



دانشکده مهندسی

پایان‌نامه کارشناسی ارشد در رشته مهندسی کامپیوتر (هوش مصنوعی)

بهبود دقت طبقه‌بندی با استفاده از روش‌های انتخاب خصیصه‌ی ترکیبی

توسط:

فاطمه علیمردانی

استاد راهنما:

دکتر رضا بوستانی

شهریور ۱۳۸۸

به نام خدا

اطهارنامه

اینجانب سید علیرضا (۸۵۹۸۷) دانشجوی رشته
忿یم کامپیوتر گرایش هوش مصنوعی دانشکده برق و کامپیوتر
اطهارمی کنم که این بایان نامه حاصل پژوهش خودم بوده و در جاهایی که
از منابع دیگران استفاده کرده‌ام، نشانی دقیق و مشخصات کامل آن را
نوشتدم. همچنین اظهارمی کنم که تحقیق و موضوع پایان نامه‌ام تکراری
نیست و تعهد می‌نمایم که بدون مجوز دستاوردهای آن را منتشر
نموده و یا در اختیار غیر قرار ندهم. کلیه حقوق این اثر مطابق با آیین‌نامه
مالکیت فکری و معنوی متعلق به دانشگاه شیراز است.

نام و نام خانوادگی: سید علیرضا

تاریخ و امضا: ۱۴۰۰/۰۶/۲۸

به نام خداوند جان و خرد

به نام خدا

بهبود دقت طبقه بندی با استفاده از روش های انتخاب خصیصه تر کیبی

به وسیله‌ی :

فاطمه علیمردانی

پایان نامه

ارائه شده به معاونت تحصیلات تکمیلی دانشگاه به عنوان بخشی از
فعالیت‌های تحصیلی لازم برای اخذ درجه کارشناسی ارشد

در رشته‌ی:

مهندسی کامپیوتر - گرایش هوش مصنوعی

از دانشگاه شیراز

شیراز

جمهوری اسلامی ایران

ارزیابی شده توسط کمیته پایان نامه با درجه: عالی

دکتر رضا بوسانی، استادیار بخش مهندسی کامپیوتر (رئيس کمیته)

دکتر منصور ذوالقدری جهرمی دانشیار بخش مهندسی کامپیوتر (ناظم اسناد)

دکتر کربیم رسنگار استادیار دانشکده پژوهشی دانشگاه علوم پزشکی شیراز

دکتر احمد غنی زاده، دانشیار دانشکده پژوهشی دانشگاه علوم پزشکی شیراز

شهریور ۱۳۸۸



به:

آنهايى كە بە من آموختند حتى يك كلمە.

سپاسگزاری

در پایان این مسیر پر فراز و نشیب، که کولهباری از تجربه‌های گران‌بها را برایم به ارمغان آورده است، به طور خاص از استاد راهنمای محترم آقای دکتر رضا بوستانی، به خاطر صبوری‌ها و راهنمایی‌های ارزنده‌شان سپاسگزارم. همچنین از استاد بزرگوارم جناب آقای دکتر کریم رستگار، جناب آقای دکترا حمید غنی زاده و آقای دکتر منصور ذوالقدر جهرمی که در طول این مدت از حمایت‌های ایشان برخوردار بوده‌ام کمال تشکر را دارم.

از تمامی دوستان به خصوص خانم خدیجه سادات نژاد و کلیه کادر بخش مهندسی و علوم کامپیوتر دانشگاه شیراز که با این جانب همکاری صادقانه داشتند، تشکر می‌کنم و یک سپاس ویژه از بیماران محترمی که در انجام آزمایشات این تحقیق همکاری بی‌دریغی داشته‌اند دارم و برای تک تک آنها سلامت و شادی روز افزون آرزومندم.

