

Discovering Hidden Cluster Structures in Patients with Cirrhosis Based on Laboratory Data

Mina Pazouki¹, Mohammad Mehdi Sepehri², Mehdi Saberifiroozi³

¹ MSc, Department of Industrial Engineering, South branch Islamic Azad University, Tehran, Iran.

² Associate Professor, Department of Industrial Engineering, Faculty of Engineering, Tarbiat Modares University, Tehran, Iran

³ Professor, Digestive Disease Research Center, Shariati Hospital, Tehran University of Medical Sciences, Tehran, Iran.

ABSTRACT

Background:

Liver cirrhosis was one of the most important liver diseases. Other chronic liver diseases could lead to liver cirrhosis. Liver cirrhosis could be one kind of liver cancers named hepatocellular carcinoma. Cirrhosis in the early stages just by laboratory and imaging tests could be diagnosed. In this study cirrhotic patients were classified based on laboratory symptoms. For this purpose data mining approach has been used in this research. Data mining was an interdisciplinary science that discovers the hidden knowledge in the data.

Materials and Methods:

We used K-Means algorithm to categorize the statuses of cirrhotic patients. In order to determine the quality of clustering results and to find the best number of clusters, we have used silhouette indices.

Results:

Our data consists of 410 records which have been collected from Dr. Shariati hospital. The number of features in this study are .1 items and sampling were divided into two main groups.

Conclusion:

At first, we have done clustering based on 21 attributes and the average silhouette was 41 percent. We improved the model, in order to reach a reasonable structure. Finally, based on 7 attributes, a reasonable clustering model was derived. The new model provides 64 percent average silhouette, and based on patients' status, patients are divided into 2 main categories. The risk of HCC in the first cluster is 23 percent and in the second cluster is 14 percent.

Keywords: Liver cirrhosis; Data mining; clustering; K-means; Silhouette

please cite this paper as:

Pazoki M, Sepehri MM, Saberifiroozi M. Discovering hidden cluster structures in patients with cirrhosis based. *Govareh* 2014;18:191-7.

Corresponding author:

Mohammad Mehdi Sepehri, MD

Department of Industrial Engineering, Tarbiat

Modares University (TMU), Jalal-e Al-e Ahmad

Highway, Tehran 1411713114, Iran

Telefax: + 98 21 82883379

E-mail: mehdi.sepehri@gmail.com

Received: 05 May 2014

Edited: 11 Aug. 2014

Accepted: 12 Aug. 2014

کشف ساختارهای خوشای پنهان در بیماران مبتلا به سیروز کبدی بر پایه نشانه‌های آزمایشگاهی

مینا پازوکی^۱، محمد مهدی سپهری^۲، مهدی صابری فیروزی^۳

^۱ دانشجوی کارشناسی ارشد، دانشکده مهندسی صنایع، دانشگاه آزاد اسلامی واحد تهران جنوب، تهران، ایران

^۲ دانشیار، بخش مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، تهران، ایران

^۳ استاد، مرکز تحقیقات گوارش و کبد، بیمارستان دکتر شریعتی، دانشگاه علوم پزشکی تهران، تهران، ایران

چکیده

زمینه و هدف:

بیماری سیروز کبدی مهم ترین بیماری کبدی است که سایر بیماری‌های کبدی به صورت مزمن می‌توانند زمینه ساز بروز آن باشند و خود می‌تواند منشا ابتلا به سلطان کند شود. این بیماری درمان قطعی ندارد و تنها بر اساس آزمایش‌ها و تصویر برداری‌ها قابل تشخیص است. در این پژوهش جهت طبقه‌بندی وضعیت این بیماران بر اساس نشانه‌های آزمایشگاهی از رویکرد داده کاوی استفاده شده است. داده کاوی یک علم میان رشته‌ای است که به کشف دانش پنهان در داده‌ها می‌پردازد.

روش بررسی:

در این مطالعه با استفاده از رویکرد خوش‌بندی و الگوریتم k-means وضعیت بیماران را دسته بندی کردیم و برای تعیین کیفیت خوش‌بندی و پیدا کردن بهترین تعداد خوش‌بندی از شاخص سیلوئت استفاده شد.

یافته‌ها:

داده‌های ما شامل ۴۰ مورد بیماران مبتلا به سیروز کبدی می‌باشد که از بیمارستان دکتر شریعتی جمع آوری شده‌اند. تعداد مشخصه‌های مورد بررسی شامل ۲۱ مورد می‌باشد. در این مطالعه وضعیت بیماران مبتلا به سیروز کبدی به دو دسته اصلی تقسیم شد.

