

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشکده مهندسی برق و رباتیک

گروه الکترونیک

شناسایی چهره با استفاده از تصاویر سه بعدی

دانشجو: ابوالفضل عرب

استاد راهنما:

دکتر امید رضا معروضی

پایان نامه ارشد جهت اخذ درجه کارشناسی ارشد

زمستان ۱۳۹۲



مدیریت تحصیلات تکمیلی  
فرم شماره (۶)

بسمه تعالی

شماره : ۹۲/۱۱/۲۶

تاریخ : ۹۲/۱۱/۲۶

ویرایش : -----

فرم صورت جلسه دفاع پایان نامه تحصیلی دوره کارشناسی ارشد

با تأییدات خداوند متعال و با استعانت از حضرت ولی عصر (عج) جلسه دفاع از پایان نامه کارشناسی ارشد خانم / آقای :  
**ابوالفضل عرب** رشته : برق  
 گرایش : الکترونیک (سیستم)  
 تحت عنوان : شناسایی چهره با استفاده از تصاویر سه بعدی  
 که در تاریخ ۹۲/۱۱/۲۶ با حضور هیأت محترم داوران در دانشگاه صنعتی شاهرود برگزار گردید به شرح زیر است :

قبول (با درجه : **بسیار خوب** امتیاز **۱۸.۵۵**)  دفاع مجدد  مردود

۱- عالی (۲۰ - ۱۹)

۲- بسیار خوب (۱۸ - ۱۸/۹۹)

۳- خوب (۱۶ - ۱۷/۹۹)

۴- قابل قبول (۱۴ - ۱۵/۹۹)

۵- نمره کمتر از ۱۴ غیر قابل قبول

| عضو هیأت داوران                 | نام و نام خانوادگی | مرتبه علمی | امضاء |
|---------------------------------|--------------------|------------|-------|
| ۱- استاد راهنما                 | ایرین سرریش        | استاد      |       |
| ۲- استاد مشاور                  | ---                | ---        | ---   |
| ۳- نماینده شورای تحصیلات تکمیلی | علیرضا ابراهیمی    | استاد      |       |
| ۴- استاد ممتحن                  | مهدیه غلامی        | استاد      |       |
| ۵- استاد ممتحن                  | مهدیه جلالی        | استاد      |       |

رئیس دانشکده :

شکر شایان نثار ایزد منان که توفیق را رفیق راهم ساخت تا این پایان نامه را به پایان برسانم . از استاد فاضل و اندیشمند جناب آقای دکتر معروضی به عنوان استاد راهنما که همواره نگارنده را مورد لطف و محبت خود قرار داده اند ، کمال تشکر را دارم.

این پایان نامه را ضمن تشکر و سپاس بیکران و در کمال افتخار و امتنان تقدیم می نمایم به:

-محضر ارزشمند پدر و مادر عزیزم به خاطر همه ی تلاشهای محبت آمیزی که در دوران مختلف زندگی ام انجام داده اند.

-به استادان فرزانه و فرهیخته ای که در راه کسب علم و معرفت مرا یاری نمودند.

-به آنان که در راه کسب دانش راهنمایم بودند.

-به آنان که نفس خیرشان و دعای روح پرورشان بدرقه ی راهم بود.

-الها به من کمک کن تا بتوانم ادای دین کنم و به خواسته ی آنان جامه ی عمل بپوشانم.

-پروردگارا حسن عاقبت ، سلامت و سعادت را برای آنان مقدر نما.

-خدایا توفیق خدمتی سرشار از شور و نشاط و همراه و همسو با علم و دانش و پژوهش جهت رشد و شکوفایی ایران کهنسال عنایت بفرما.

یا رب دل مارا تو به رحمت جان ده      درد همه را به صابری درمان ده

این بنده چه میداند که چه باید جست      داننده تویی هر آن چه دانی آن ده

# تعهد نامه

اینجانب ابوالفضل عرب دانشجوی دوره کارشناسی ارشد رشته الکترونیک سیستم دانشکده مهندسی برق و رباتیک دانشگاه صنعتی شاهرود نویسنده پایان نامه با عنوان :

شناسایی چهره با استفاده از تصاویر سه بعدی

تحت راهنمایی جناب دکتر امیدرضا معروضی متعهد می شوم .

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است .
- در استفاده از نتایج پژوهشهای محققان دیگر به مرجع مورد استفاده استناد شده است .
- مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است .
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید .
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت می گردد.
- در کلیه مراحل انجام این پایان نامه ، در مواردی که از موجود زنده ( یا بافتهای آنها ) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است .
- در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاق انسانی رعایت شده است .

## تاریخ

## امضای دانشجو

## مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج ، کتاب ، برنامه های رایانه ای ، نرم افزار ها و تجهیزات ساخته شده است ) متعلق به دانشگاه صنعتی شاهرود می باشد . این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود .

## چکیده فارسی

یکی از روشهای بیومتریک برای شناسایی افراد، استفاده از ویژگی های چهره است. در این روش با توجه به این که نیازی به ارتباط فیزیکی با فرد وجود ندارد از لحاظ اجتماعی نیز مورد توجه قرار گرفته است. سیستم های مدرن شناسایی چهره دو بعدی، در شرایط یکنواخت و کنترل شده بسیار خوب عمل می کنند با این حال، تغییرات در نورپردازی تصویرها و حالات مختلف چهره از مشکلات پیش روی این روش ها است. در مقابل، تصاویر سه بعدی می توانند اشیاء را بدون در نظر گرفتن شدت نور به وضوح نمایش دهند.

در این تحقیق تلاش بر این است که با استفاده از اطلاعات تصویر سه بعدی (اطلاعات عمق) کارایی سیستم های شناسایی چهره را در شرایط نامساعد، از قبیل نورپردازی، ژست و حالات کنترل نشده، بهبود ببخشیم. این تحقیق بر روی پایگاه داده (GAVAB) با تصویرهایی که شامل انواع وضعیت های نامطلوب در شناسایی چهره از قبل خندیدن، نگاه به بالا و پایین، چرخش سر به چپ و راست و همچنین حالت های تصادفی چهره است انجام شده است.

