

Diagnosis of Mitral Valve Disease using Manifold Learning

Jaafari kia, Saba ¹ / Behnam, Hamid ^{2*} / Vafaezadeh, Majid ³ / Hosseinsabet, Ali ⁴

¹ - M.Sc. Student, Medical Image Processing Lab, School of Electrical Engineering, Iran University of Science and Technology, Tehran, Iran

² - Associate Professor, Medical Image Processing Lab, School of Electrical Engineering, Iran University of Science and Technology, Tehran, Iran

³ - Ph.D. Student, Medical Image Processing Lab, School of Electrical Engineering, Iran University of Science and Technology, Tehran, Iran

⁴ - Associate Professor, Cardiology Department, Tehran Heart Center, Tehran University of Medical Sciences, Tehran, Iran

ARTICLE INFO

DOI: 10.22041/IJBME.2021.530092.1691

Received: 10 May 2021

Revised: 16 July 2021

Accepted: 10 October 2021

KEYWORDS

Mitral Valve Disease
Non-Linear Dimension Reduction (NLDR)
Manifold Learning (ML)
Locally Linear Embedding (LLE)

ABSTRACT

Heart diseases are main cause factors endangering human health and life, one of the most important heart diseases is valvular heart disease, which has had an increasing trend in recent years. Therefore, if they are diagnosed and treated in time and correctly, they can improve the quality of life and increase the life expectancy, so researchers have always been looking for ways to improve and accelerate the process of diagnosing this disease. Medical images monitoring and recording the activity of the human heart are the main ways to diagnose heart diseases. Processing of these images is generally complex and time consuming, so scientists and experts have always been looking for ways to speed up and facilitate the detection process. Manifold learning is one of the nonlinear dimension reduction methods which has different algorithms and can simplify the processing of echocardiographic images. In this study, using one of the manifold learning algorithms named LLE, we examined echocardiographic images of the heart, and tried to categorize groups with mitral disorders while identifying healthy data from those with disorders. Results show that the method has carefully separated the data of the healthy group from the group with the disorder, and good results were obtained in the data classification. The results show that more than 80% of the samples of the natural group have a different pattern in terms of manifold structure from the samples with the disorder.

*Corresponding Author

Address	Medical Image Processing Lab, School of Electrical Engineering, Iran University of Science and Technology, Tehran, Iran		
Postal Code	16846-13114	Tel	+98-21-73225629
E-Mail	behnam@iust.ac.ir	Fax	+98-21-73225777





به کارگیری یادگیری منیفلد برای تشخیص بیماری دریچه‌ی میترا

جعفری کیا، صبا^۱ / بهنام، حمید^{۲*} / وفايي زاده، مجید^۳ / حسین ثابت، علی^۴

- ^۱ - کارشناس ارشد، آزمایشگاه پردازش تصاویر پزشکی، دانشکده‌ی مهندسی برق، دانشگاه علم و صنعت ایران، تهران، ایران
- ^۲ - دانشیار، آزمایشگاه پردازش تصاویر پزشکی، دانشکده‌ی مهندسی برق، دانشگاه علم و صنعت ایران، تهران، ایران
- ^۳ - دانشجوی دکتری، آزمایشگاه پردازش تصاویر پزشکی، دانشکده‌ی مهندسی برق، دانشگاه علم و صنعت ایران، تهران، ایران
- ^۴ - دانشیار، گروه قلب و عروق، مرکز قلب تهران، دانشگاه علوم پزشکی تهران، تهران، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/IJBME.2021.530092.1691

پذیرش: ۱۸ مهر ۱۴۰۰

بازنگری: ۲۵ تیر ۱۴۰۰

ثبت در سامانه: ۲۰ اردیبهشت ۱۴۰۰

چکیده

بیماری‌های قلبی یکی از اصلی‌ترین عوامل به خطر انداختن سلامت و زندگی انسان هستند. از مهم‌ترین بیماری‌های قلب، بیماری‌های مربوط به دریچه‌های قلب بوده که در طی سال‌های اخیر روندی افزایشی داشته است. تشخیص و درمان درست و به موقع این بیماری‌ها، بهبود کیفیت زندگی و افزایش طول عمر افراد را به دنبال دارد. از این رو محققان همواره به دنبال یافتن روش‌هایی برای بهبود و تسریع روند تشخیص این بیماری بوده‌اند. تصاویر پزشکی، فعالیت قلب انسان را بررسی و ضبط کرده و از جمله راه‌های اصلی تشخیص مشکلات قلبی هستند. عموماً پردازش این تصاویر پیچیده و زمان‌بر است، به همین جهت محققان به دنبال پیدا کردن روش‌هایی برای ساده‌سازی پردازش این تصاویر هستند. یادگیری منیفلد یکی از روش‌های کاهش بعد غیرخطی است که الگوریتم‌های مختلفی داشته و می‌تواند موجب ساده‌سازی پردازش تصاویر اکوکاردیوگرافی شود. در این پژوهش با کمک یکی از الگوریتم‌های یادگیری منیفلد به نام LLE، تصاویر اکوکاردیوگرافی مورد بررسی قرار گرفته و سعی شده است تا با کمک روش یادگیری منیفلد داده‌های سالم از داده‌های دارای اختلال دریچه‌ی میترا شناسایی شده و ویژگی‌های جدا کننده‌ی سه گروه پاتولوژی دریچه‌ی میترا شامل MVP، MS و III-b استخراج شود. نتایج به دست آمده نشان می‌دهد که بیش از ۸۰٪ نمونه‌های گروه طبیعی از نظر ساختار منیفلد الگویی متفاوت با نمونه‌های دارای اختلال دارند.

واژه‌های کلیدی

بیماری دریچه‌ی میترا
کاهش بعد غیرخطی
یادگیری منیفلد
الگوریتم LLE

*نویسنده‌ی مسئول

نشانی: آزمایشگاه پردازش تصاویر پزشکی، دانشکده‌ی مهندسی برق، دانشگاه علم و صنعت ایران، تهران، ایران