نتیجه گیری:

خوش‌بندی بر اساس ۲۱ مشخصه انجام شد و میانگین معیار سیلوئت ۴۱ درصد شد. اما با کاهش تعداد مشخصه‌ها در نهایت با در نظر گرفتن ۷ مشخصه به کیفیت خوش‌بندی قابل قبول با متوسط معیار سیلوئت ۶۴ درصد رسیدیم و وضعیت بیماران بر اساس نشانه‌های آزمایشگاهی به دو دسته تقسیم شد که احتمال ابتلای سلطان در خوش‌بندی اول ۲۳ درصد و در خوش‌بندی دوم ۱۴ درصد می‌باشد.

کلید واژه: سیروز کبدی، داده کاوی، خوش‌بندی، سیلوئت، K-means

تحقیقات پژوهشی در سال ۲۰۱۰ ثبت شد. امروزه یکی از مهم‌ترین کاربردهای داده کاوی در زمینه پژوهشی است و به پژوهشگران کمک می‌کند که به بینش عمیقی از مجموعه داده‌های پژوهشی دست پیدا کنند.^(۱) در سال های اخیر داده کاوی علاوه بر این که توانسته است در زمینه‌های مختلف پژوهشی در فرایند شناخت بیماری، تشخیص بیماری، پیش‌بینی روند بیماری، انتخاب روش درمان، پیش‌بینی طول مدت اقامت در بیمارستان، ارتباط بین بیماری‌ها و ارتباط بین داروها کمک شایانی به ارائه دهنده‌گان خدمات بهداشت و درمان ارائه نماید.^(۲-۷) به دلیل افزایش کیفیت خدمات بهداشتی و درمانی باعث کاهش ریسک‌های ناشی از تشخیص غلط بیماری و یا روش درمان و درنهایت کاهش هزینه و بهبود وضعیت سلامت بیماران شده است.

بر حسب این که در فرایند داده کاوی استنتاج چه نوع دانشی از مجموعه آموزشی مورد نظر است از روش‌های مختلف داده کاوی می‌توان

زمینه و هدف: داده کاوی^۱ به عنوان رویکرد کشف دانش در داده‌ها می‌کاود تا گنج نهان دانش را پیدا کند. داده کاوی در اوخر سال ۲۰۰۹ به عنوان موضوع

1. Data mining

نویسنده مسئول: محمد مهدی سپهری
تهران، بزرگراه جلال آل احمد، پل نصر، دانشگاه تربیت مدرس،
کد پستی ۱۴۱۱۷۱۳۱۱۴

تلفن و نمایر: ۰۲۱-۸۲۸۸۳۳۷۹
پست الکترونیک: mehdii.sepehri@modares.ac.ir

تاریخ دریافت: ۹۳/۲/۱۵
تاریخ اصلاح نهایی: ۹۳/۵/۲۰
تاریخ پذیرش: ۹۳/۵/۲۱

سیروز کبدی می‌تواند منجر به ابتلا به سلطان کبد شود که هپاتوسولار کارسینوما(HCC) رایج ترین نوع آن می‌باشد. بر اساس گزارش آژانس بین‌المللی تحقیقات سلطان، HCC در مردان پنجمین سلطان شایع در دنیاست و در زنان هفتمین سلطان شایع است.(۱۷) این سلطان سومین علت شایع مرگ و میر در اثر سلطان در دنیا می‌باشد.(۱۸) میزان ابتلای بیماران سیروتیک به HCC در غرب سالانه بین ۲ تا ۳ درصد و در خاور دور بین ۶ الی ۱۱ درصد می‌باشد.(۱۹)

در این پژوهش به کمک رویکرد خوشبندی به دنبال دسته بندی وضعیت بیماران سیروز کبدی بر اساس نشانه‌های آزمایشگاهی آن‌ها هستیم. که می‌تواند به درک پزشکان از وضعیت بیماری بیماران بر اساس چند مورد از نشانه‌های آزمایشگاهی و تصمیم‌گیری آن‌ها در فرایند درمان تأثیر به سزاپی داشته باشد.

روش بررسی: معرفی داده‌ها:

کل داده‌های جمع آوری شده شامل ۴۱۰ رکورد است که از بیماران مبتلا به سیروز مراجعه کننده به بیمارستان دکتر شریعتی جمع آوری شده است. داده‌های جمع آوری شده مربوط به سال‌های ۸۹ تا ۹۲ می‌باشند و ۵۰ مورد از این بیماران در طی این ۴ سال به HCC مبتلا شدند. تعداد مشخصه‌ها ۲۱ مورد است که در جدول ۱ معرفی شده‌اند.