روش های پیاده شده در این تحقیق در دو گروه روش های کل نگر و جزء نگر دسته بندی می شوند. در روش های کل نگر، ما از سه ویژگی عمق، انحنای میانگین و انحنای گوسی استفاده کرده ایم. بهترین نتیجه به دست آمده در روش های کل نگر مربوط به ویژگی انحنای میانگین با دقت ۹۱.۰۹ درصد می باشد. مزیت این روش ساده بودن پیاده سازی و سرعت بالای اجرای آن می باشد.

در روش های جزءنگر ما از ویژگی های الگوی باینری محلی کامل (CLBP)، الگوی باینری مبتنی بر واریانس (LBPV)، الگوی باینری مبتنی بر انحنای گوسی (LBPK) و الگوی باینری محلی مبتنی بر

انحنای میانگین (LBPH) استفاده کرده ایم. در روش های بین روش های جزء نگر بهترین نتیجه مربوط به روش LBP\_S/M/C با دقت ۹۶.۴۷ درصد می باشد. همچنین در این تحقیق دو روش استخراج ویژگی جدید (LBPH, LBPK) نیز ارائه شده است.

**کلمات کلیدی:** شناسایی چهره سه بعدی، پایگاه داده GAVAB، ویژگی های کل نگر، ویژگی های جزء نگر

|    |  |
|----|--|
| ۱  | مقدمه                                  |
| ۲  | ۱-۱ پیش گفتار                          |
| ۲  | 1-2 شناسایی چهره                       |
| ۴  | ۳-۱ مشکلات شناسایی با تصاویر دو بعدی   |
| ۸  | ۴-۱ تصاویر سه بعدی                     |
| ۹  | ۱-۴-۱ تصاویر سه بعدی در مغز انسان      |
| ۱۱ | ۲-۴-۱ تصاویر سه بعدی در سینما          |
| ۱۲ | ۵-۱ شناسایی چهره با تصویر سه بعدی      |
| ۱۵ | ۲: مروری بر روش های گذشته              |
| ۱۶ | ۱-۲ روشهای مبتنی بر تصاویر شدت روشنایی |
| ۱۷ | ۱-۲-۱ آنالیز اجزای اصلی (PCA)          |
| ۲۱ | ۲-۱-۲ آنالیز اجزای مستقل (ICA)         |
| ۲۲ | ۱-۲-۱-۲ مقایسه روشهای PCA و ICA        |
| ۲۴ | ۲-۱-۲ آنالیز تفکیک پذیری خطی (LDA)     |
| ۲۶ | ۲-۱-۲ روشهای غیر خطی                   |
| ۲۷ | ۱-۴-۱-۲ روش KPCA                       |
| ۲۹ | ۲-۱-۲ روشهای مبتنی بر ویژگی های محلی   |



- ۳۰ ..... ویولت گابور ۱-۵-۱-۲
- ۳۳ ..... 2-1-5-2 روش الگوی باینری محلی (LBP).....
- ۳۵ ..... تبدیل ویژگی غیرحساس به بزرگنمایی (SIFT)..... ۳-۵-۱-۲
- ۳۸ ..... ۶-۱-۲ مقایسه روشها.....
- ۳۹ ..... ۲-۲ روشهای مبتنی بر تصویر سه بعدی.....
- ۴۰ ..... 2-2-1 روش PCA و LDA.....
- ۴۰ ..... ۲-۲-۲ روش فاصله هاسادروف.....
- ۴۱ ..... 2-2-3 مدل دگردیس.....
- ۴۲ ..... ۴-۲-۲ روشهای جزء نگر شناسایی چهره سه بعدی.....
- ۴۲ ..... ۱-۴-۲-۲ روش نقطه مبنا.....
- ۴۳ ..... ۲-۴-۲-۲ روش انحنا مبنا.....
- ۴۴ ..... ۳-۴-۲-۲ روشهای مبتنی بر بخش بندی.....
- ۴۶ ..... ۴-۴-۲-۲ روش توصیفگر عمومی.....
- ۴۷ ..... ۵-۴-۲-۲ روش مبتنی بر چند نوع ویژگی.....
- ۴۹ ..... ۳: روش پیشنهادی.....
- ۵۰ ..... ۱-۳ کلیات روش پیشنهادی.....
- ۵۱ ..... ۲-۳ دیتابیس تصویر سه بعدی.....
- ۵۲ ..... ۳-۳ پیش پردازش.....

- ۵۲ ..... ۳-۳-۱ حذف نویز پرش
- ۵۳ ..... ۳-۳-۲ حذف نویز حفره
- ۵۴ ..... ۳-۳-۳ تعیین رویه چهره
- ۵۵ ..... ۳-۴ استخراج ویژگی
- ۵۵ ..... ۳-۴-۱ الگوی باینری محلی کامل
- ۵۶ ..... ۳-۴-۱-۱ الگوی باینری محلی پایه
- ۵۹ ..... ۳-۴-۱-۲ هیستوگرام الگوی باینری محلی کامل
- ۶۲ ..... ۳-۴-۲ هیستوگرام واریانس الگوی باینری محلی
- ۶۳ ..... 3-4-3 ویژگی های مبتنی بر انحنای اصلی
- ۶۷ ..... ۳-۵ انتخاب ویژگی ها
- ۶۸ ..... ۳-۶ روش دسته بندی
- ۶۹ ..... ۳-۶-۱-۱ روش دسته بندی ساده بیزی
- ۷۰ ..... ۳-۶-۱-۲ دسته بند K نزدیکترین همسایه
- ۷۲ ..... ۴: نتایج آزمایشات
- ۷۳ ..... ۴-۱ کلیات پیاده سازی
- ۷۴ ..... ۴-۲ نتایج روش استخراج ویژگی CLBP
- ۷۸ ..... 1-2-4 تحلیل نتایج روش CLBP
- ۸۰ ..... 3-4 مقایسه نتایج روش LBPH، LBPV و LBPK