کد پستی: ۱۶۸۴۶-۱۳۱۱۴

پست الکترونیک: behnam@iust.ac.ir

تلفن: +۹۸-۲۱-۷۳۲۲۵۶۲۹

دورنگار: +۹۸-۲۱-۷۳۲۲۵۷۷۷



۱- مقدمه

پزشک از یک یا چند روش استفاده می‌شود [۳]. تصویربرداری اولتراسوند^۸ به دلیل ایمن بودن، قیمت مناسب و غیرتهاجمی^۹ بودن از دیرباز در تصویربرداری‌های پزشکی مورد توجه بوده است. این روش هم‌چنین امکان مشاهده‌ی بلادرنگ^{۱۰} حرکت ساختارهای قلب را فراهم می‌سازد. اکوکاردیوگرافی مبتنی بر امواج اولتراسوند بوده و یکی از روش‌های تشخیصی برای تصویربرداری از قلب جهت به دست آوردن اطلاعات مفید شامل اندازه و شکل قلب، قدرت پمپاژ خون و وسعت آسیب به بافت است که می‌تواند در بررسی و تشخیص اختلال‌های دریچه‌ی قلب بسیار کمک کننده باشد [۴]. محققان حوزه‌ی هوش مصنوعی همواره به دنبال تحلیل خودکار تصاویر و ویدئوهای اکوکاردیوگرافی بیماران با استفاده از روش‌های شناسایی الگو و بینایی کامپیوتر بوده‌اند. با وجود این که بعد بالای تصاویر جزئیات بیش‌تری از وضعیت بیمار را در اختیار قرار می‌دهد اما تحلیل و پردازش این حجم از داده‌ها زمان‌بر، پیچیده و گاهی دشوار است. این امر منجر به استفاده از روش‌های کاهش بعد^{۱۱} به منظور دور ریختن اطلاعات اضافی یا بهبود کیفیت تفسیر داده‌ها شده است [۵]. کاهش بعد فرایندی است که طی آن با روش‌های مختلف، تصاویر با بعد بالا به تصاویر ساده با بعد پایین‌تر تبدیل شده و در نتیجه تحلیل و پردازش تصاویر ساده‌تر می‌شود. کاهش بعد به طور کلی به دو صورت کاهش بعد خطی^{۱۲} (LDR) و کاهش بعد غیرخطی^{۱۳} (NLDR) انجام می‌شود. اساس این روش‌ها بر این ایده استوار است که بعد بالای یک سیستم الزاما به معنی بعد واقعی و ذاتی آن سیستم نبوده بلکه تعداد پارامترهای واقعی که می‌تواند داده‌ها را از هم متمایز کند، می‌تواند از بعد ظاهری کم‌تر باشد [۶]. در روش‌های کاهش بعد خطی از توابع ساده‌ی خطی استفاده شده تا داده‌های با ابعاد بالا به ابعاد پایین‌تر تبدیل شود [۷]. از روش‌های قدیمی و خطی کاهش بعد می‌توان به دو روش تحلیل مولفه‌های اصلی^{۱۴} (PCA) و تغییر مقیاس چندبعدی^{۱۵} (MDS) اشاره کرد. این دو روش، روش‌های بردار ویژه بوده و با این هدف طراحی شده‌اند تا متغیرهای خطی در داده‌های بعد بالا را مدل‌سازی کنند. نکته‌ی قابل توجه این است که این روش‌ها تنها برای مواردی که ارتباط خطی بین پارامترهای داده‌ها

بیماری‌های قلب و عروق یکی از عوامل مهم تهدید کننده‌ی سلامت و زندگی انسان به شمار رفته و دومین علت مرگ و میر در دنیا است [۱]. بر اساس یک گزارش در سال ۲۰۱۹ بیش از ۱۸ میلیون نفر در نتیجه‌ی اثرات بیماری‌های قلبی فوت کرده‌اند [۲]. اختلالات دریچه‌ی قلب یکی از انواع بیماری‌های قلبی است. بیماری‌های دریچه‌ی قلب با درگیر کردن بافت دریچه‌ها بر عمل‌کرد آن‌ها تاثیر می‌گذارند. دریچه‌ها در عمل‌کرد تلمبه‌ای و پمپاژ قلب نقش اساسی ایفا کرده و از برگشت خون جلوگیری به عمل می‌آورند. هر گونه اختلال در عمل‌کرد این دریچه‌ها می‌تواند موجب اختلال در عمل‌کرد قلب شود. این اختلالات دریچه‌ای به مرور زمان باعث نارسایی قلب^۱ می‌شود. در ابتدای ایجاد اختلال در عمل‌کرد دریچه‌های قلب هیچ گونه علامت مشخصی در بیمار ایجاد نمی‌شود اما با پیشرفت بیماری، فرد بیمار در انجام فعالیت‌های فیزیکی دچار مشکل شده و به مرور با پیشرفت بیماری و تشدید آن فرد حتی در حالت استراحت و یا خواب نیز دچار تنگی نفس و احساس خفگی می‌شود. اختلالات دریچه‌ی قلب در جوامع امروزی به شدت در حال افزایش است بنابراین تشخیص، بررسی و مدیریت این بیماری از اهمیت بسیار زیادی برخوردار بوده و در دراز مدت به کاهش آسیب‌های ناشی از این بیماری و کاهش مرگ و میر کمک می‌کند. دانش اساسی در مورد بیماری دریچه خیلی مهم است و می‌تواند در مراحل اولیه بسیار کمک کننده باشد [۳]. در این پژوهش به طور ویژه وضعیت دریچه‌ی میترال مورد ارزیابی قرار گرفته است. دریچه‌ی میترال دریچه‌ای است که بین دهلیز چپ و بطن چپ قرار گرفته و شامل دو لت است. لت‌های این دریچه هنگام انقباض (دیاستول) قلب باز بوده و خون از دهلیز وارد بطن چپ می‌شود. طی انقباض بطن چپ (سیستول)، دریچه‌ی میترال به وسیله‌ی تارهای نگه دارنده، محکم بسته نگه داشته می‌شود. از جمله روش‌های تشخیصی برای بررسی بیماری‌های قلب می‌توان به اکوکاردیوگرافی^۲، کاتتریزاسیون قلب^۳، الکتروکاردیوگرافی^۴ (ECG)، تصویربرداری اشعه‌ی ایکس از قفسه‌ی سینه^۵، ام‌آر‌آی قلبی^۶، آزمایش‌های ورزشی و آزمایش‌های استرس^۷ اشاره کرد که بنا بر تشخیص

^۹ Non-Invasive^{۱۰} Real Time^{۱۱} Dimension Reduction^{۱۲} Linear Dimension Reduction^{۱۳} Non-Linear Dimension Reduction^{۱۴} Principal Component Analysis^{۱۵} Multidimensional Scaling^۱ Heart Failure^۲ Echocardiography^۳ Catheterization^۴ Electrocardiography^۵ Chest X-Ray (CXR)^۶ Cardiac Magnetic Resonance Imaging^۷ Exercise Test^۸ Ultrasound Imaging



این است که پارامترهای ذاتی سیستم شناسایی شده و کل مجموعه‌ی دادگان روی منیفلدی که بیان کننده‌ی ارتباط ذاتی پارامترها است، قرار گرفته و ارتباط بین دادگان در فضایی با بعد کم‌تر بیان شود. با فرض این که X_i شامل N نمونه با بعد D باشد، با نگاشت مناسب یادگیری منیفلد و با حفظ ارتباط ذاتی دادگان، متناظر با هر X_i یک Y_i وجود داشته که دارای بعد d بوده که در آن $D \gg d$ است (رابطه‌ی ۱) [۶].

$$x_1, x_2, \dots, x_n \in R^D \rightarrow y_1, y_2, \dots, y_n \in R^d \quad (1)$$