آماده سازی داده و پیش پردازش:
اغلب به دلیل خطاها عملياتی و پیاده سازی سیستم‌ها، داده‌های به دست آمده پر غلط، ناقص و ناسازگارند. بنابراین نیاز است که در ابتدا این داده‌ها تمیز شوند که این کار با اجرای مراحل پیش پردازش داده‌ها و در طی مراحل زیرانجام شد:

الف) پاکسازی داده‌ها:

پاکسازی داده در واقع مرحله کنترل کیفی قبل از تحلیل داده است. در این پژوهش قبل از انجام عملیات پیش پردازش کلیه داده‌ها از نظر صادق بودن با مقادیر امکان پذیر کنترل شده اند و مقادیر اشتباه اصلاح شده‌اند. و هم چنین رکوردهایی از داده‌ها که بسیاری از مشخصه‌های آن‌ها خالی بود و یا اعداد اشتباه وارد شده بودند حذف شدند و در این مرحله تعداد کل رکوردهای ما به ۳۶۴ مورد رسید.

پر کردن مقادیر مفقوده:

در این مرحله برای پر کردن مقادیر از دست رفته از الگوریتم دسته بندی k نزدیک ترین همسایگی^۱ استفاده شد و بر اساس تعداد ۳ نزدیکترین همسایگی و مدن آن‌ها، مقادیر مفقود شده پر شدند. علت انتخاب عدد ۳ این بود که انتخاب تعداد کمتر ممکن است روش را متأثر 7. K-Nearest Neighbor (KNN)

بهره جست. این روش‌ها از نظر شیوه یادگیری به دو دسته اصلی تقسیم می‌شوند.(۸)

الف-الگوریتم‌های یادگیری با نظارت

ب-الگوریتم‌های یادگیری بدون نظارت

در روش‌های داده کاوی مبتنی بر الگوریتم‌های یادگیری با نظارت هدف از داده کاوی مشخص است و در حقیقت تحلیل گر می‌داند که به دنبال چه دانشی می‌گردد. برخلاف آن در روش‌های مبتنی بر یادگیری بدون نظارت، هدف از کشف دانش کاملاً تعریف شده نیست.(۹)

خوشبندی یک تکنیک داده کاوی است که از رویکرد یادگیری غیر ناظارتی برای تحلیل داده‌ها استفاده می‌کند.(۱۰) داده‌ها بر اساس اصل حداقل کردن شباهت داخل گروه‌ها و حداقل کردن شباهت بین گروه‌ها، خوشبندی می‌شوند. خوشبندی با پیدا کردن روابط پنهان در داده‌ها که برای پیدا کردن الگوها و پیش‌بینی وقایع آینده یا تبدیل رکوردهای داده‌ها به خوشبندی معنی دار مفید است، به ارزش پایگاه داده‌های موجود می‌افزاید.(۱۱)

موضوع مورد بحث در این پژوهش از حوزه بهداشت و سلامت، بیماری سیروز کبدی^۱ است. سیروز کبدی یکی از جدی ترین بیماری‌های کبدی است که تقریباً تمام بیماری‌های کبدی اگر منجر به از بین رفتن سلول های کبدی شوند می‌توانند به سیروز تبدیل شوند.(۱۲) این بیماری در اثر التهاب مزمن بافت کبد ایجاد می‌شود که به دلایل گوناگونی اتفاق می‌افتد. هر گونه التهابی به صورت کم یا زیاد باعث تخریب بافت کبد می‌شود. در اثر ادامه این فرایند به طور مزمن و مکرر، ساختار منظم و یک شکل کبد در هم می‌ریزد و به تدریج بافت کبد سفت می‌شود. فعالیت‌های احیا کننده تحت سیروز کبدی ادامه می‌باشد ولی سرعت پیشرفت از دست دادن سلول های بیش از جایگزینی آنها است.(۱۳) علل عدمه سیروز کبدی شامل هپاتیت B، هپاتیت C و هپاتیت اتوایمیون^۲ است. ولی داروها و مواد سمی، کبد چرب، بیماری ویلسون، تنگی مجرای صفر اوی، مشکلات قلبی و انسداد وریدهای کبدی از علل دیگر این بیماری می‌باشند.(۱۴) در مرحله اولیه، بیماری هیچ گونه نشانه‌ای ندارد و تنها با آزمایش‌های دقیق و بررسی‌های رادیولوژیکی و بافت شناسی قابل تشخیص است.(۱۴) به تدریج که بیماری پیشرفت می‌کند نشانه‌ها و عوارض بیماری نیز افزایش می‌باشد. از مهم ترین نشانه‌های سیروز کبدی آسیت^۳ و تجمع مایع در شکم، آنسفالوپاسی کبدی^۴، واریس مری^۵ و خونریزی واریس^۶ یا عوارض دیگری که بر روی سیستم قلب و عروق، ریه‌ها و کلیه‌ها ایجاد می‌کند، می‌باشد.(۱۵) درمان بیماری سیروز کبدی بر اساس درمان بیماری زمینه‌ای آن می‌باشد و درمان قطعی ندارد(۱۶).