۴-۴ نتایج روش های کل نگر ..... ۸۳

۵-۴ سرعت پردازش روش های اجرا شده ..... ۸۶

۶-۴ مقایسه با روش های گذشته ..... ۸۷

۵: نتیجه گیری ..... ۸۸

۱-۵ نتیجه گیری ..... ۸۹

۲-۵ پیشنهادات برای کار های آینده ..... ۹۰

## فهرست شکل ها

- شکل ۱-۱- تغییرات زاویه سر [5] ..... ۵
- شکل ۲-۱- تغییر میزان روشنایی تصویر [5] ..... ۶
- شکل ۳-۱- تصویر حرارتی مادون قرمز [5] ..... ۶
- شکل ۴-۱- تغییرات حالت چهره [5] ..... ۷
- شکل ۵-۱- تغییرات چهره با سالخوردگی [7] ..... ۷
- شکل ۶-۱- تغییر فاصله تا دوربین [5] ..... ۸
- شکل ۷-۱- تغییر تصویر زمینه [5] ..... ۸
- شکل ۸-۱- سنسور فعال سه بعد [8] ..... ۱۳
- شکل ۱-۲- نمونه تصاویر پایگاه داده ORL [9] ..... ۱۹
- شکل ۲-۲- میانگین تصاویر ORL [9] ..... ۱۹
- شکل ۳-۲- بردار ویژگی بر اساس ۱۲ مقدار ویژه بزرگتر [9] ..... ۲۰
- شکل ۴-۲- بردار ویژگی بر اساس ۱۲ مقدار ویژه کوچک [9] ..... ۲۰
- شکل ۵-۲- مقایسه روش های PCA و ICA [11] ..... ۲۳
- شکل ۶-۲- بردار اول پایه با اعمال LDA [2] ..... ۲۶
- شکل ۷-۲- اعمال یک Kernel به تابع دوبعدی برای انتقال به فضای سه بعدی ..... ۲۸
- شکل ۸-۲- فضای اصلی توزیع داده ها ..... ۲۸
- شکل ۹-۲- نتیجه اعمال PCA و KPCA ..... ۲۸
- شکل ۱۰-۲- مراحل کلاسه بندی محلی [14] ..... ۲۹
- شکل ۱۱-۲- یولت گابور: a: قسمت حقیقی فیلتر گابور با ۸ جهت و پنج مقیاس b: دامنه فیلتر گابور

- در چند مقیاس مختلف [15] ..... ۳۱
- شکل ۲-۱۲- فیلتر گابور a: قسمت حقیقی b: دامنه تصویر [15] ..... ۳۲
- شکل ۲-۱۳- نمونه ای از گراف چهره از پایگاه داده FRET [16] ..... ۳۳
- شکل ۲-۱۴- عملگر الگوی باینری محلی [16] ..... ۳۴
- شکل ۲-۱۵- مقایسه یک پیکسل با همسایه های ۲۶ گانه برای به دست آوردن اکستریم های محلی  
..... ۳۶
- شکل ۲-۱۶- تولید توصیفگر نقاط کلیدی با محاسبه دامنه و جهت گرادیان اطراف نقاط کلیدی (شکل  
چپ) محاسبه هیستوگرام جهت در یک ناحیه  $4*4$  (شکل چپ) [18] ..... ۳۸
- شکل ۲-۱۷- مراحل اجرای روش مدل دگر دیس [24] ..... ۴۲
- شکل ۲-۱۸- انحنای شعاعی [28] ..... ۴۴
- شکل ۲-۱۹- قسمت بندی تصویر در روش Alyuz [32] ..... ۴۶
- شکل ۳-۱- کلیات روش پیشنهادی ..... ۵۰
- شکل ۳-۲- تصویر دیتا بیس Gavab [38] ..... ۵۱
- شکل ۳-۳- نویز پرش [28] ..... ۵۲
- شکل ۳-۴- وجود نویز حفره، تصویر سمت راست نویز حفره را در مردمک چشم نشان می دهد و  
تصویر چپ نویز حفره را در ناحیه ابرو نشان می دهد. .... ۵۳
- شکل ۳-۵- حذف قسمت اضافی تصاویر ..... ۵۴
- شکل ۳-۶- الگوریتم محاسبه الگوی باینری محلی کامل ..... ۵۵
- شکل ۳-۷- همسایگی های مختلف برای یک پیکسل [16] ..... ۵۶
- شکل ۳-۸- الگوی یکنواخت برای  $(R=1, P=8)$  که دایره های سفید و سیاه نشان دهنده صفر و یک بودن  
بیت می باشد [40] ..... ۵۸

- شکل ۳-۹ a : یک بلوک  $3*3$  b: محاسبه اختلاف هر پیکسل با پیکسل مرکزی c : محاسبه بردار علامت d: محاسبه بردار دامنه ..... ۶۰
- شکل ۳-۱۰-الگوریتم محاسبه ویژگی LBPV ..... ۶۲
- شکل ۳-۱۱-سطوح مختلف و میزان انحنای گوسی و میانگین هر سطح [34] ..... ۶۵
- شکل ۳-۱۲-مهمترین روش های دسته بندی داده ها ..... ۶۸
- شکل ۳-۱۳-محدوده همسایگی ..... ۷۱
- شکل ۳-۱۴-الگوریتم دسته بندی k نزدیکترین همسایه ..... ۷۱
- شکل ۴-۱-روال کلی سیستم پیشنهادی ..... ۷۳
- شکل ۴-۲-نمودار تاثیر اندازه شعاع همسایگی برای استخراج ویژگی در شناسایی ..... ۷۸
- شکل ۴-۳-مقایسه دقت هر یک از ویژگی ها با یکدیگر توسط دسته بند ساده بیزی ..... ۷۹
- شکل ۴-۴-نمودار مقایسه عملکرد دسته بند ساده بیزی و نزدیکترین همسایه ..... ۸۰
- شکل ۴-۵-مقایسه دقت شناسایی با افزایش بلوک بندی تصویر ..... ۸۲
- شکل ۴-۶-دقت شناسایی بر اساس تعداد ویژگی های انتخاب شده با LDA ..... ۸۳
- شکل ۴-۷-نمودار تاثیر استفاده از LDA بر روی عملکرد سیستم با دسته بند KNN ..... ۸۵
- شکل ۴-۸-نمودار تاثیر استفاده از LDA بر روی عملکرد سیستم با دسته بند ساده بیزی ..... ۸۵

