26] B. T. Jijo and A. M. Abdulazeez, "Classification Based on Decision Tree Algorithm for Machine Learning," Journal of Applied Science and Technology Trends, vol. 2, no. 01, 2021, doi: 10.38094/jastt20165.
- [27] K. Rezaei, H. Agahi and A. Mahmoodzadeh, "A Weighted Voting Classifiers Ensemble for the Brain Tumors Classification in MR Images," IETE Journal of Research, vol. 68, no. 5, 2022, doi: 10.1080/03772063.2020.1780487.
- [28] <https://csegroups.case.edu/bearingdatacenter/pages/welcomecase-western-reserve-university-bearing-data-center>.

---

#### COPYRIGHTS

©2024 by the authors. Published by the Islamic Azad University Bushehr Branch. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) <https://creativecommons.org/licenses/by/4.0>

---