روش‌های کاهش بعد غیرخطی به دو دسته‌ی کلی سراسری^۳ و موضعی^۴ تقسیم می‌شوند. روش‌های کاهش بعد غیرخطی سراسری نه تنها سعی در حفظ ویژگی‌های کلی دادگان داشته بلکه قابلیت تعبیر یک نگاشت غیرخطی بین دادگان در بعد بالا با دادگان در بعد پایین را نیز دارند. در روش‌های غیرخطی موضعی با حفظ ساختار محلی، دادگان به بعد پایین نگاشت می‌شوند [۶]. یک رویکرد محلی از نظر محاسباتی کارآمدتر از یک رویکرد سراسری است زیرا روش اول شامل ماتریس‌های پراکنده بوده و به طور کلی برای انواع مختلف منیفلد قابل استفاده می‌باشد. با مطرح شدن ایده‌ی یادگیری منیفلد، الگوریتم‌های مختلفی برای کاهش بعد غیرخطی ارائه شده است. از معروف‌ترین الگوریتم‌های یادگیری منیفلد می‌توان به لاپلاسیان،^۵ Isomap،^۶ تعبیه‌ی محلی خطی^۶ (LLE)،^۷ HLLE و نقشه‌ی دیفیوژن^۸ اشاره کرد (شکل ۱). پیشنهاد می‌شود برای آگاهی از مبانی ریاضی یادگیری منیفلد غیرخطی به مقاله‌ی [۹] مراجعه شود. هر الگوریتم از استخراج مقادیر ویژه و بردارهای ویژه از برخی ماتریس‌های متقارن بزرگ ساخته شده و روش هر الگوریتم متفاوت از دیگری است [۷].

۲-۱- الگوریتم LLE

الگوریتم LLE یک روش محلی بوده زیرا تعبیه‌ی آن بر اساس رابطه‌ی هر نقطه‌ی داده با نقاط همسایه‌ی آن است و می‌تواند هر دو نوع تعبیه شده را بازیابی کند. ممکن است نمونه‌ها مستقیماً به عنوان نقاط تعبیه شده در یک فضای اقلیدسی با ابعاد بالا، یا به صورت غیرمستقیم به عنوان یک ماتریس فاصله‌ی جفتی القا شده توسط یک ساختار متریک و یا روابط شباهت جفتی رمزگذاری شده توسط دانش دامنه ارائه شوند. روش LLE یک الگوریتم یادگیری بدون نظارت است که با حفظ

وجود دارد مناسب بوده و این امر می‌تواند به عنوان یک محدودیت تلقی شود. هنگامی که پارامترهای ذاتی سیستم ارتباط خطی و به ظاهر معناداری با یکدیگر نداشته باشند، روش‌های خطی پاسخ‌گو نبوده و باید با کمک روش‌های غیرخطی به حل مساله پرداخته شود [۶]. فعالیت‌های پژوهشی زیادی در زمینه‌ی کاهش بعد غیرخطی انجام شده که برخی از این روش‌ها تعمیم غیرخطی روش‌های خطی هستند [۷]. رویکرد جدیدی که برای حل مسائل کاهش بعد توصیف شده است از اطلاعات متریک محلی که به راحتی قابل اندازه‌گیری بوده برای یادگیری هندسه‌ی کلی یک مجموعه‌ی داده استفاده می‌کند [۷]. در زمینه‌ی کاهش بعد غیرخطی سیستم، ایده‌ی یادگیری منیفلد یکی از جدیدترین روش‌ها است. ایده‌ی اصلی این روش بر اساس حفظ ارتباط بین دادگان است که می‌تواند به صورت حفظ فاصله بیان شود. با در اختیار داشتن یک مجموعه‌ی تصویر، هر تصویر به عنوان یک داده در نظر گرفته شده و با توجه به این که هر تصویر توسط تعدادی پیکسل بیان می‌شود، بعد ظاهری هر داده برابر با تعداد این پیکسل‌ها خواهد بود. در ادامه با وجود شباهت زیاد تصاویر سعی می‌شود پارامترهای ذاتی که موجب اختلاف اندک و تمایز تصاویر از یکدیگر بوده، شناسایی شده و با استفاده از این پارامترها و استفاده از الگوریتم‌های مناسب منیفلد، ارتباط بین تصاویر استخراج شود [۸]. با توجه به این که تا کنون برای تشخیص اختلالات دریچه‌ی میترال از تکنیک‌های پردازش تصویر استفاده نشده، در این پژوهش بعد بالای تصاویر اکوکاردیوگرافی با استفاده از روش یادگیری منیفلد کاهش داده شده و با این کار ضمن ساده‌سازی پردازش این تصاویر، سعی شده است تا امکان تشخیص ساده‌تر برخی از اختلالات دریچه‌ی میترال فراهم شود.

۲- روش

یادگیری منیفلد یا کاهش ابعاد غیرخطی، به روشی اشاره دارد که هدف آن حفظ خواص هندسی و توپولوژیکی مجموعه‌ی محدودی از نمونه‌ها بوده که از یک فضای غیراقلیدسی در ابعاد بالا گرفته شده است [۸]. پیشنهاد می‌شود برای آگاهی از مقدمه‌ی دقیق ریاضی در نظریه‌ی منیفلدها به متون کلاسیک بوئی^۱ [۵] و اسپواک^۲ [۹] مراجعه شود. در هندسه‌ی منیفلد، واژه‌ی منیفلد به هر رویه، منحنی و یا شکل پیچیده‌ی غیرخطی اطلاق می‌شود. در حقیقت در روش یادگیری منیفلد سعی بر

^۳ Isometric Map

^۴ Locally Linear Embedding (LLE)

^۷ Hessian Locally Linear Embedding (HLLE)

^۸ Diffusion Map

^۱ Boothby

^۲ Spivak

^۳ Global

^۴ Local

فاصله‌ی بین نقاط بر اساس تابع اقلیدسی محاسبه شده است. پس از به دست آمدن نقاط همسایه، نموداری شکل گرفته که این نقاط را به هم متصل می‌کند. در این نمودار اندازه‌ی یال‌ها معادل فاصله‌ی بین دو نقطه بوده که چون همسایه‌ی هم هستند، به طور مستقیم به هم وصل شده‌اند. معمولاً پاسخ LLE برای یک محدوده‌ی مشخص از k پایدار است [۱۲]. در این مقاله با امتحان چندین مقدار متفاوت برای k ، بهترین نتیجه در ۱۲ به دست آمده و لذا مقدار k ثابت و برابر ۱۲ در نظر گرفته شده است. پس از انتخاب k مناسب، در مرحله‌ی دوم ضرایب خطی w بازسازی شده است. بازسازی بهینه‌ی این ضرایب با کمینه کردن تابع ارزی در رابطه‌ی (۲) انجام شده است [۱۳].

$$E(w) = \sum_{i=1}^N \left| \tilde{x}_i - \sum_{j=1}^k w_{ij} \tilde{x}_j \right|^2 \quad (2)$$