## فهرست جدول ها

- جدول ۳-۱ محاسبه ویژگی ها در الگوی باینری محلی کامل ..... ۶۱
- جدول ۴-۱ ابعاد هریک از ویژگی ها قبل از کاهش ویژگی ..... ۷۵
- جدول ۴-۲ نتایج روش CLBP با در نظر گرفتن ۷۰ درصد داده ها برای آموزش ..... ۷۶
- جدول ۴-۳ نتایج روش CLBP با در نظر گرفتن ۳۰ درصد داده ها برای آموزش ..... ۷۷
- جدول ۴-۴ نتایج روش های LBPV،LBPH وLBPK با در نظر گرفتن ۷۰ درصد داده ها برای آموزش ۸۱
- جدول ۴-۵ نتایج روش های LBPV،LBPH وLBPK با در نظر گرفتن ۳۰ درصد داده ها برای آموزش ۸۱
- جدول ۴-۶ نتایج روش های کل نگر با در نظر گرفتن ۷۰ درصد داده ها برای آموزش ..... ۸۴
- جدول ۴-۷ نتایج روش های کل نگر با در نظر گرفتن ۳۰ درصد داده ها برای آموزش ..... ۸۴
- جدول ۴-۸ زمان پردازش سیستم پیشنهادی با ویژگی های مختلف ..... ۸۶
- جدول ۴-۹ مقایسه روش پیشنهادی با روش های گذشته ..... ۸۷





١ : مقده

## ۱-۱ پیش گفتار

یکی از روشهای بیومتریک شناسایی افراد از روی ویژگی های چهره است که این روش با توجه به این که نیازی به ارتباط فیزیکی با فرد ندارد مورد توجه قرار گرفته است و از لحاظ اجتماعی نیز پذیرفته شده است با وجود پیشرفت های صورت گرفته در زمینه بینایی ماشین و تشخیص الگو، شناسایی چهره سه بعدی هنوز یکی از مسائل چالش بر انگیز محسوب می شود. سیستم های مدرن شناسایی چهره دو بعدی، در شرایط یکنواخت و کنترل شده بسیار خوب عمل می کنند با این حال، تغییرات در نورپردازی تصویرها، زوایای مختلف ژست چهره و حالات مختلف چهره از مشکلات پیش روی تمامی روش های شناسایی چهره می باشند. در مقابل، تصاویر سه بعدی می توانند اشیاء را بدون در نظر رفتن نقطه دید و شدت نور به وضوح نمایش دهند. به عبارتی، داده سه بعدی چهره انسان دارای این پتانسیل می باشد که کارایی سیستم های شناسایی چهره را در شرایط نامساعد، از قبیل نورپردازی، ژست و حالات کنترل نشده، بهبود ببخشد.

## ۱-۲ شناسایی چهره

کلمه Biometric از ترکیب دو کلمه یونانی bios به معنای زندگی و kometrikos به معنای اندازه گیری تشکیل شده است و طبق تعریف عبارت است از، تشخیص هویت افراد با استفاده از ویژگی های فیزیولوژی و رفتاری آنها. همه ما می دانیم که برای شناسایی همدیگر از یک سری ویژگی هایی استفاده می کنیم که برای هر شخص به طور انحصاری است و از شخصی به شخص دیگر فرق می کند که از آن جمله می توان به شکل صورت و گفتار و طرز راه رفتن اشاره کرد. سیستم شناسایی بیومتریک و تشخیص هویت در بسیاری از موارد با هم اشتراک دارند، اما به طور کامل شبیه هم نیستند. امروزه در زمینه های فراوانی از اجرای قانون تا اهداف تجاری ما به وسایلی نیاز داریم که هویت اشخاص را شناسایی کند و بر اساس ویژگی های بدن اشخاص آن هارا بازشناسی کند و این زمینه هر روز بیشتر و بیشتر رشد پیدا می کند و علاقه مندان فراوانی را پیدا کرده است. برای مثال

ما در زندگی روزانه خود برای دریافت پول از عابر بانک، سوار شدن به قطار یا هواپیما، وارد شدن به سیستم کامپیوتر خود و... نیازمند تایید شدن هویت خود می باشیم. سیستم‌های بیومتریک باید با درصد قابل توجهی قابل اعتماد باشند تا سیستم در تشخیص افراد و اجازه دسترسی آنها اشتباه نکند. روش‌های شناسایی بیومتریک به طور کلی نسبت به سیستم‌های سنتی مزایایی دارند مثلاً نمی‌توان آنها را غرض داد، گم یا فراموش نمی‌شوند، نمی‌توان آنها را دزدید و خراب هم نمی‌شوند. در بین روشهای بیومتریک، تشخیص هویت از طریق چهره دارای محبوبیت بیشتری نسبت به سایر روشها می‌باشد. در روشهایی مثل اثر انگشت ما نیازمند ارتباط فیزیکی با سیستم شناسایی هستیم و مشکلات دیگری نظیر استفاده از اثر انگشت ژلاتینی و حتی استفاده از لاشه انگشت توسط سارقان نیز وجود دارد و یا در روش تشخیص از طریق عنبیه نیازمند همکاری دقیق کاربر برای تهیه تصویر دقیق از عنبیه می‌باشیم. به صورت کلی از چهره برای دو کاربرد امنیتی و شناسایی استفاده می‌شود. در سیستم‌های امنیتی هنگامی که فردی ادعا می‌کند که یک شخص خاص است سیستم ادعای او را بررسی کرده و یا آن شخص را تایید می‌کند و یا او را رد می‌کند. که از این سیستم‌ها در کنترل دسترسی به ساختمان‌ها، فرودگاهها، بنادر، دسترسی به دستگاههای خود پرداز، امنیت کامپیوتر، سیستم‌های کنترل مرزی و ایمیل‌های تصدیق هویت استفاده می‌گردد.

در سیستم‌های شناسایی سیستم با دریافت تصویر یک فرد ناشناس آن را با پایگاه داده خود مقایسه می‌کند و هویت فرد ناشناس را تعیین می‌کند. این سیستم‌ها بیشتر برای شناسایی مجرمان به کار می‌رود به طور مثال برای شناسایی افرادی که در ورزشگاهها ایجاد اختلال می‌کنند به کار می‌رود، در دستگاه قضایی و پلیس نیز کاربرد فراوانی دارد همچنین برای برگزاری انتخابات و یا تشخیص نوزادان در بیمارستان‌ها. سیستم‌های شناسایی نیز خود به دو دسته مجموعه بسته<sup>۱</sup> و مجموعه باز<sup>۲</sup> تقسیم می‌شوند در شناسایی مجموعه بسته سیستم فرض می‌کند که تصویر ی که باید شناسایی

---

<sup>۱</sup> Close -set

<sup>۲</sup> Open-set

بشود حتما در پایگاه داده عکس هایش وجود دارد و به دنبال عکسی می گردد که بیشترین تشابه را با عکس مورد نظر دارد و یک جواب در خروجی به ما می دهد. در سیستم های مجموعه باز دیگر این فرض اولیه وجود ندارد و ممکن است شناسایی اتفاق نیافتد.