چکیده

بهبود دقت طبقه بندی با استفاده از روش های نوین ترکیبی انتخاب خصیصه

به وسیله‌ی:
فاطمه علیمردانی

در سال‌های اخیر، کاراتر سازی روش‌های انتخاب خصیصه به صورت رو به رشد مورد توجه بوده‌اند. تحقیقات انجام شده به منظور کاهش هزینه‌ی محاسبات و همچنین کاهش ریسک تطابق بیش از حد مطالعه شده‌اند. در راستای کاهش بعد خصیصه‌ها از بین همه‌ی الگوریتم‌ها روش‌های پیشرونده به دلیل هزینه‌ی محاسباتی کم بسیار کارا هستند. در این رساله دو الگوریتم پیشرونده‌ی جدید بر اساس مقدار افزایش اطلاعاتی که با حضور هر خصیصه خواهیم داشت ارائه شده است. این الگوریتم‌ها سعی دارند خصیصه‌های حاوی بیشترین اطلاعات را یافته و انتخاب کنند. از طرف دیگر با غلبه بر محدودیت‌های الگوریتم‌های ترتیبی پیشرونده و پسرونه سعی می‌کنند زیرمجموعه‌ای را انتخاب کنند که خصیصه‌های آن بیشترین استقلال را داشته باشند. برای بررسی میزان خوبی خصیصه‌هایی که انتخاب می‌شوند از طبقه بندی کننده‌ی نزدیکترین همسایه استفاده شده است. این طبقه بند وابسته به معیار فاصله‌ای که برای یافتن نزدیکترین همسایه به کار می‌برد می‌باشد. در همین راستا یک نسخه‌ی تصحیحی برای حذف این وابستگی پیشنهاد شده است که از رای گیری بین سه فاصله نتیجه‌ی خود را برای نمونه‌ی آزمایشی اعلام می‌کند. نتایج، بهبود قابل توجه صحت طبقه بندی نسبت به روش‌های شناخته شده راروی داده‌های UCI نشان می‌دهند. دلیل این بهبود، کارایی الگوریتم‌های جدید معرفی شده است و از سویی دیگر طبقه بند پیشنهادی تصمیم پایدارتر و ثابت‌تری در انتخاب کلاس نمونه‌ی آموزشی نسبت به نسخه‌ی استاندارد آن می‌گیرد. در یک آزمایش دیگر روش‌های پیشنهادی در تشخیص دو دسته بیماری روانی (دو قطبی و اسکیزوفرنی) که در پزشکی تشخیص کمی روی آن‌ها وجود ندارد به کار برده شده است. این مطالعه آماری روی این دو بیماری برای اولین بار ارائه شده است.

فهرست مطالب

صفحه	عنوان
۱.....	-۱ مقدمه -۱
۱	۱-۱- انتخاب خصیصه
۳	۱-۲- ارزیابی یک زیر مجموعه از خصیصه ها
۳	۱-۲-۱- معیارهای مستقل
۴	۱-۲-۲- معیارهای وابستگی
۹.....	-۲ مروری بر روش های استخراج خصیصه از سیگنال -۲
۱۱	۲-۱- سیگنال های EEG
۱۲	۲-۲- تست پاسخ محرک بینایی
۱۲	۲-۳- ثبت سیگنال
۱۸	۲-۴- روش های استخراج خصیصه
۱۹	۲-۴-۱- مدل خودبازگشتنی
۲۱	۲-۴-۲- کورتوفسیس
۲۲	۲-۴-۳- بعد فراکتالی و هندسه فراکتالی
۲۳	۲-۴-۴- ۱- مولفه های لیاپانوف
۲۷	۲-۵- فیلترینگ
۲۸.....	-۳ مروری بر روش های گسترش ای -۳
۲۸	۳-۱- مقدمه
۲۸	۳-۲- معرفی گسترش ای
۲۹	۳-۳- روش های موجود
۳۱	۳-۴- ارزیابی نتایج گسترش ای
۳۲	۳-۵- چهار چوب گسترش ای
۳۳	۳-۶- روش های تقسیم کردن
۳۴	۳-۶-۱- بخش بندی
۳۷	۳-۶-۲- معیار انتروپی