1. Liver Cirrhosis
2. Autoimmune hepatitis
3. Ascites
4. Encephalopathy
5. Varices
6. Varical bleeding

کشف ساختارهای خوش‌های در بیماری سیروز کبدی

جدول ۱: مشخصه‌های مورد بررسی

شماره	مشخصه	مشخصه	مشخصه	مشخصه	مشخصه	مشخصه	مشخصه	مشخصه	مشخصه	مشخصه
۹	Serum Albumin	ALT	AST	WBC	Platelet	BMI	Weight	Height	Age	شماره
۸	۱۸	۱۷	۱۶	۱۵	۱۴	۱۳	۱۲	۱۱	۱۰	شماره
۷	Cholesterol	TG	FBS	INR	BUN	Creatinine	BilirubinD	BiLirubinT	Alkph	مشخصه
۶							۲۱	۲۰	۱۹	شماره
۵							k	Na	AFP	مشخصه
۴										
۳										
۲										
۱										

جدول ۲: تفسیر مقادیر میانگین معیار سیلوئت (۱۶)

میانگین معیار سیلوئت	تفسیر
ساختار قوی	۰/۷۱-۱
ساختار منطقی (مناسب)	۰/۵۱-۰/۷
ساختار ضعیف	۰/۲۵-۰/۵
هیچ ساختار قابل توجهی وجود ندارد	<۰/۲۵

از داده‌های مغذیش کرده و مقدار بزرگتر آن هم ممکن است رفتارهای نزدیک تر را در نظر نگیرد.(۸)

K-means الگوریتم :

پارامتر k (تعداد خوش‌های) را به عنوان ورودی گرفته و مجموعه‌ی n شیء را به k خوش‌های افزایی کند. به طوری که سطح شباهت داخلی خوش‌های بالا بوده و سطح شباهت اشیا بین خوش‌های پایین باشد. شباهت هر خوش‌های نسبت به متوسط اشیا آن خوش‌های سنجیده شده که این متوسط مرکز خوش‌های نیز نامیده می‌شود.(۱۶)

اعتبار سنجی خوش‌های:

شاخص‌های اعتبار سنجی برای سنجش میزان صحبت نتایج خوش‌بندی به منظور مقایسه بین روش‌های خوش‌بندی مختلف مختلاف مقدارهای مقایسه‌ی نتایج

حاصل از یک روش با پارامترهای مختلف مورد استفاده قرار می‌گیرند. دو معیار پایه‌اندازه‌گیری پیشنهاد شده برای ارزیابی و انتخاب خوش‌های بهینه عبارتند از:

تراکم^۱: داده‌های متعلق به یک خوش‌های باقیستی تا حد ممکن به یکدیگر نزدیک باشند. معیار رایج برای تعیین میزان تراکم داده‌ها واریانس داده‌ها است.

جدایی^۲: خوش‌های خود باقیستی به اندازه کافی از یکدیگر جدا باشند. در این پژوهش از شاخص اعتبار سنجی سیلوئت^۳ استفاده شده است که در ادامه مختصراً تشریح می‌شود:

شاخص سیلوئت: یکی از معیارهای متداول اعتبار سنجی خوش‌بندی است. دو معیار فواصل درون خوش‌هایی و برون خوش‌های را هم‌زمان در نظر می‌گیرد.(۱۷) جدول ۲ تفسیر مقادیر مختلف معیار سیلوئت را نشان می‌دهد:

یافته‌ها:

در ابتدا مدل سازی بر اساس ۲۱ مشخصه جدول ۱-۳ و بر اساس الگوریتم K-means انجام شد. شکل ۱ نتایج با توجه به نمودار سیلوئت در شکل ۱، در این مرحله متوسط کیفیت خوش‌های مدل خوش‌های بندی را

1. Compactness
2. Separation
3. Silhouette

شناسایی نقاط پرت:

جهت شناسایی نقاط پرت از الگوریتم خوش‌بندی K-means استفاده شد. داده‌های به ۴ خوش‌های تقسیم شدند و ۲۰ داده‌ی پرت شناسایی و حذف شدند. در این مرحله تعداد داده‌های ما به ۳۴۴ مورد رسید.