در سال های اخیر به خصوص در ۲۰ سال گذشته فعالیت های زیادی در زمینه تشخیص چهره انجام شده است. و ما هر روز در زندگی خود با این سیستم ها درگیر می شویم. شرکتهای تجاری و موسسات آموزشی و پژوهشی نیز هر روز ایده های نو در این زمینه ارائه می دهند. ساخت پایگاه های داده مختلف نیز برای آزمایش الگوریتم های جدید نیز به پیشرفت این سیستم ها کمک زیادی کرده است. روشهای مختلفی از جمله آنالیز اجزای اصلی [1]، آنالیز اجزای جدا پذیری خطی [2]؛ تطبیق دسته ای منعطف [3]، الگوی باینری محلی [4] تا به حال بروی پایگاههای داده مختلفی آزمایش شده اند و نتایج قابل قبول و خوبی به دست آمده است.

## ۱-۳ مشکلات شناسایی با تصاویر دو بعدی

با وجود برتری هایی که شناسایی چهره نسبت به روشهای بیومتریکی دیگر دارد مشکلاتی نیز در این روش وجود دارد. تصویر چهره افراد مختلف شباهت های زیادی با هم دارد و در موارد خاص مثل دو قلوها این شباهت بیش از اندازه زیاد است، در حالی که در اثر انگشت یا عنبیه همچین شباهتی وجود ندارد. علاوه بر این مشکل، زمانی که ما از یک عکس دو بعدی استفاده می کنیم تغییرات حالت چهره و یا تغییر در روشنایی تصویر و چرخش وضعیت سر، بر روی نتایج ما تاثیر نا مطلوبی می گذارد. نتایج آزمایشات انجام شده بر روی تصویر دو بعدی بسیار خوب بوده است اما برای این که تشخیص ما قابل اعتماد باشد باید بتوانیم مشکلاتی که وجود دارد را حل کنیم.


انتظار ما این است که یک سیستم تشخیص چهره نسبت به تغییرات روشنایی، چرخش سر، حالت های

<sup>1</sup> linear discriminant Analysis

<sup>2</sup> elastic bunch graph matching

<sup>3</sup> Local binary pattern

چهره و تغییر سن و سال مقاوم باشد. تغییر زاویه سر<sup>۱</sup> ممکن است در هر جهتی رخ بدهد که یکی از مشکلات عمده سیستم های شناسایی دوی بعدی می باشد. در شکل ۱-۱ نمونه ای از تغییر زاویه یک عکس را می بینیم .



شکل ۱-۱- تغییرات زاویه سر [5]

تغییرات روشنایی نیز یکی دیگر از مشکلات تصویر دوی بعدی است که تاثیر نامطلوبی بر روی سیستم می گذارد. در صورت تغییر روشنایی تصویر دچار سایه می شود و نقاط برجسته اش تغییر می کند. در شکل ۲-۱ تاثیر تغییر روشنایی بر چهره به خوبی مشخص است. البته برای غلبه بر این مشکل روشهای مختلفی مورد بررسی قرار گرفته مثلا در روشی که در [6] ارایه شد از تصاویر حرارتی مادون قرمز<sup>۲</sup> (شکل ۳-۱) استفاده شده تا تاثیر تغییرات روشنایی را کاهش دهد. اما این روش نیز بدون مشکل نبود، تصویر حرارتی مادون قرمز به شدت تحت تاثیر گرمای جسمی است که از آن عکس می گیریم و گرمای بدن انسان هم در شرایط مختلف تغییر میکند و این مسئله خود یک مشکل جدید است و نمیتوانیم با این روش مشکل تغییر روشنایی را به طور کلی حل کنیم.

<sup>1</sup> Pose variation

<sup>2</sup> Thermal infrared



شکل ۱-۲- تغییر میزان روشنایی تصویر [5]

در شکل ۱-۳ یک نمونه تصویر مادون قرمز آورده شده است.



شکل ۱-۳- تصویر حرارتی مادون قرمز [5]


تغییر حالت چهره<sup>۱</sup> معمولاً با حرکت ماهیچه های صورت و یا وضعیت های احساسی، تعجب، خنده و گریه رخ می دهد. هر کدام از این حالت ها تاثیر منفی بر روی سیستم تشخیص می گذارد و باعث کاهش دقت سیستم می گردد.

<sup>۱</sup> Facial expression variation



شکل ۴-۱- تغییرات حالت چهره [5]


تغییر چهره با سالخوردگی<sup>۱</sup> عمدتاً به کندی اتفاق می افتد و برگشت ناپذیر است. بیشترین تغییرات در سر و صورت از دوران کودکی تا بزرگسالی اتفاق می افتد و از سن بزرگسالی تا پیری بیشتر تغییرات در بافت<sup>۲</sup> پوست می باشد. هرچند در بازه زمانی کوتاه مدت این یک مشکل بزرگ نیست اما در مدت زمان دراز این قضیه تبدیل به یک مشکل بزرگ می شود. در شکل ۵-۱ تغییرات چهره انیشتن را در سالهای مختلف می بینیم.



شکل ۵-۱- تغییرات چهره با سالخوردگی [7]

از جمله مشکلات دیگری که وجود دارد اضافه شدن عینک، کلاه، ریش و مواد آرایشی به صورت است و یا مواردی که فاصله صورت افراد تا دوربین تغییر می کند و یا زمینه پشت سر عکس عوض می شود که هر کدام از این موارد باعث عدم تشخیص صحیح سیستم می شود.

<sup>۱</sup> Face imaging  
<sup>۲</sup> texture



شکل ۱-۶- تغییر فاصله تا دوربین [5]



شکل ۱-۷- تغییر تصویر زمینه [5]

## ۴-۱ تصاویر سه بعدی

تصاویر سه بعدی که اصطلاحاً استریو گرام<sup>۱</sup> نامیده می‌شوند، در واقع تصاویر مسطح دوبعدی است که بعد سوم آن در میان دو بعد دیگر پنهان است. اشیایی که در زندگی با آن‌ها سروکار داریم اشیایی سه بعدی هستند، در واقع جهان ما، جهانی سه بعدی است که همه اشیای درون آن سه بعد، طول، عرض و ارتفاع دارند و حجمی را در فضا اشغال می‌کنند که توسط این سه بعد پدید می‌آید. در به تصویر کشیدن اشیا چه از طریق عکاسی و چه از طریق نقاشی، همواره بعد سوم اشیا که بعد عمق است از میان می‌رود و بدین ترتیب ما در یک تصویر نقاشی یا یک عکس با باز نمودی دو بعدی از اشیای سه بعدی روبه رو هستیم.