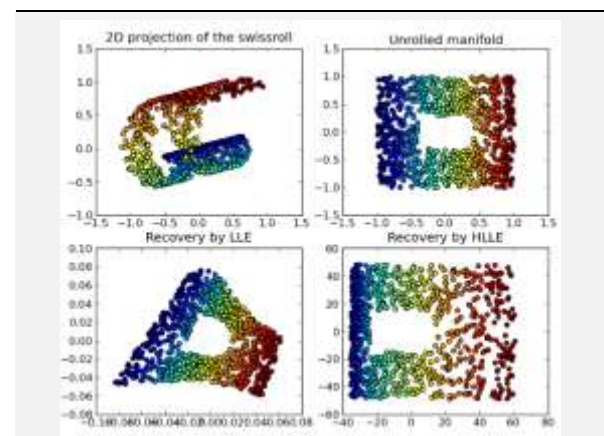
پس از بازسازی ضرایب، در گام آخر، x در فضای D بعدی به y در فضای d بعدی نگاشته می‌شود [۱۲]. با فرض این که داده‌ها روی y یا نزدیک یک منیفلد با بعد d قرار دارند، تصور می‌شود که یک تبدیل خطی شامل جابه‌جایی، چرخش و تغییر اندازه وجود دارد که مختصات با بعد بالا را به مختصات ذاتی منیفلد نگاشت می‌کند. در این نگاشت ضرایب w به گونه‌ای طراحی شده که ویژگی‌های هندسی دادگان به این تبدیلات خطی، ثابت باقی بماند. به طوری که رابطه‌ی محلی دادگان در بعد بالا، در بعد پایین نیز هم‌چنان حفظ شود. به عبارت دیگر w_{ij} ‌هایی که x_i را در فضای D بعدی بازسازی کرده‌اند باید قادر به بازسازی دادگان در فضای d بعدی y_i باشند. این مرحله با کمینه کردن تابع ارزی در رابطه‌ی (۳) انجام شده است [۱۲].

$$\varphi(y) = \sum_{i=1}^N \left| \tilde{y}_i - \sum_{j=1}^k w_{ij} \tilde{y}_j \right|^2 \quad (3)$$

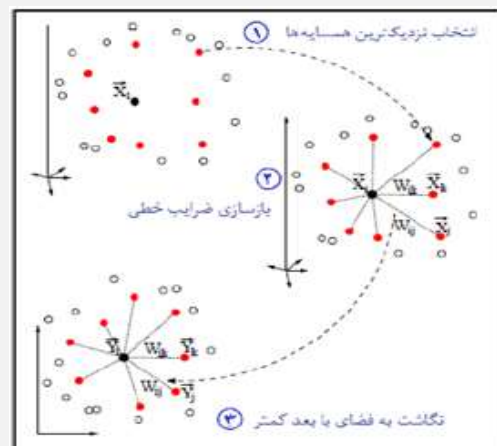
این تابع مانند رابطه‌ی (۲) سعی در کمینه کردن خطای بازسازی دارد با این تفاوت که در این جا y ‌ها تنها با اطلاعات ضرایب w محاسبه شده و در این مرحله هیچ استفاده‌ای از x نمی‌شود. به عبارت دیگر کاهش بعد با حفظ اطلاعات هندسی اخذ شده از ضرایب انجام می‌شود. برای حل این رابطه از روش تحلیل بردار ویژه استفاده شده است. با بازنویسی مجدد رابطه‌ی (۳)، رابطه‌ی زیر به دست می‌آید [۱۲].

$$\begin{aligned} \varphi(y) &= \sum_i \left| \tilde{y}_i - \sum_j w_{ij} \tilde{y}_j \right|^2 \\ &= \sum \left(\tilde{y}_i - \sum_j w_{ij} \tilde{y}_j \right) \left(\tilde{y}_i - \sum_j w_{ij} \tilde{y}_j \right) \\ &= \sum_{ij} M_{ij} (\tilde{y}_i \tilde{y}_j) \end{aligned} \quad (4)$$

اطلاعات بعد بالا، یک نگاشت بعد پایین از داده‌ها می‌سازد. در روش LLE تلاش می‌شود تا با استخراج بازسازی خطی از تقارن محلی، ساختار غیرخطی داده‌های بعد بالا شناسایی شود [۱۱]. الگوریتم LLE در شکل (۲) خلاصه شده است. در این روش ویژگی محلی دادگان منیفلد به وسیله‌ی ترکیب خطی همسایگان بازسازی شده و یک سری ضرایب به دست می‌آید. سپس حین کاهش بعد دادگان، تلاش می‌شود این ضرایب در بازسازی حفظ شوند [۶]. مطابق شکل (۲)، پیاده‌سازی این الگوریتم در سه مرحله انجام می‌شود.



شکل (۱) - اطلاعات هزار نقطه در نمای swissroll (بالا چپ)، منیفلد دوبعدی اصلی (بالا راست)، بازسازی با دو الگوریتم LLE (پایین چپ) و HLLE (پایین راست) [۱۰]



شکل (۲) - خلاصه‌ای از الگوریتم LLE [۶]

مرحله‌ی اول الگوریتم یافتن تعداد k همسایه‌ی نزدیک برای هر داده است. برای یافتن این نقاط دو روش وجود دارد. حالت اول این است که مقدار k ثابت در نظر گرفته شده و به وسیله‌ی فواصل اقلیدسی k همسایه‌ی نزدیک هر داده به دست آورده شود. حالت دیگر این است که یک شعاع همسایگی در نظر گرفته شده و تمام نقاطی که در این شعاع قرار دارند به عنوان همسایه‌ی نزدیک آن داده محسوب شوند. در این تحقیق



۳- تغییر ریخت‌شناسی دریچه‌ی میترال ناشی از تغییر در ساختارهای حمایت کننده از دریچه که در اثر کاردیومیوپاتی‌های ایسکمیک یا غیرایسکمیک رخ داده، با عنوان تغییرات ثانویه^۱ شناخته شده و مطابق با نوع IIIb است. در این مقاله سایر پاتولوژی‌های دریچه‌ی میترال مورد بررسی قرار نگرفته است [۱۳]. در این پژوهش سعی بر آن است تا با انتخاب الگوریتم مناسب یادگیری منیفلد بتوان ضمن کاهش بعد دادگان ورودی پردازش این تصاویر را ساده‌تر کرد تا با دقت کافی به صورت ساده‌تر و در زمان کوتاه‌تر در گام اول داده‌ی گروه طبیعی از داده‌های دارای اختلال جدا شده و در مرحله‌ی دوم ویژگی‌های این گروه‌ها استخراج شود. نتایج به دست آمده برای ارزیابی به پزشک متخصص نشان داده شده و با این کار به تشخیص سریع‌تر بیماری دریچه‌ی میترال کمک می‌شود.