ب) یکپارچه سازی داده:

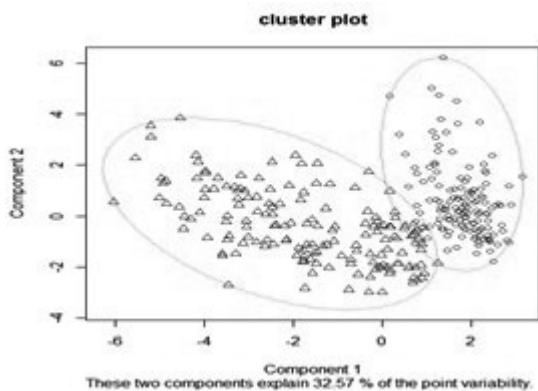
این عملیات شامل یکپارچه سازی چندین پایگاه داده است. که در این جا داده‌های مربوط به بیمارستان شریعتی و بیمارستان امام خمینی در یک فایل اکسل مرتب شدند.

ج) تبدیل داده:

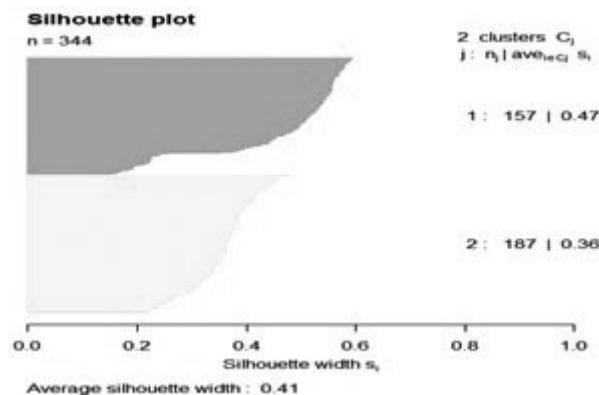
در این مرحله فرایند نرمال سازی روی داده‌ها انجام شد. نرمال سازی تغییر مقیاس داده‌ها به گونه‌ای است که آن‌ها را به یک فاصله‌ی کوچک و معین نگاشت می‌کند و باعث می‌شود که داده‌ها با مقیاس بزرگ نتایج را به سمت خود منحرف نکنند. در این پژوهش با استفاده از روش Min-Max (۸) نرمال سازی داده‌های کمی که شامل مشخصه‌های نتایج آزمایشگاهی بود انجام شد و داده‌ها در بازه عددی بین صفر و یک قرار گرفتند.

مدل سازی:

روش مدل سازی در این پژوهش بر اساس الگوریتم افزایی K-means می‌باشد.



ب



الف

شکل ۱: (الف) نمودار معیار سیلوئت برای دو خوشها، (ب) شکل خوشها.

جدول ۳: مشخصه های مربوط به مدل با ۷ مشخصه

	۷	۶	۵	۴	۳	۲	۱	شماره
K	Na	AFP	Creatinine	Serum Albumin	ALT	AST		مشخصه

ها را به دو دسته طبقه بندی کنیم. جدول ۴-۲ متوسط مقدار هر مشخصه را در هر خوشها نشان می دهد.

براساس نتایج فوق وضعیت بیماران به دو دسته تقسیم شد که با توجه به جدول ۴ به طور متوسط خوشاهی ۱ وضعیت بدتری را نسبت به AST, ALT, AFP, Na, K خوشاهی ۲ نشان می دهد و ۷ مشخصه ای، Creatinine و Serum Albumin در بین نشانه های آزمایشگاهی در نظر گرفته شده برای تعیین وضعیت بیماران از اهمیت بالاتری برخوردارند.