تاریخچه پیدایش تصاویر سه بعدی و استریوگرام در اصل به سال ۱۸۸۴ میلادی بازمی‌گردد؛ جایی

<sup>۱</sup> Stereogram



که چارلز ویتستون<sup>۱</sup> دانشمند انگلیسی توانست به طور اتفاقی به پدیده جالبی پی ببرد. وی در خلال آزمایشات خود به طور اتفاقی دریافت از آنجا که چشمان انسان در فاصله اندکی از هم قرار دارند. شی مشاهده شده توسط هر چشم تا اندازه بسیار کمی با چشم دیگر فرق می‌کند که این امر سبب پیدایش خطای دید در عمق می‌شود. پنج سال بعد و با کشف پدیده استروسکوپ (برجسته بینی)، وی دستگاه استروسکوپ دستگامی متشکل از آینه هادر زوایای خاص را اختراع کرد که دو تصویر از یک جسم را به چشم منتقل می‌کرد و بیننده را قادر می‌ساخت اشیا را به طور برجسته ببیند. در سال‌های بعد و با اختراعات متعدد گام‌های دیگری در پیشبرد صنعت ساخت دوربین‌های سه بعدی برداشته شد تا سرانجام علم هولوگرافی<sup>۲</sup> پدید آمد. علم هولوگرافی که در واقع دانش مربوط به ثبت تصاویر در سه بعد است به طور تصادفی توسط فیزیکدان مجارستانی کشف شد. وی در حالی که سرگرم مطالعه بهبود میکروسکوپ‌های الکترونی بود، موفق به تولید و ایجاد تصاویر سه بعدی شد و این تصاویر را هولوگرام نامید که متشکل از دو کلمه یونانی هولو به معنای «تمام و کمال» و گرام به معنای «پیام» است. اما این اختراع هم پایان راه تصاویر سه بعدی نبود. روانشناسی به نام بلا جولز در ضمن مطالعه روی الگوشناسی و ادراک عمق نشان داد که تصاویر سه بعدی در مغز تولید می‌شود نه در شبکیه و به این ترتیب بر باور پیشینیان در محل تشکیل تصاویر سه بعدی نیز خط بطلان کشیده شد.

## ۱-۴-۱ تصاویر سه بعدی در مغز انسان

با توجه به این که دو چشم انسان با یکدیگر حدود ۵.۶ سانتی متر فاصله دارند انسان توسط این دو چشم به محیط اطراف با زاویه‌ای متفاوت نگاه می‌کند همانطور که ما به اطراف نگاه می‌کنیم، شبکیه هر چشم تصویری دوبعدی از محیط اطراف ضبط و برای مغز ارسال می‌کند. مغز این دو تصویر دوبعدی را طی فرآیندی ادغام و محیط اطراف را به شکل سه بعدی درک می‌کند. بنابراین انسان دارای

<sup>1</sup> Charles Vytstvn

<sup>2</sup> Holographic

قابلیت تشخیص عمق<sup>۱</sup> می‌شود. قابلیت که به ما اجازه می‌دهد اجسام دور را از اجسام نزدیک تشخیص دهیم و به راحتی درباره فواصل اشیا قضاوت کنیم.

انسان به دلیل داشتن قابلیت دوربین دو چشمی<sup>۲</sup>، محیط اطراف خود را سه‌بعدی می‌بیند. اما انسان برای درک یک تصویر به صورت سه بعدی از تکنیک‌هایی به صورت ناخواسته استفاده می‌کند که عبارتند از:

#### ۱. برجسته بینی<sup>۳</sup>

قابلیتی است که به دو چشم اجازه می‌دهد، تصاویری جداگانه با زوایای افق متفاوت تهیه کنند. در این تصاویر، اشیا نزدیک بسیار جدا و متمایز از اشیا دور می‌باشند.

#### ۲. سازش با محیط<sup>۴</sup>

همان طور که انسان بر جسمی دور یا نزدیک متمرکز می‌شود چشم انسان به شکل فیزیکی لنز خود را جابه‌جا کرده و آن را بر حسب فاصله‌ای که بر آن متمرکز شده است، تغییر می‌دهد.

۳. اختلاف منظر<sup>۵</sup> هنگامی که انسان سر خود را از سمتی به سمت دیگر حرکت می‌دهد، به نظر می‌رسد که اشیا نزدیک بیشتر از اشیا دور حرکت می‌کنند و جابه‌جا می‌شوند.

#### ۴. آشنایی با حجم اشیا<sup>۶</sup>

اگر شما اندازه تقریبی جسمی را بدانید، از روی بزرگ به نظر رسیدن و کوچک به نظر رسیدن آن

---

<sup>۱</sup> Depth Perception

<sup>۲</sup> Binocular vision

<sup>۳</sup> Stereoscopic vision

<sup>۴</sup> Accommodation

<sup>۵</sup> Parallax

<sup>۶</sup> Size Familiarity

می‌توانید به طور تقریبی، فاصله آن جسم را تا خودتان حدس بزنید. به طور مثال اگر بین دو جسم که می‌دانید اندازه یکسانی دارند، یکی بزرگ‌تر و دیگری کوچک‌تر به نظر بیاید، می‌توانید حدس بزنید که جسم بزرگ‌تر به شما نزدیک‌تر است.

#### ۵. چشم انداز هوایی<sup>۱</sup>

اشیای دور، کنتراست کمتری نسبت به اشیای نزدیک دارند و همچنین کمتر اشباع شده از رنگ به نظر می‌آیند و دارای پس زمینه کم رنگی هستند، که معمولاً آبی می‌باشد، این به این دلیل است که نور به صورت اتفاقی در هوا پخش می‌شود.