۳-۱- جمع‌آوری پایگاه داده

تصاویر اکوکاردیوگرافی مورد بررسی از ۲۰۰ نفر شامل چهار گروه ۵۰ نفره (یک گروه با دریچه‌ی طبیعی و سه گروه دارای اختلال دریچه) از نمای چهار حفره‌ای قلب با استفاده از دستگاه فیلیپس^۲ در بخش اکوکاردیوگرافی مرکز قلب تهران با میانگین 41 ± 8 فریم‌درثانیه اخذ شده است. با توجه به اتصال لیدهای ECG به هر فرد، فریم اول در ضبط اکوکاردیوگرافی مطابق با فاز پایان دیاستول قلب است. هم‌چنین داده‌ها از نظر جنسیت، سن و شدت بیماری افراد دسته‌بندی نشده است.

۳-۲- کاهش بعد تصاویر

کاهش بعد تصاویر با نرم‌افزار متلب نسخه‌ی 2015-a انجام شده است. ابعاد اولیه‌ی هر تصویر 314×512 پیکسل بوده و بنابراین بعد ظاهری هر داده ۱۶۰۷۶۸ است. با روش یادگیری منیفلد هر تصویر به فضای دوبعدی نگاشته شده است. تعداد همسایگان هر داده ۱۲ در نظر گرفته شده است. مجموعه‌ی تصاویر به این دلیل در فضای دوبعدی نگاشته شده که دو مقدار ویژه‌ی اولیه بزرگ‌ترین مقادیر ویژه بوده و نگه داشتن تنها دو بردار ویژه‌ی متناظر با این مقادیر ویژه بزرگ کفایت می‌کند [۶]. لازم برای نگاشت یک مجموعه‌ی تصویر اکوکاردیوگرافی به فضای دوبعدی منیفلد حدوداً 2 ± 0.5 ثانیه است.

۴- نتایج

برای انتخاب الگوریتم مناسب چند الگوریتم مختلف از جمله لاپلاسیان، tSNE، Isomap و LLE روی داده‌ها اجرا شده است

در این رابطه ماتریس M طبق رابطه‌ی (۵) تعریف می‌شود.

$$M_{ij} = \sigma_{ij} - w_{ij} - w_{ji} + \sum_k w_{kj} w_{ki} \quad (5)$$

$$= (I - W)^T (I - W)$$

در نتیجه با محاسبه‌ی بردارهای ویژه‌ی معادل d کوچک‌ترین مقدار ویژه‌ی ماتریس M، می‌توان تابع ارزشی را کمینه کرد. بردارهای ویژه‌ی به دست آمده، مختصات جدید فضای خروجی الگوریتم LLE بوده و به این ترتیب ارتباط بین y_i ها در فضای با بعد d نمایش داده می‌شود. برای اعمال این الگوریتم روی مجموعه‌ی تصاویر اخذ شده از یک شی خاص، فرض می‌شود که در هر تصویر $N \times N$ پیکسلی، هر پیکسل معرف یک بعد بوده و در نتیجه بعد ظاهری تصویر N^2 است که عدد بسیار بزرگی خواهد شد. در این پژوهش با در اختیار داشتن مجموعه‌ی تصاویر اکوکاردیوگرافی، هر x معادل یک فریم با بعد بالای $D=N^2$ بوده که به y_i در فضای $d=2$ بعدی نگاشته شده و در کل مجموعه روی یک منحنی غیرخطی قرار می‌گیرد [۱۲].

۳- داده‌ها

اختلال‌های دریچه‌ی قلب انواع مختلفی دارد که در مقاله‌ی [۳] چند مورد از آن‌ها از جمله نارسایی و تنگی دریچه مورد بررسی قرار گرفته و در مورد هر اختلال مطالبی هم‌چون علت بروز، راه‌های شناسایی و تشخیص مشکل و درمان‌های پیشنهادی مطرح شده است. داده‌ی مورد استفاده در این پژوهش بر اساس دسته‌بندی مقاله‌ی [۱۳] شامل یک گروه طبیعی و سه کلاس پاتولوژی دریچه‌ی میترال (II, IIIb, IIIa) با توجه به طبقه‌بندی کارپنتییر [۱۴] طبق تعاریف زیر است [۱۳].

۱- پرولاپس دریچه‌ی میترال و flail شدن لتهای دریچه (لت قدامی، خلفی، یا هر دو) که در آن افزایش حرکات لتهای دریچه رخ داده و لتهای در زمان سیستول در خلف خط آنولوس دریچه‌ی میترال قرار می‌گیرد. در موارد پرولاپس، اختلال به طور اصلی در ساختار لت دریچه وجود دارد و در flail اختلال در اثر پارگی کوردا رخ می‌دهد که می‌تواند همراه با پرولاپس در سایر نواحی دریچه‌ی میترال باشد یا نباشد که منطبق با نوع II طبقه‌بندی کارپنتییر است.

۲- درگیری روماتیسمی دریچه‌ی میترال که منجر به تنگی قابل توجه شده (سطح دریچه کمتر از 2 cm^2) که در آن حرکات لتهای در طی سیستول و دیاستول کاهش یافته که مطابق با نوع IIIa طبقه‌بندی کارپنتییر است.

^۲ Philips Equipment (Philips, Affinity 70C, Andover, MA, USA) with an S5-1 Probe

^۱ Secondary

۳- الف). با توجه به این که ارتباط معناداری بین تصاویر مینفلد مشاهده نشده، الگوریتم روی یک پنجره در ناحیه‌ی دریاچه‌ی میترا (شکل ۳-ب). نتایج به دست آمده از تعبیه‌ی مینفلد روی قسمت دریاچه‌ی میترا تصاویر اکوکاردیوگرافی، اطلاعات و جزئیات بیش‌تری درباره‌ی وضعیت دریاچه در اختیار قرار داده است. در بخش‌های بعد به بررسی جزئیات این تصاویر پرداخته شده است.

[۱۲]. با بررسی شکل‌ها مشاهده شده است که تصاویر حاصل از الگوریتم LLE ارتباط بین تصاویر اکوکاردیوگرافی را بهتر نمایش می‌دهد.

۴-۱- بررسی کل شکل و رسیدن به ناحیه‌ی دریاچه

ابتدا الگوریتم LLE روی تصویر نمای Apical four-chamber در اکوکاردیوگرافی قفسه‌ی سینه پیاده‌سازی شده است (شکل



شکل (۳) - الف) نمای چهار حفره‌ای قلب، ب) دریاچه‌ی میترا

نمی‌دهد، اثبات شده است که سه ناحیه‌ی متراکم مینفلد با این سه فاز در سیکل قلبی مطابقت دارد (برای توضیحات کامل‌تر به مقاله‌ی [۱۵] رجوع شود). با بررسی این ویژگی در تصاویر سایر گروه‌ها مشاهده شده که در تصاویر مینفلد داده‌های گروه طبیعی این سه ناحیه‌ی متراکم در رئوس الگوی مثلث شکل قرار گرفته اما در داده‌های دارای اختلال، یا به طور کلی ساختار مثلثی دیده نشده و یا این که ساختار نسبتاً مثلثی وجود دارد اما نواحی ایزوولومتریکی به خوبی در تصاویر دیده نمی‌شود (شکل ۴). ساختار مینفلد داده‌های گروه‌های IIIa و IIIb دارای دو راس گوشه‌دار و یک راس خمیده است (شکل ۴-ج و د). در جدول (۱) نتایج بررسی این ویژگی در تمام نمونه‌های هر گروه به صورت کمی ارائه شده است.