۴۰	۳-۶-۳- معیار وابستگی
۴۱	۴-۶-۳- معیار دقت
۴۲	۷-۳- روش‌های ادغام کردن
۴۲	۷-۳-۱- معیار مربع کای
۴۳	۲-۷-۳- روش Chi Merge
۴۳	۳-۷-۳- روش Chi ²
۴۵	۸-۳- تکنیک گسسته‌سازی بر اساس معیار فیشر
۴۵	۱-۸-۳- معرفی معیار فیشر
۴۶	۲-۸-۳- الگوریتم گسسته سازی بر اساس فیشر
۴۸	۴- مروری بر روش‌های انتخاب خصیصه
۴۸	۱-۴- مقدمه
۴۹	۲-۴- الگوریتم جستجوی تبو
۵۳	۳-۴- پلاس. ال. ماینس. آر
۵۳	۴-۴- اف. سی. بی. اف
۵۴	۱-۴-۴- ارتباط خطی
۵۵	۲-۴-۴- اطلاعات متقابل
۵۹	۵-۴- شاخص دیویس بولدین
۶۳	۶-۴- رتبه بندی متغیرها
۶۳	۱-۶-۴- اصول متند و علامت گذاری ها
۶۳	۲-۶-۴- شرایط همبستگی
۶۴	۷-۴- مثالهای کوچک اما راه گشا
۶۵	۱-۷-۴- آیا متغیرهای اضافی فرضی به همدیگر کمک می‌کنند؟
۶۶	۲-۷-۴- چگونه همبستگی بر افزونگی متغیرها تاثیر می گذارد؟
۶۷	۳-۷-۴- آیا متغیری که به تنها یی مفید نیست در کنار بقیه متغیرها سودمند است؟
۶۹	۸-۴- روش‌های انتخاب خصیصه‌ی توکار(تو در تو)
۶۹	۱-۸-۴- متدهای زیرمجموعه های تودر تو
۷۰	۲-۸-۴- بهینه سازی اهداف مستقیم
۷۱	۹-۴- مقولات پیشرفته و مسائل باز
۷۱	۱-۹-۴- واریانس زیرمجموعه های انتخاب شده
۷۱	۲-۹-۴- معیار انتخاب خصیصه در مسائل بدون ناظر
۷۲	۳-۹-۴- انتخاب پیشرو در مقابل انتخاب عقبگرد
۷۳	۱۰-۴- مسائل چند کلاسی

۷۴	-۵ طبقه بندی کننده
۷۴	۱-۵ مقدمه
۷۵	۲-۵ طبقه بند بیز ساده
۷۶	۳-۵ طبقه بند نزدیکترین همسایه
۸۱	-۶ روش‌های پیشنهادی و نتایج تجربی
۸۱	۱-۶ مقدمه
۸۱	۲-۶ روش‌های پیشنهادی
۸۱	۱-۲-۶ الگوریتم حریصانه بر اساس ارتباط کلی خصیصه‌ها
۸۶	۲-۲-۶ الگوریتم سریع کاهش ویژگی با استفاده از شاخص دیویس بولدین
۸۸	۳-۶ مجموعه داده‌های سیگنال
۹۰	۱-۳-۶ روش شکاف آماری (گپ استاتیک)
۹۱	۲-۳-۶ روش ارزیابی Silhouette
۹۴	۳-۳-۶ خوش بندی تفاضلی
۹۹	۴-۶ داده‌های استاندارد
۱۰۴	-۷ نتیجه‌گیری و کارهای آینده
۱۰۴	۱-۷ نتیجه‌گیری
۱۰۴	۲-۷ کارهای آینده
۱۰۶	-۸ مراجع

فهرست جداول

عنوان	صفحة
جدول ۱- نقاط گسستگی داده‌ی با روش پهنانی مساوی	۳۵
جدول ۲- نقاط گسستگی داده‌ی Iris با روش فراوانی مساوی	۳۵
جدول ۳- نقاط گسستگی در روش ۱R	۳۶
جدول ۴- مقایسه سه روش بخش بندی	۳۷
جدول ۵- مقایسه نتایج سه روش با آزمون مریع کای	۴۴
جدول ۶ - تعداد خصیصه‌های انتخاب شده توسط روش‌های مختلف.	۹۰
جدول ۷- دقت نتیجه شده از NN استاندارد در مقایسه با NN ^{پیشنهادی}	۹۵
جدول ۸- دقت طبقه بند پیشنهادی بر روی هر کدام از خصیصه‌ها به تنها	۹۷
جدول ۹- نتایج انتخاب خصیصه NN+ استاندارد و NN معرفی شده روی داده‌های نویزی	۹۷
جدول ۱۰ - مشخصات مجموعه داده‌های UCI به کار رفته در این رساله	۱۰۰
جدول ۱۱ - نتایج طبقه بندی کننده‌ی پیشنهادی روی خصیصه‌های انتخاب شده مختلف	۱۰۱
جدول ۱۲ - نتایج طبقه بندی کننده‌های مختلف روی خصیصه‌های انتخابی GOR	۱۰۳