### ۱-۴-۲ تصاویر سه بعدی در سینما

اما چگونه انسان تصویر تخت روی پرده سینما یا صفحه تلویزیون را به صورت سه بعدی می‌بیند؟ برای تولید یک تصویر سه بعدی روش‌های زیادی وجود دارد و به صورت کلی همه این روش‌ها از تکنیک‌های استریوسکوپی استفاده می‌کنند در ساخت این نوع تصویر از نوعی دوربین تصویری متحرک استفاده می‌شود که تصاویر را از دو دیدگاه ثبت می‌کند. برای نمایش این نوع تصویر، از نوعی سخت افزار و عینک‌های خاص استفاده می‌شود که درک عمق تصویر را افزایش می‌دهند. پیچیده‌ترین قسمت ساخت یک فیلم سه بعدی این است که تصاویر باید گونه‌ای نمایش داده شوند که هر چشم تنها تصویر مربوط به خود را ببیند نه تصاویر مربوط به چشم دیگر را، زیرا در این حالت بیننده دو تصویر تار را مشاهده خواهد کرد که با هم منطبق نیستند. برای جداسازی تصاویر از یکدیگر و نمایش آن‌ها از روش‌های مختلفی استفاده می‌شود که یکی از این روشها استفاده از عینک‌هایی است که به اصطلاح به عینک‌های سه بعدی معروف هستند. این عینک‌ها نیز خود به دو دسته فعال و غیرفعال تقسیم می‌شوند. عینک‌های سه بعدی باید با هماهنگی نمایشگری که تصاویر سه بعدی را نمایش

---

<sup>۱</sup> Aerial perspective

می‌دهد، کار کنند. به همین دلیل تمامی مدل‌های فعال، به نوعی با تلویزیون ارتباط دارند. در مقابل، آنهایی که در سینماها استفاده می‌شوند، همیشه از انواع غیرفعال یا پسیو هستند. البته یک نوع نمایشگر بدون لنز نیز ساخته شده است در این روش نیازی به استفاده از عینک برای تماشای فیلم نیست. در حال حاضر، تنها نمونه تجاری آن موجود است.

## ۱-۵ شناسایی چهره با تصویر سه بعدی


با توجه به مشکلاتی که در شناسایی تصویر دوبعدی وجود دارد محققین به دنبال استفاده از تصویر سه بعدی برای غلبه بر محدودیت‌های تصویر دو بعدی می‌باشند. تصاویر عمق همراه با ویژگی‌های انحنایی<sup>۱</sup> صورت برتری بیشتری نسبت به تصاویر شدت معمولی دارد. به طور خاص انحنای صورت می‌تواند دقت بیشتری در نمایش یک تصویر ایجاد کند، ویژگی‌های صورت را در قسمت پیشانی، چانه و گونه‌ها به طور مناسبی نشان دهد و نسبت به نقطه دید تغییر نکند.

در حال حاضر فن آوری ثبت تصویر سه بعدی که برای تشخیص چهره به کار می‌رود به سه دسته تقسیم می‌شود. دسته اول روش‌های غیرفعال می‌باشند که در این روش از دو دوربین با یک رابطه هندسی شناخته شده استفاده می‌شود و بعد از پیدا شدن نقطه متناظر در هر دو عکس گرفته شده محل نقطه<sup>۳</sup> بعدی محاسبه می‌گردد.

روش دوم روش تصویر برداری فعال می‌باشد که در این روش از یک دوربین و یک پروژکتور نور با یک رابطه هندسی از پیش تعریف شده استفاده می‌گردد. یک نمونه از این سنسورها سنسور VIVID910 از شرکت مینولتا می‌باشد که در شکل ۱-۸ آورده شده است.

---

<sup>۱</sup>curvature



شکل ۸-۱- سنسور فعال سه بعد [8]

روش سوم یک روش ترکیبی از دو روش فعال و غیر فعال می باشد. سنسور "3Q Qlonerator" یک نمونه از سنسورهای هیبریدی می باشد. در بین این سه روش سنسورهای فعال می توانند تصویری با اطلاعات عمق خیلی دقیق به ما بدهند اما این سنسورها یک محدودیت دارند که زمان تصویر برداری آنها خیلی سریع نیست. اما سنسورهای غیر فعال بر خلاف سنسور فعال بسیار سریع تصویر برداری را انجام می دهند ولی میزان نمونه گیری آنها از صحنه به اندازه کافی زیاد نیست و ممکن است برخی از اطلاعات بافت به خوبی ثبت نشود. سنسورهای هیبریدی که با ترکیب این دور روش ساخته می شوند سعی در غلبه بر محدودیت های سنسورهای فعال و غیر فعال را دارند. البته در همه این سنسورها مشکلاتی از قبیل حفره<sup>۱</sup> و پرش<sup>۲</sup> در هنگام ثبت تصاویر بوجود می آید، زمانی که سنسور نمی تواند اطلاعات یک قسمت از تصویر را ثبت کند حفره در تصویر بوجود می آیند.

<sup>۱</sup>hole  
<sup>۲</sup>spike



**۲: مروری بر روش های گذشته**

در این بخش به بررسی روشهای موجود در شناسایی چهره می پردازیم، به صورت کلی روشهای شناسایی چهره در سه دسته تقسیم بندی می شوند، در دسته اول برای شناسایی از تصاویر شدت روشنایی چهره استفاده می شود و در دسته دوم که به منظور حل برخی مشکلات روش اول به کار می رود از تصاویر سه بعدی استفاده می شود و در گروه سوم برای رسیدن به جواب بهتر از ترکیب تصاویر دو بعدی و سه بعدی استفاده می شود. که در اینجا ما بر اساس دسته بندی بالا روشهای موجود را به اختصار بیان میکنیم:

## ۱-۲ روشهای مبتنی بر تصاویر شدت روشنایی

به طور کلی این روشها را میتوانیم به دو دسته تقسیم بندی کنیم: روش های کل نگر<sup>۱</sup> و روشهای جزء نگر<sup>۲</sup>، در سیستم جزء نگر برای هر یک از اجزای چهره مانند لب، بینی و چشمها یک بردار ویژگی استخراج می شود و از این بردار برای تصمیم گیری استفاده می شود، در مقابل روشهای کل نگر از کل چهره یک بردار استخراج می کنند و از این بردار برای شناسایی استفاده می کنند. در روشهای کل نگر با توجه به این که داده های موجود برای شناسایی دارای ابعاد بالایی هستند، داده ها به یک فضا با ابعاد کم تر انتقال می یابند و پردازش در فضای جدید صورت می گیرد. فضای جدید می تواند توسط یک تبدیل خطی یا غیر خطی بوجود آید. مهم ترین روشهای موجود در این دسته شامل، آنالیز اجزای اصلی<sup>۳</sup>، آنالیز تفکیک پذیری خطی<sup>۴</sup> و آنالیز اجزای مستقل<sup>۵</sup> می باشد. اما در روش جزء نگر یک سری ویژگی از چهره استخراج می شود و از این ویژگی ها برای شناسایی استفاده می شود که، تطبیق دسته الاستیکی<sup>۶</sup>، الگوی باینری محلی<sup>۷</sup> و ویژگی های ثابت در مقیاس<sup>۸</sup> از جمله این روشها می