۴-۲- بررسی تصاویر حاصل از الگوریتم LLE

یکی از نکاتی که در تصاویر حاصل از تعبیه‌ی الگوریتم LLE بررسی شده، شکل هندسی تصاویر مینفلد است. پس از بررسی نتایج گروه‌های مختلف، مشاهده شده که تصاویر مینفلد گروه طبیعی اکثراً دارای الگوی مثلثی با سه راس دارای نقاط متراکم است. برای توضیح این سه ناحیه از نتایج مقاله‌ی [۱۵] استفاده شده که در آن با هدف تعیین خودکار فریم‌های پایان دیاستول و پایان سیستول، الگوریتم LLE روی تصاویر اکوکاردیوگرافی اجرا شده است. در تصاویر مینفلد به دست آمده، سه ناحیه‌ی متراکم مشاهده شده که با علم به این که در یک چرخه‌ی قلبی در سه حالت مربوط به انقباض ایزوولومتریکی^۱، استراحت ایزوولومتریکی^۲ و دیاستاز^۳، تغییر محسوسی در حجم بطن^۴ رخ

جدول (۱) - بررسی ساختار شکل حاصل از پیاده‌سازی الگوریتم LLE روی تصاویر اکوکاردیوگرافی

گروه	کل نمونه‌ها	تعداد نمونه با ساختار مثلثی و سه ناحیه‌ی ایزوولومتریکی در رئوس	درصد	توضیحات
Normal	۵۰	۴۲	۸۴	ساختار مثلثی یا سه ناحیه‌ی متراکم در رئوس
II	۵۰	۳۴	۶۸	هم‌پوشانی نقاط در نواحی ایزوولومتریکی نسبت به گروه طبیعی کم‌تر است
III-a	۵۰	۱۵	۳۰	شکل دارای یک ضلع خمیده است
III-b	۵۰	۱۵	۳۰	شکل دارای یک ضلع خمیده است

^۱ Diastase

^۲ Ventricular Volume


^۱ Isovolumetric Contraction

^۲ Isovolumetric Relaxation




جدول (۲) - بررسی ساختار دارای تحدب در تصاویر حاصل از پیاده‌سازی الگوریتم LLE روی تصاویر اکوکاردیوگرافی


گروه	کل نمونه‌ها	تعداد نمونه با دو راس مثلثی و یک ضلع محدب	درصد
Normal	۵۰	۱۰	۲۰
II	۵۰	۸	۱۶
III-a	۵۰	۳۴	۶۸
III-b	۵۰	۲۰	۴۰




ب



الف



د



ج

شکل (۴) - بررسی ساختار شکل‌های حاصل از تعبیه‌ی منیفلد، الف) طبیعی، ب) گروه II، ج) گروه III-a، د) گروه III-b

۵-ب). با اتصال نقاط مربوط به سه ناحیه‌ی ایزوولومتریکی در هر شکل یک مثلث رسم شده تا میزان تقعر اندازه‌گیری شود. نتایج حاصل از اندازه‌گیری تقعر در چند نمونه در جدول (۴) ارائه شده است. در گروه‌های IIIa و IIIb نه تنها تقعر دیده نشده بلکه نقاط در این نواحی محدب هستند (شکل ۵-ج و د).

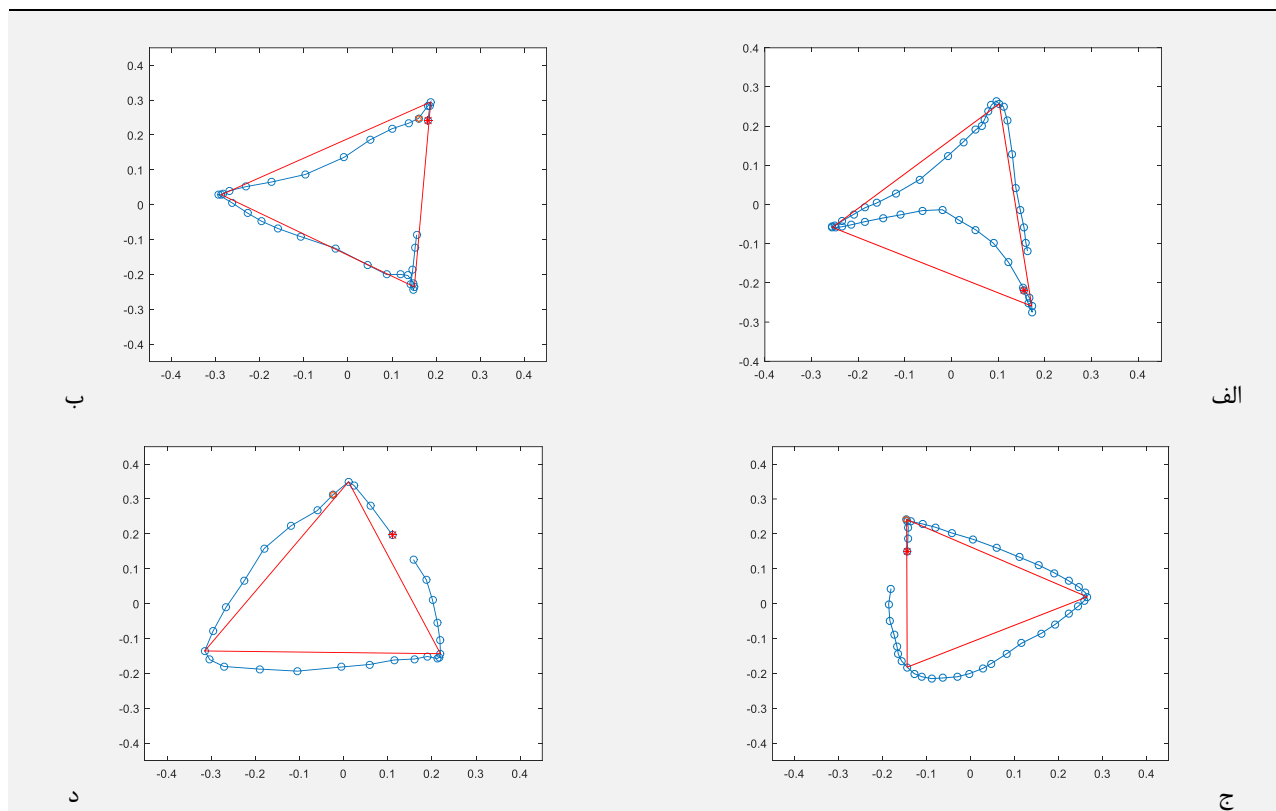
۴-۴- بررسی میانگین فواصل بین نقاط گروه IIIa و طبیعی