فهرست شکل‌ها

صفحه	عنوان
۵	شکل ۱- دسته بندی روش‌های انتخاب خصیصه [1]
۱۳	شکل ۲- مکان الکتروودها در سیستم ۲۰-۱۰
۱۵	شکل ۳- الف) نمونه‌ای از سیگنالهای ضبط شده (الف) دوقطبی، ب) اسکیزوفرنی
۱۷	شکل ۴- طبیف توان نمونه‌های از هر دو نوع بیماری به کمک Color Map، الف) دو قطبی، ب) اسکیزوفرنی
۲۰	شکل ۵- مدلسازی AR [77]
۲۰	شکل ۶- یک نمونه سیستم خطی [76]
۲۲	شکل ۷- الف) یک عملگر ساده فرکتال و اثر متوالی آن بر یک پاره خط. ب) یک شکل فرکتال مصنوعی [80].
۲۶	شکل ۸- منحنی جمع همبستگی بر حسب شعاع کره برای یک سیگنال غیر نویزی.
۳۳	شکل ۹- چهارچوب سلسله مراتبی گستته سازی [25]
۳۶	شکل ۱۰- مثال عملی مراحل انجام روش R
۴۷	شکل ۱۱- فلوچارت تکنیک گستته سازی با معیار فیشر [74]
۴۸	شکل ۱۲- چهار گام کلیدی در فرایند انتخاب خصیصه [21]
۵۱	شکل ۱۳- شمای کلی الگوریتم تبو [15]
۵۲	شکل ۱۴- شبیه کد الگوریتم تبو [20]
۵۴	شکل ۱۵- شبیه کد الگوریتم پلاس. ال. ماینس. آر [83]
۵۹	شکل ۱۶- شبیه کدالگوریتم اف. سی. بی. اف [10]
۶۱	شکل ۱۷- کارایی روش‌های مختلف انتخاب خصیصه تحت شرایط خاص [5]
۶۵	شکل ۱۸- اطلاعات به دست آمده از متغیرهای اضافی فرضی
۶۶	شکل ۱۹- تاثیر همبستگی بر افزونگی داده‌ها
۶۹	شکل ۲۰- بررسی مفید بودن متغیرها در همکاری با هم.
۷۳	شکل ۲۱- بررسی انتخاب عقبگرد و پیشرو
۷۷	شکل ۲۲- مثالی از عملکرد NN با $k=5$
۷۹	شکل ۲۳- کانتورهایی از فاصله‌های مساوی [28]
۸۶	شکل ۲۴- الگوریتم حریصانه بر اساس ارتباط کلی خصیصه‌ها.

٨٨	شکل -٢٥ - شبیه کد الگوریتم DB-FFR
٩٣	شکل -٢٦ - مقدار Silhouett برای هر دو دسته بیماری
٩٦	شکل -٢٧ - مقایسه نرخ تشخیص بین دو بیماری با الگوریتم های مختلف انتخاب
٩٨	شکل -٢٨ - دقت روشاهای مختلف انتخاب + NN معرفی شده روی داده های نویزی
١٠٢	شکل -٢٩ - مقایسه روشاهای مختلف انتخاب خصیصه با طبقه بند پیشنهادی
١٠٣	شکل -٣٠ - مقایسه نتیجه های GOR با استفاده از طبقه بند های مختلف

فهرست اختصارات

ABBREVIATION	MEANING
AR	Auto Regressive
BMD	Bipolar Mode Disorder
DB	Davies Boildin
DB-FFR	Davies Bouldin Fast Feature Reduction
GOR	Greedy Overall Relevancy
MNN	Modified Nearest Neighbor
ONR	Overall Normalize Relevancy
R-N-R	Relevant-Non- Redundant