بحث:

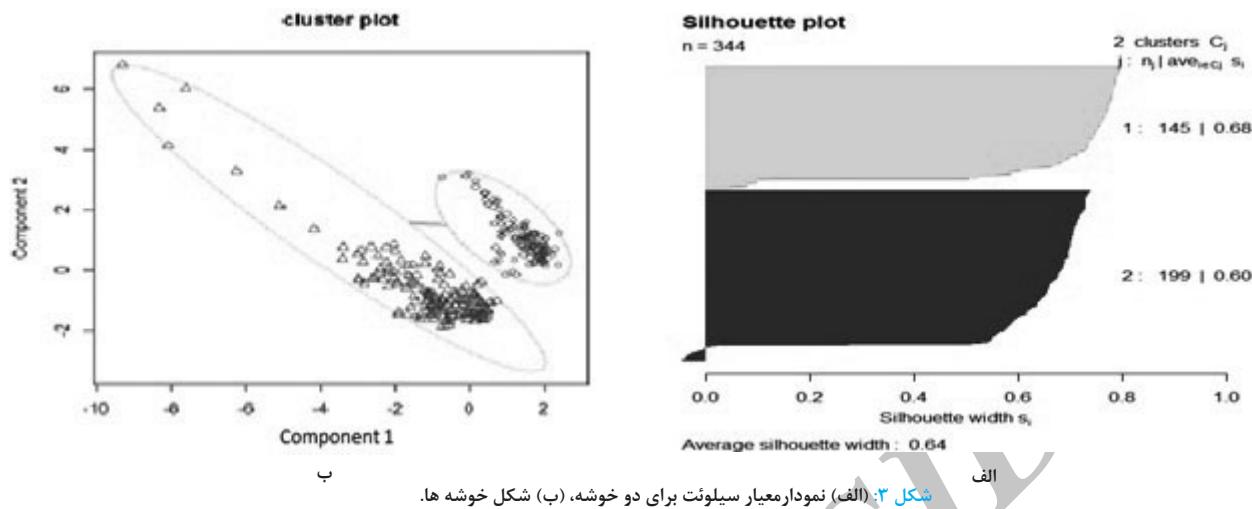
بیماری سیروز کبدی مهم ترین بیماری کبدی است که سایر بیماری های کبدی به صورت مزمن می توانند زمینه ساز بروز آن باشند و خود می توانند منشا ابتلا به سرطان کند شود. در این پژوهش جهت بررسی مهمنه ترین نشانه های آزمایشگاهی در تعیین وضعیت بیماران مبتلا به سیروز کبدی و دسته بندی وضعیت آن ها به کمک رویکرد خوشاهی غیر نظارتی و بر اساس رفتار داده ها، از رویکرد خوشاهی بندی استفاده کردیم. برای این منظور نتایج آزمایش مربوط به ۴۰ بیمار مبتلا به سیروز کبدی در نظر گرفته شد و وضعیت بیماران مبتلا به سیروز کبدی را بر اساس نشانه های آزمایشگاهی آنها و رویکرد خوشاهی بندی که یک رویکرد کاملاً غیر نظارتی است تقسیم بندی نمودیم. کلیه نشانه های آزمایشگاهی در نظر گرفته شده در این مطالعه بر اساس نتایج آزمایش اولین مراجعه بیماران می باشد ولی آنژیم های کبدی TLA و TSA به علت این که در اثر مصرف داروها و بیماری های عفونی و بیماری های ایسکمیک و... مقادیرشان تغییر می کند،

نشان می دهد. ها ۴۱ درصد است. که بر اساس جدول ۳-۲ این خوشاهی بندی ضعیف است.

نمودار شکل ۲ روند تغییرات معیار سیلوئت با درنظر گرفتن تعداد خوشاهی مختلف را مشخص می کند که بهترین تعداد خوشاهی در این مرحله ۲ می باشد. با کاهش تعداد مشخصه ها و حذف مشخصه های ناسازگار مدل خوشاهی بندی بهبود پیدا کرد و در نهایت به مدلی با ۷ مشخصه معرفی شده در جدول ۳ رسیدیم. نتایج مدل خوشاهی بندی در این مرحله در شکل ۳ آورده شده است:

بر اساس نمودار سیلوئت در شکل ۳ برای تعداد دو خوشاهی، متوسط کیفیت خوشاهی بندی ۶۴ درصد است و در این مدل، خوشاهی بندی ما در محدوده ۱ قابل قبول قرار می گیرد. شکل ۴ نمودار روند معیار سیلوئت با درنظر گرفتن تعداد خوشاهی های مختلف را نشان می دهد. بر اساس شکل ۴ بهترین تعداد خوشاهی در این مرحله ۲ می باشد. بنابراین با درنظر گرفتن نشانه های آزمایشگاهی بیماران مبتلا به سیروز کبدی توانستیم وضعیت آن