با دقت در شکل (۵-ج) مشاهده می‌شود که نقاط منیفلد در تصاویر گروه IIIa نسبت به سایر گروه‌ها به یک‌دیگر نزدیک‌تر است. نزدیک شدن نقاط از نظر پزشکی کاملاً توجیه علمی دارد. همان‌طور که پیش‌تر گفته شد، مشکل گروه IIIa تنگی دریاچه‌ی میترال بوده که علت اصلی آن عفونت باکتریایی حاصل از تب رماتیسمی است که در نتیجه‌ی آن دریاچه‌ی میترال باریک‌تر از حالت عادی بوده و در نتیجه جریان خون کاهش

۴-۳- بررسی تقعر و محاسبه‌ی فاصله‌ی آن با مثلث
پیش‌تر در بخش توضیحات مربوط به دستگاه جمع‌آوری پایگاه داده اشاره شد که فریم اول در داده‌های مورد استفاده‌ی این مقاله مطابق با فاز پایان دیاستول است که به صورت نقاط متراکم روی تصویر منیفلد مشخص می‌شود. از سوی دیگر با توجه به چرخه‌ی قلب و با استفاده از نتایج مقاله‌ی [۱۵] نقاط متراکم دوم مطابق با فاز پایان سیستول است [۱۵]. با بررسی تصاویر منیفلد مشاهده شده که نقاط منیفلد بین دو فاز پایان دیاستول و پایان سیستول، به سمت داخل تقعر دارند (شکل ۵-الف). در جدول (۳) نتیجه‌ی جامع بررسی این ویژگی در تمام داده‌ها ارائه شده است. از لحاظ پزشکی این تقعر را می‌توان با انقباض بطن در این زمان توجیه کرد. در تصاویر منیفلد داده‌های طبیعی میزان این تقعر از لحاظ عددی اندازه‌ی بیش‌تری دارد که نشان دهنده‌ی عمل‌کرد سالم قلب بوده اما در گروه II این تقعر از اندازه‌ی کم‌تری برخوردار است (شکل

است. همچنین از فواصل ۵۰ نمونه‌ی هر دو گروه میانگین گرفته شده و مشاهده شده که میانگین کلی این گروه نیز از میانگین گروه طبیعی کم‌تر است (جدول ۵).

می‌یابد [۱۶]. با محاسبه‌ی میانگین فاصله‌ی بین نقاط با استفاده از معیار فاصله‌ی اقلیدسی، مطابق جدول (۵) در اکثر نمونه‌های گروه IIIa میانگین فاصله‌ی بین نقاط کم‌تر از ۰/۰۳۵



شکل (۵) - بررسی تقعر در تصاویر حاصل از تعبیه‌ی منیفلد، الف) طبیعی، ب) گروه II، ج) گروه III-a، د) گروه III-b

جدول (۳) - تعداد نمونه‌های دارای نقاط مقعر در هر چهار گروه

گروه	کل نمونه‌ها	تعداد نمونه‌های دارای نقاط مقعر بین فاز پایان دیاستول و پایان سیستول	درصد	توضیحات
Normal	۵۰	۳۰	۶۰	-
II	۵۰	۱۹	۳۸	مقدار تقعر نقاط در این گروه نسبت به گروه طبیعی کم‌تر است
III-a	۵۰	۱۳	۲۶	نقاط این گروه در فاز مورد نظر بیش‌تر محدب هستند
III-b	۵۰	۶	۱۲	نقاط این گروه در فاز مورد نظر بیش‌تر محدب هستند

جدول (۴) - مقایسه‌ی حداکثر فاصله‌ی تقعر تا ضلع مثلث در چند نمونه از گروه طبیعی و گروه II

گروه	نمونه‌ی ۵	نمونه‌ی ۱۰	نمونه‌ی ۱۵	نمونه‌ی ۲۰	نمونه‌ی ۳۰	نمونه‌ی ۴۰
Normal	۰/۱۴۶۶	۰/۲۱۵۲	۰/۱۲۳۲	۰/۱۰۳۴	۰/۱۱۹۳	۰/۱۲۷۶
II	۰/۰۴۲۵	۰/۰۷۰۲	۰/۰۳۳۵	۰/۰۵۴۴	۰/۰۳۶۹	۰/۰۶۷۸

۴-۵- بررسی تعداد نقاط داخل و خارج مثلث

پس از رسم مثلث روی تصاویر حاصل از تعبیه‌ی منیفلد، با توجه به این که در گروه‌های دارای اختلال اکثر نقاط خارج از مثلث قرار گرفته، درصد نقاط داخل مثلث و خارج از مثلث در تمام نمونه‌های هر چهار گروه بررسی شده است. مطابق انتظار در گروه‌های دارای اختلال درجه بیش از ۷۰٪ نقاط و در برخی

جدول (۵) - میانگین فاصله‌ی بین نقاط

گروه	$s < 0/035$	$s > 0/035$	میانگین
III-a	٪۷۲	٪۲۸	۰/۰۲۹۴
Normal	٪۳۰	٪۷۰	۰/۰۴۰۸

S = میانگین فاصله‌ی بین نقاط در هر تصویر منیفلد



IIIb نقاط منیفلد خیلی به هم نزدیک نیستند. ضمناً در این گروه نیز مشابه گروه IIIa اکثر نقاط منیفلد خارج از مثلث قرار دارند. برای جداسازی گروه II، مواردی مانند مشخص نبودن نقاط ایزوولومتریکی در تصاویر منیفلد و نبود تقعر نقاط یا وجود تقعر با مقدار کم در فاز مربوطه می‌تواند مورد استفاده قرار گیرد. با توجه به نتایج به دست آمده چند نکته در قالب پیشنهاد بیان می‌شود که ممکن است برای کارهای تحقیقاتی آتی کمک کننده باشد. داده‌های این مقاله از نظر شدت بیماری دسته‌بندی نشده است و پیش‌بینی می‌شود که تعیین شدت اختلال می‌تواند به شناسایی بهتر داده کمک کند. برای مثال در گروه دارای اختلال تنگی دریچه‌ی میترال آگاهی از شدت این اختلال ممکن است در شناسایی داده‌های این گروه اثرگذار باشد. هم‌چنین در این مقاله در مورد جنسیت افراد اطلاعاتی در دسترس نبوده و دسته‌بندی داده‌ها از این جهت نیز ممکن است نتایج را تحت تاثیر قرار دهد.

۵-۱- نتیجه‌گیری

با توجه به تمام نکات بالا می‌توان گفت که با کمک الگوریتم LLE داده‌های طبیعی از گروه دارای اختلال به خوبی تشخیص داده شده و در دسته‌بندی گروه‌ها، گروه IIIa و IIIb با دقت خوبی تفکیک شده است اما این روش در جداسازی گروه II نتوانسته خیلی موفق عمل کند. نظر پزشک متخصص پس از مطالعه‌ی گزارش پژوهش این بوده که نکات و ویژگی‌های استخراج شده برای هر گروه قابل تامل بوده و ممکن است بررسی تعداد بیش‌تر داده‌های برجسب‌گذاری شده در کارهای آینده کمک کننده باشد و منجر به کسب نتایج دقیق‌تر شود.