فصل اول

مقدمه

۱ - مقدمه

۱-۱ - انتخاب خصیصه

جمع آوری داده با انجام آزمایش کار بسیار ساده و راحتی است. داده ها با سرعت بی سابقه ای گرد آوری و ذخیره می شوند که بسیار بیشتر از سرعت پردازش انسان است بنابراین پیش پردازش این داده های تل انبار شده به منظور استخراج یک مجموعه داده کاراتر امر بسیار مهمی در مسائل یادگیری ماشین و داده کاوی به شمار می رود. انتخاب خصیصه از رایج ترین تکنیکهای کارایی آن در برخورد با مجموعه داده های بزرگ در بسیاری از مسائل یادگیری ماشین از قبیل: طبقه بندی، خوشه سازی و داده کاوی از سال ۱۹۷۰ ثابت شده است [1,2,3,4]. روشهای انتخاب خصیصه در دو دسته‌ی کلی یادگیری ماشین یعنی روشهای همراه با ناظر و نیز روشهای بدون ناظر به کار برده شده‌اند اما در این رساله ما توجه خود را به مسائل همراه با ناظر (طبقه بندی) متمرکز کرده‌ایم که در آنها برچسب کلاس هر کدام از داده‌ها از ابتدا در مسئله مشخص است. پس یک مرور کلی بر روشهای انتخاب خصیصه در مسائل طبقه بندی کننده در این رساله انجام می‌شود. برای هر کدام از روشها مهمترین زمینه‌های کاربردی بازنگری خواهد شد و در پایان یک روش جدید ارائه خواهد شد تا در حالیکه سعی دارد فواید روشهای قبلی را به ارت ببرد با دقت بهتری خصیصه‌های بهینه را گزینش کند.

انتخاب یک زیر مجموعه از خصیصه‌ها به دو موضوع برای بررسی نیازمند است: ۱- یک الگوریتم و استراتژی جستجو کننده برای انتخاب خصیصه‌های کاندید و ۲- یک تابع هدف برای ارزیابی خصیصه‌های کاندید تا میزان خوبی این کاندیدها مشخص شود. از طرفی باید نشانه‌ای از مقدار ارزیابی شده توسط تابع هدف، به عنوان بازخورد به الگوریتم جستجو کننده باز گردانده شود تا در انتخاب کاندیدهای بعدی در نظر گرفته شود. الگوریتم‌های جستجو گربه طور کلی به سه دسته تقسیم می‌شوند: الف) الگوریتم‌های نمایی^۱، ب) الگوریتم‌های ترتیبی^۲ و الگوریتم‌های تصادفی^۳. و از طرفی الگوریتم‌های ترتیبی خود به دو گروه روش‌های پیشرونده^۴

¹ exponential Algorithms

² Sequential Algorithms

³ Randomized Algorithms

⁴ Forward

و پسرونده^۵ دسته بندی می‌شوند. روش‌های پسرونده کار خود را با مجموعه‌ای با حضور تمام خصیصه‌ها شروع می‌کند و سپس به طور ترتیبی خصیصه‌هایی که بیشترین کاهش در تابع هدف را موجب می‌شوند از این مجموعه حذف می‌کند. و روش‌های پیشروندۀ ابتدا مجموعه جواب را خالی فرض می‌کند و گام به گام در هر مرحله خصیصه‌ای را به جواب اضافه می‌کند که بیشترین تغییر را در مقدار تابع هدف موجب می‌شود.