کشف ساختارهای خوش‌های در بیماری سیروز کبدی

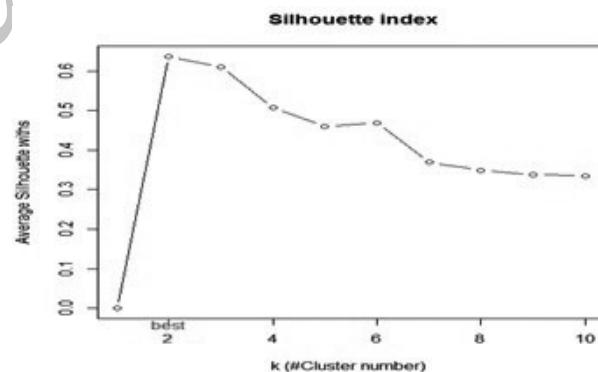


جدول ۴: میانگین مقادیر مشخصه‌ها در خوش‌های مختلف

Creatinine	Serum Albumin	K	Na	AFP	ALT	AST	مشخصه
۲	۱	۲	۱	۲	۱	۲	خوش
۱	۱/۲	۳/۵	۳	۴	۴/۵	۱۳۸/۸	۱۳۰

مشخصه	خوش	میانگین
	۶۶/۹	۸۷/۴

خوش‌بندی ضعیف بود. با حذف مشخصه‌های ناسازگار کیفیت خوش‌بندی بهبود یافت و در نهایت با در نظر گرفتن ۷ مشخصه به کیفیت خوش‌بندی قابل قبول با میانگین معیار سیلوئت ۶۴ درصد رسیدیم و وضعیت بیماران بر اساس ۷ مورد از نشانه‌های آزمایشگاهی به دست آمده در این مرحله به دو دسته تقسیم شد. دسته اول با توجه به نشانه‌های در نظر گرفته شده وضعیت بدتری را نشان می‌دهد هم چنین این رویکرد نشان می‌دهد Serum Albumin ، K.Na ، AFP ALT AST که ۷ مشخصه‌ی Creatinine در بین نشانه‌های آزمایشگاهی در نظر گرفته شده برای تعیین وضعیت بیماران از اهمیت بالاتری برخوردارند. در نتیجه‌ی مقایسه‌ی میزان ابتلا به سرطان در دو گروه بسته آمده، ملاحظه شد احتمال ابتلا به سرطان در گروه اول ۲۲/۶۹ درصد و در گروه دوم ۱۴ درصد می‌باشد بنابراین ریسک ابتلا به سرطان در گروه اول به میزان تقریباً ۹ درصد بالاتر می‌باشد. بر این اساس به علت این که داده‌های ما مربوط به رفتار ۴ سال بیماران می‌باشد، احتمال ابتلا به سرطان در گروه اول به طور سالانه حدود ۵/۶ درصد و در گروه دوم حدود ۳/۵ درصد می‌باشد. بر اساس این نتایج می‌توانیم نتیجه‌گیری کنیم که اگر نشانه‌های آزمایشگاهی بیماری در محدوده گروه اول قرار گیرد احتمال ابتلا به سرطان در این گروه بالاتر می‌باشد و باید درمان‌های جدی تری برای آن‌ها در نظر گرفت. تمرکز این تحقیق بر روی داده کاوی و کاربرد آن در مورد آزمایش‌های روتین بیماران سیروتیک بوده که مرتباً در مورد این بیماران انجام می‌شود



شکل ۴: نمودار روند میزان تغییرات معیار سیلوئت برای تعداد خوش‌های مختلف.

میانگین آن‌ها در آزمایش‌های مربوط به هر بیمار در نظر گرفته شد. در رویکرد خوش‌بندی اطلاعات گذشته درباره میزان اهمیت نشانه‌ها و داده‌ها در نظر گرفته نمی‌شود و مدل خودش به طور کاملاً غیر نظرارتی و بر اساس رفتار داده‌ها، نشانه‌های مهم را پیدا می‌کند و دسته بندی را بر اساس آن‌ها انجام می‌دهد. برای انجام خوش‌بندی از الگوریتم K-means استفاده شد و بر اساس شاخص اعتبارسنجی سیلوئت کیفیت خوش‌بندی و بهترین تعداد خوش‌های را پیدا کردیم. در ابتدا خوش‌بندی بر اساس ۲۱ مشخصه انجام شد که میانگین معیار سیلوئت در این حالت ۴۱ درصد بود و ساختار

HCC و هم چنین این که مقدار آنزیم های AST و ALT در اثر عوامل مختلف بسیار تغییر پذیر می باشند و این که نتایج آزمایش بیماران مربوط به آزمایشگاه های مختلف است و می تواند خطاهایی را به همراه داشته باشد، ضعف هایی دارد. از نقاط قوت این پژوهش می توان به این که اولین پژوهشی است که به کاربرد داده کاوی در بیماری سیروز کبدی پرداخته است و این که در ایران اولین پژوهشی است که به طور متوالی داده های مربوط به چهار سال بیماران سیروتیک را مورد بررسی قرار داده است، اشاره کرد.