۶- مراجع

- [1] G.Mensah , G.Roth , V. Fuster , “The Global Burden of Cardiovascular Diseases and Risk Factors: 2020 and Beyond”, Journal of the American college of cardiology, vol. 74, , no. 20, pp. 2529 –2532, November, 2020.
- [2] Gregory A Roth , George A Mensah , Catherine O Johnson, et al, “Global Burden of Cardiovascular Diseases and Risk Factors, 1990-2019: Update From the GBD 2019 Study”, Journal of the American college of cardiology, vol. 76, , no. 25, pp. 2982 –3021, December, 2020.
- [3] Maganti.K, Rigolin.V, Enriquez Sarano.M, and Bonow.R, “Valvular Heart Disease: Diagnosis and Management”, Mayo Clin Proc, vol. 85, no. 5, pp.483-500, 2010.
- [4] P.Gifani,H. Behnam, A.Shalbaf and Z.Alizadeh Sani, “Noise Reduction of Echocardiography Images Using Isomap Algorithm”, 1st Middle

نمونه‌ها حتی ۱۰٪ نقاط خارج از مثلث قرار دارند. در جدول (۶) درصد میانگین نقاط خارج از مثلث بین ۵۰ نمونه از هر گروه ارائه شده است.

جدول (۶) - میانگین نقاط خارج از مثلث

بین ۵۰ نمونه از هر گروه

گروه	میانگین نقاط خارج از مثلث
Normal	٪۵۲
II	٪۷۱
III-a	٪۸۲
III-b	٪۷۷

۵- یافته‌ها و بحث

هدف این مقاله این است که با استفاده از الگوریتم LLE، در گام اول داده‌های گروه طبیعی از داده‌های دارای اختلال جدا شده و در گام دوم ویژگی‌های گروه‌های دارای اختلال استخراج شود. مطالب مورد بررسی در این پژوهش شامل موارد زیر است. الف) بررسی ساختار شکل‌های حاصل از تعبیه‌ی منیفلد و نواحی سه‌گانه‌ی ایزوولومتریکی در گروه‌های مختلف ب) بررسی تقعر نقاط بین فاز پایان دیاستول و پایان سیستول ج) محاسبه‌ی میزان تقعر د) بررسی فاصله‌ی بین نقاط منیفلد و محاسبه‌ی میانگین فواصل بین نقاط در تمام گروه‌ها ه) بررسی نقاط داخل و خارج مثلث با بررسی تصاویر به دست آمده از تعبیه‌ی منیفلد روی تصاویر اکوکاردیوگرافی، به طور کلی می‌توان گفت که در گروه طبیعی ساختار تصاویر منیفلد اکثراً به شکل مثلث بوده و سه ناحیه‌ی ایزوولومتریکی در رئوس قرار دارد اما در گروه‌های دارای اختلال اغلب ساختار مثلثی دیده نشده و نواحی ایزوولومتریکی به خوبی مشخص نمی‌شود. در گام بعد با توجه به ویژگی‌های خاص هر گروه، به دسته‌بندی اختلالات پرداخته شده است. داده‌های گروه IIIa با توجه به چهار ویژگی شامل الگوی منیفلد متفاوت (دارای دو راس گوشه‌دار و یک راس خمیده)، فاصله‌ی نزدیک نقاط منیفلد، وجود تحدب در نقاط بین فاز پایان دیاستول و پایان سیستول و قرار گرفتن بیش از ۸۰٪ نقاط منیفلد در خارج از مثلث، با دقت خوبی قابل جداسازی از سایر گروه‌ها می‌باشند. در تصاویر به دست آمده از تعبیه‌ی منیفلد روی داده‌های گروه IIIb ساختار مثلثی و نقاط ایزوولومتریکی دیده نشده است. ساختار تصاویر این گروه مشابه گروه IIIa دارای دو راس گوشه‌دار و یک راس خمیده است. بر خلاف گروه IIIa، در گروه



- [11] Lawrence K. Saul, Sam T. Roweis, "An Introduction to Locally Linear Embedding", Journal of Machine Learning Research, 2003.
- [12] L. Saul, S. Roweis, "Think Globally, Fit Locally: Unsupervised Learning of Low Dimensional Manifolds", Journal of Machine Learning Research, Vol. 4, pp -119-155, 2003.
- [13] Robert O. Bonow, Patrick T. O'Gara, "2020 Focused Update of the 2017 ACC Expert Consensus Decision Pathway on the Management of Mitral Regurgitation", Journal of the American College of Cardiology, Vol. 75, No. 17, May, 2020.
- [14] A. Carpentier, "Cardiac valve surgery-the French correction", The Journal of THORACIC AND CARDIOVASCULAR SURGERY, vol. 86, no. 3, pp. 323-337, September, 1983.
- [15] P. Gifani, H. Behnam, A. Shalhaf and Z. Alizadeh Sani, "Automatic detection of end-diastole and end-systole from echocardiography images using manifold learning", PHYSIOLOGICAL MEASUREMENT, vol. 31, pp-1091-1103, May 2010.
- [16] Lawrence M. Tierney, Stephen J. McPhee, Maxine A. Papadakis "Current medical diagnosis and treatment", 45th Edition, San Francisco, October 19, 2006.
- East Conference on Biomedical Engineering, Sharjah, United Arab Emirates, INSPEC Accession Number: 11962136, April, 2011.
- [5] Sh. Ayesha, M. Kashif Hanif, R. Talib, R. "Overview and comparative study of dimensionality reduction techniques for high dimensional data", Information Fusion, vol. 59, pp. 44-58, January, 2020.
- [6] P. Gifani, H. Behnam, Z. Alizadeh Sani, "Analysis of Echocardiography Images using Manifold Learning", Iranian Journal of Biomedical Engineering, vol. 4, no. 2, pp. 149-160, 2010.
- [7] A. Izenman, "Introduction to manifold learning", WIREs Compute Stat, vol. 4, pp- 439-446, September/October, 2012.
- [8] K. Bhatia, A. Rao, A. Price, R. V. Hajnal, D. Rueckert, "Hierarchical Manifold Learning for Regional Image Analysis", IEEE transactions on medical imaging, vol. 33, no. 2, February, 2014.
- [9] Turaga, P., Anirudh, R., Chellappa, R., "Manifold Learning", Springer Nature Switzerland AG, K. Ikeuchi, Computer Vision, 2020.
- [10] Daniel D. Lee, Sebastian Mika, Bernhard Scholkopf, "A kernel view of the dimensionality reduction of manifolds", 21th International Conference of machine learning, Banff, Canada, July, 2004.