بطور کلی توابع هدف مورد استفاده در روش‌های انتخاب خصیصه در دو دسته قرار می‌گیرند[32]: فیلترها^۶ و رپرها^۷. در رویکرد فیلتر، انتخاب بهترین زیرمجموعه از خصیصه‌هادر واقع یک مرحله پیش‌پردازش است و بعداً خصیصه‌ها برای طبقه بندی به الگوریتم‌های یادگیری ماشین داده می‌شوند. این روش بر اساس یک معیار از پیش تعیین شده می‌باشد که مستقل از کارایی خصیصه‌های انتخاب شده در افزایش دقت طبقه بند استفاده شده است. هر چند رویکرد فیلتر زمان اجرای کمتری لازم دارد اما این عیب را دارد که به طبقه بندی کننده مورد استفاده در فاز بعدی مسئله توجه نمی‌کند. در حالیکه در رویکرد رپر، همکنش بین مجموعه خصیصه انتخاب شده و طبقه بندی کننده به طور خاص مورد توجه روش جستجو در خصیصه‌ها قرار می‌گیرد. به عبارتی رپرها یک ماشین یادگیری خاص برای جستجو زیرمجموعه خصیصه مناسب بکار می‌برند. ماشین یادگیری روی یکی از زیرمجموعه خصیصه‌های موردنظر آموزش داده می‌شود و درجه دقت یادگیرنده در طبقه بندی داده‌ها به عنوان معیار ارزیابی زیرمجموعه ای از خصیصه‌های کاندید بازگردانده می‌شود. این مرحله برای همه‌ی زیرمجموعه‌های کاندید از خصیصه‌ها تکرار می‌شود تا جایی که بهترین زیرمجموعه خصیصه یافته شود. رویکرد رپر توسط John Kohavi معرفی شد، و بطور کلی می‌تواند طبقه‌بندی کننده‌ای نهایی با دقت پیشگویی خوب تولید کند[32]؛ اما رویکرد رپر در مقایسه با روش فیلتر هزینه‌ی محاسباتی بیشتری دارد و احتمال داشتن مشکل انطباق بیش از حد^۸ را افزایش می‌دهد[33,34]. بنابراین در بسیاری کاربردها، روش‌های فیلتر نسبت به رپر ترجیح داده می‌شوند.

معیار انتخاب خصیصه نقش حیاتی در روش‌های فیلتر بازی می‌کند. در مبحث طبقه‌بندی، این معیار سعی در اندازه‌گیری توانایی یک خصیصه یا یک مجموعه خصیصه برای جدا کردن کلاس‌های مختلف دارد. تا به حال معیارهای مختلفی مانند معیارهای فاصله، وابستگی، و سازگاری برای انتخاب خصیصه بکار رفته‌است[35,36-37]. ولی این معیارها ممکن است به مقادیر قطعی داده‌های آموزشی بسیار حساس باشند؛ در نتیجه آنها به راحتی تحت تاثیر نویز^۹ یا داده‌های بیرونی^{۱۰} قرار می‌گیرند. در حالیکه معیارهای اطلاعات، از قبیل انتروپی^{۱۱} یا

⁵ Backward

⁶ Filter approach

⁷ wrapper

⁸ Over-fitting

⁹ Noise

¹⁰ Outliers

اطلاعات متقابل، میزان اطلاعات یا عدم قطعیت یک خصیصه را برای طبقه‌بندی بررسی می-کنند. بر تئوری اطلاعات [Shannon^{38, 39}، مدلی که مقدار اطلاعات را افزایش ندهد بی-فایده تلقی می‌شود و انتظار نمی‌رود دقت پیشگویی آن بهتر از تنها یک حدس تصادفی باشد^[40]. یکی از محسن معیار میزان اطلاعات یک خصیصه این است که این معیار تنها به توزیع احتمال یک متغیر تصادفی وابسته است، نه به مقادیر قطعی آن. معیارهای اطلاعات بطور وسیع برای انتخاب خصیصه مورد استفاده قرار گرفته‌اند^[42, 41]، از قبیل بسیاری الگوریتم‌های یادگیری مانند [43]. یکی از این معیارها اطلاعات متقابل^{¹²} می‌باشد.

۱-۲-۱- ارزیابی یک زیرمجموعه از خصیصه‌ها

در همه کاربردها، به منظور ارزیابی یک زیرمجموعه از خصیصه‌ها میزان خوبی این زیرمجموعه توسط یک معیار معین به دست می‌آید. معیارهای ارزیابی به طور وسیع با توجه به وابستگی آنها به الگوریتم کاوشی که بعداً روی زیرمجموعه انتخاب شده عمل خواهد کرد در دو گروه دسته بندی می‌شوند: معیارهای مستقل^{¹³} و معیارهای وابسته^{¹⁴}.