گرچه انجام این آزمایش ها تاثیر فوری برای مراقبت از بیماران دارد ولی تاثیر این آزمایش ها در عاقبت بیماران و مراقبت طولانی مدت آنها کاملاً مشخص نمی باشد. بنابراین در این پژوهش هدف تنها بررسی وضعیت بیماران بر اساس نشانه های آزمایشگاهی بوده است و هم چنین کشف غیر نظارتی نشانه های مهم در تعیین وضعیت بیماران و باید صحت نتایج آن در مورد بیماران جدید که به درمانگاه ها مراجعه می کنند بررسی شود. این مطالعه، یک مطالعه مقدماتی است که می تواند در تحقیقات آتی با در نظر گرفتن نشانه های بالینی بیماران توسعه داده شود.

این پژوهش به علت کم بودن تعداد داده ها و تعداد بیماران مبتلا به

REFERENCES

- Yoo I, Alafaireet P, Marinov M, Pena-Hernandez K, Gopidi R, Chang JF, et al. Data mining in healthcare and biomedicine: a survey of the literature. *J Med Syst* 2012;36:2431-48.
- Anunciação O, Gomes BC, Vinga S, Gaspar J, Oliveira AL, Rueff J. A Data Mining Approach for the Detection of High-Risk Breast Cancer Groups. *Adv Bioinformatics* 2010;74:43-51.
- Gauthier E, Brisson L, Lenca P, Ragusa S. Breast cancer risk score: a data mining approach to improve readability. *International Conference on Data Mining* 2011:15-21.
- Bhatla N, Jyoti, K. An Analysis of Heart Disease Prediction using Different Data Mining Techniques. *International J Engineering* 2012;1:8.
- Agrawal A, Misra S, Narayanan R, Polepeddi L, Choudhary A. A lung cancer outcome calculator using ensemble data mining on SEER data. In Proceedings of the Tenth International Workshop on Data Mining in Bioinformatics 2011:5.
- Kaur AR. A Study of Detection of Lung Cancer Using Data Mining Classification Techniques. *International J* 2013; 3(3).
- Ahmed K, Jesmin T, Zamilur Rahman M. Early Prevention and Detection of Skin Cancer Risk using Data Mining. *International J Computer Applications* 2013;62:1-6.
- Han J, Kamber M, Pei J. Data mining: concepts and techniques. Morgan kaufmann 2006.
- Marinakis Y, Marinaki M, Matsatsinis N. A stochastic nature inspired metaheuristic for clustering analysis. *International J Business Intelligence Data Mining* 2008;3:30-44.
- Wagstaff K, Cardie C, Rogers S, Schrödl S. Constrained k-means clustering with background knowledge. *ICMI* 2001 ;1:577-84.
- Suh SC, Saffer S, Adla NK. Extraction Of Meaningful Rules In A Medical Database. Seventh International Conference 2008:450-6.
- Rajeswari P, Reena G. Analysis of Liver Disorder Using Data mining Algorithm. *Global J Computer Science Technology* 2010;10:4.
- D'Amico G, Garcia-Tsao G, Pagliaro L. Natural history and prognostic indicators of survival in cirrhosis: a systematic review of 118 studies. *J Hepatol* 2006;44:217-31.
- Singh V, Nagpal S. A Guided clustering Technique for Knowledge Discovery—A Case Study of Liver Disorder Dataset. *International J of Computing Business Research* (1).
- Asrani SK, Kim WR. Organ allocation for chronic liver disease: model for end-stage liver disease and beyond. *Curr Opin Gastroenterol* 2010;26:209-13.
- Rousseeuw PJ. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *J computational applied Mathematics* 1987;20:53-65.
- El-Serag HB. Epidemiology of viral hepatitis and hepatocellular carcinoma. *Gastroenterology* 2012;142:1264-73.
- Pietrangelo A, Dohil R, Newbury R, Fox L, Bastian J, Aceves S. Reviews Basic Cline Gastroenterology.
- Chiaramonte M, Stroffolini T, Vian A, Stazi MA, Floreani A, Lorenzoni U, et al. Rate of incidence of hepatocellular carcinoma in patients with compensated viral cirrhosis. *Cancer* 1999;85:2132-7.