۱-۲-۱- معیارهای مستقل

معیارهای مستقل عموماً در الگوریتم‌های فیلتر استفاده می‌شوند. این معیارها سعی دارند میزان خوبی یک خصیصه را با بهره‌گیری از ویژگیهای ذاتی داده‌های آموزشی و بدون در نظر گرفتن الگوریتم‌های کاوش اندازه گیری کنند.

برخی معیارهای مستقل عبارتند از مقیاس فاصله، مقدار اطلاعات، مقدار همبستگی و میزان سازگاری یا انطباق^[5,6]. مقیاس فاصله با نامهای دیگری مثل مقدار جدایی، انحراف و کجی یا مقدار تشخیص پذیری نیز به کار برده شده است. از آنجا که در یک مسئله دو کلاسه هدف یافتن خصیصه‌ای است که کلاس‌ها را تا حد امکان از هم جدا کند، خصیصه X نسبت به خصیصه Y ارجح است اگر با در نظر گرفتن خصیصه X فاصله بیشتری بین احتمال شرطی کلاس‌ها ایجاد شود. یک خصیصه را غیر قابل تمیز دادن می‌گوییم اگر فاصله بین کلاس‌ها در حضور آن صفر شود. معیار مقدار اطلاعات معمولاً میزان افزایش اطلاعات را معین می‌کنند. میزان افزایش تفاوت بین عدم قطعیت از پیش مشخص شده در داده‌ها وقتی خصیصه X را

¹¹ Entropy

¹² Mutual information

¹³ Independent Criteria

¹⁴ Dependency Criteria

استفاده می‌کنیم و عدم قطعیت پسین با حضور خصیصه X است. هرچه مقدار اطلاعات یک خصیصه بیشتر باشد مطلوب تر است پس در هر مرحله خصیصه با مقدار اطلاعات بیشتر انتخاب می‌شود.

معیارهایی نیز به عنوان اندازه‌ای از همبستگی و شباهت شناخته شده‌اند و در واقع توانایی پیش‌بینی کردن یک مقدار از مقادیر دیگر را اندازه می‌گیرند. در مسئله انتخاب خصیصه برای طبقه بندی ما به دنبال خصیصه‌هایی هستیم که بیشترین همبستگی را با برچسب کلاس هر داده دارد. و در مسئله انتخاب خصیصه برای خوش‌سازی داده‌ها، میزان شباهت بین دو خصیصه مد نظر قرار می‌گیرد.

معیارهای سازگاری مشخصه‌های متفاوتی نسبت به معیارهای دکر شده دارند. این معیارها به داده‌های کلاس متکی هستند [6] و سعی می‌کنند مینیمم تعداد خصیصه‌ای را پیدا کنند که مطابق با وقتی که همه خصیصه‌ها را در نظر می‌گیریم بتواند کلاس‌ها را از هم جدا کند. عدم انطباق دو خصیصه به معنی این است که علیرغم داشتن مقدار یکسان در این خصیصه‌ها دو برچسب متفاوت بر اساس آنها انتخاب شود.

۱-۲- معیارهای وابستگی

در رپرها از معیارهای همبستگی استفاده می‌شود و لازم است یک الگوریتم کاوش از قبل تعریف شده داشته باشند. رپرها اغلب کارایی بستری دارند چون خصیصه‌هایی که برای این الگوریتم کاوش مناسب ترند را پیدا می‌کنند ولی در عوض هزینه محاسباتی زیادی دارند و در ضمن ممکن است برای الگوریتم‌های کاوش دیگر، کارایی آنها کاهش پیدا کند.

همه‌ی روش‌های انتخاب خصیصه گفته شده به یک معیار یا شرط برای توقف کار نیاز دارند.

معیار توقف معمولاً یکی از موارد زیر است:

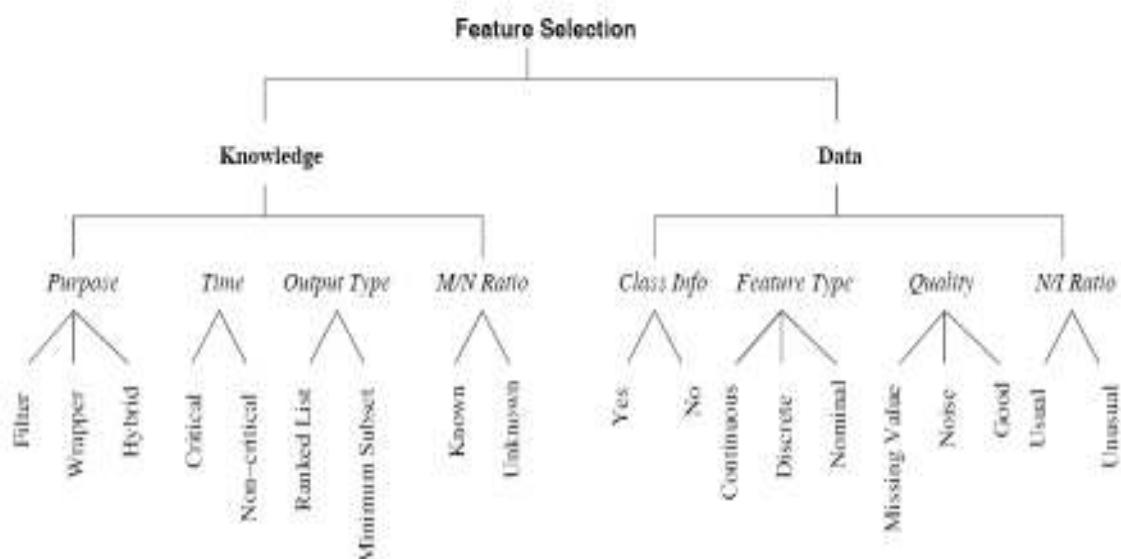
۱- جستجو کامل شده باشد،

۲- یک حد بالایی مشخصی مرتفع شده است (به عنوان مثال به مینیمم تعداد خصیصه‌ها رسیده‌ایم و یا به ماکزیمم تعداد تکرار)،

۳- دیگر اضافه یا حذف کردن خصیصه‌ی بعدی تاثیری بر کارایی مجموعه خصیصه انتخاب شده تاکنون ندارد و

۴- وقتی که یک زیر مجموعه‌ی به اندازه کافی خوب از خصیصه‌ها انتخاب شده باشد. در نهایت پس از انتخاب زیر مجموعه‌ای از خصیصه‌ها با یکی از روش‌های مورد نظر وقت آن است که این مجموعه را ارزیابی کنیم. یک راه ساده برای ارزیابی نتایج آن است که مستقیماً

با استفاده از اطلاعاتی که از قبل راجع به داده‌ها داریم نتیجه را مقدار سنجی کنیم. اگر از قبل خصیصه‌های مرتبط و مطرح در جواب بهینه را بدانیم می‌توانیم این مجموعه معین را با مجموعه انتخاب شده مقایسه کنیم. اینکه اطلاعاتی درباره خصیصه‌هی غیر مرتبط و افزونه داشته باشیم هم می‌تواند مفید باشد. زیرا انتظار داریم این خصیصه‌ها انتخاب نشوند. البته در کاربردهای دنیای واقعی معمولاً این دانش را از قبل راجع به خصیصه‌ها نداریم بنابراین باید کار را به طور غیر مستقیم دنبال کنیم، به این ترتیب که بر میزان تغییر در کارایی الگوریتم کاوش (طبقه بند یا خوشه ساز) وقتی خصیصه‌ها ی شرکت کننده را تغییر می‌دهیم نظارت کنیم. مثلاً اگر نرخ خطای طبقه بندی را به عنوان مشخص کننده کارایی عمل کاوش انتخاب کنیم می‌توانیم به سادگی این نرخ را قبل و بعد از اضافه یا حذف یک خصیصه حساب کنیم.[5]. در نمودار ۱ یک قالب دسته بندی از روش‌های انتخاب خصیصه آمده است.



شکل ۱- دسته بندی روش‌های انتخاب خصیصه[1]

همان‌طور که می‌بینید دو فاکتور اصلی دانش از قبل مشخص شده و داده‌ها هستند. دانش خود شامل: هدف، زمان مورد نظر، نوع خروجی و نرخ $\frac{M}{N}$ است که در آن M تعداد مورد انتظار برای زیر مجموعه‌ای که می‌خواهیم انتخاب کنیم و N تعداد کل مجموعه اصلی خصیصه-