---

<sup>۱</sup>Holistic

<sup>۲</sup>Local feature based

<sup>۳</sup> Principal component analysis

<sup>۴</sup> linear discriminant Analysis

<sup>۵</sup> Independent Component Analysis

<sup>۶</sup>Elastic Bunch Graph Matching

<sup>۷</sup> Local Binary Ppatter

<sup>۸</sup> Scale- invariant feature



باشند. البته روشهای دیگری نیز وجود دارند مثل روش مدل ظاهری فعال که در دو دسته کلی بالا قرار نمی گیرند. در این قسمت ما روشهای که در بالا ذکر شد را بررسی می کنیم.

## ۱-۱-۲ آنالیز اجزای اصلی (PCA)

این روش به عنوان تبدیل هتلینگ<sup>۱</sup> نیز شناخته می شود [1]. این روش بر این مبنا استوار است که داده های یک ماتریس  $M \times N$  بعدی را می توان با حداکثر  $P$  بردار عمود بر هم نشان داد که  $P$  مینیمم  $M$  و  $N$  است. در بعضی وضعیت ها ابعاد بردار ویژگی ورودی بسیار بزرگ است، و اجزاء بردارها، همبستگی بالایی دارند، مفید است که در این وضعیت ابعاد بردار ورودی را کاهش دهیم.

با اجرای این روش بر روی داده ها می توانیم به نتایج زیر برسیم:

۱. متعامد سازی اجزا بردار ورودی (بنابراین آنها هیچ وابستگی با یکدیگر ندارند)

۲. مرتب سازی اجزای اصلی و اولویت دادن به اجزای اصلی

۳. حذف اجزایی که تغییرات کم دارند

مراحل اجرای این روش به صورت زیر می باشد:

مرحله اول: تنظیم داده ها

ابتدا باید تصویر ورودی را که به صورت یک ماتریس دو بعدی می باشد به صورت یک بردار یک بعدی تبدیل کنیم و با کنار هم قرار دادن این بردارها ماتریس ویژگی را تشکیل بدهیم. در صورتی که تعداد کل تصاویر ما  $N$  تا باشد و بعد هر تصویر  $p * q$  باشد ماتریس ویژگی به صورت  $n * N$  به دست می آید که  $n = p * q$  می باشد.

---

<sup>۱</sup> Karhunen-Loeve's

$$X = (x_1, x_2, \dots, x_i, \dots, x_N) \quad (1-2)$$

که در رابطه (1-2) ماتریس ویژگی  $x_i, n \times N$  بردار ویژگی هر تصویر با ابعاد  $n$  می باشد که  $n=p \times q$  می باشد.

مرحله دوم: محاسبه میانگین

در این مرحله ابتدا میانگین هر کلاس از داده هارا به دست می آوریم و سپس تک تک داده های هر دسته را از میانگینش کم میکنیم تا داده ها به مرکز صفر منتقل بشوند.

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (2-2)$$

مرحله سوم: ماتریس کواریانس

در این مرحله ماتریس کواریانس را حساب می کنیم و سپس از روی این ماتریس، مقادیر ویژه و بردارهای ویژه را به دست می آوریم

$$S_T = \sum_{i=1}^N (x_i - \mu)(x_i - \mu)^T \quad (3-2)$$

مرحله چهارم: انتخاب مولفه ها و ساختن ماتریس بردار ویژگی ها


در این مرحله مفهوم کاهش ابعاد داده وارد می شود بردار های ویژه ای که در مرحله قبل به دست آمد را بر اساس مقادیر ویژه آنها از بزرگ به کوچک مرتب می کنیم (مقادیر ویژه ماتریس کواریانس همگی بزرگتر از صفر هستند) با این کار مولفه های داده از پراهمیت به کم اهمیت مرتب می شوند در اینجا اگر بخواهیم ابعاد داده را کاهش دهیم می توانیم داده های کم اهمیت را حذف کنیم که البته با

این کار مقداری از اطلاعات ما از بین می رود. فضایی که توسط این بردارهای ویژه (چهره های ویژه) تولید می شود را فضای ویژه می گویند. در شکل زیر نتیجه انجام این مراحل بر روی تصاویر پایگاه داده ORL را مشاهده میکنید:



شکل ۱-۲- نمونه تصاویر پایگاه داده ORL [9]

با محاسبه میانگین مجموعه این پایگاه داده شکل زیر به دست می آید




شکل ۲-۲- میانگین تصاویر ORL [9]

در شکل زیر بردار ویژگی چهره بر اساس ۱۲ مقدار ویژه بزرگتر را می بینیم



شکل ۲-۳- بردار ویژگی بر اساس ۱۲ مقدار ویژه بزرگتر [9]

البته برای اثبات این که بردار های ویژه متناظر با مقادیر ویژه کوچک شامل اطلاعات زیادی نیست به شکل زیر توجه میکنیم که بر اساس ۱۲ مقدار ویژه کوچک به دست آمده است



شکل ۲-۴ بردار ویژگی بر اساس ۱۲ مقدار ویژه کوچک [9]

اشکال این روش در این است که بین داده های درون کلاسی و داده های کلاس های دیگر تفاوتی وجود ندارد، در صورتی که ما برای کلاسه بندی نیازمند این هستیم که پراکندگی درون کلاسی کم باشد و پراکندگی برون کلاسی زیاد باشد.

## ۲-۱-۲ آنالیز اجزای مستقل<sup>۱</sup> (ICA)

ICA به عنوان یک روش کارآمد در زمینه جداسازی کور سیگنالهای صوتی مورد استفاده بوده است. استفاده از این روش برای شناسایی هویت با استفاده از تصاویر چهره توسط بارتلت<sup>۲</sup> در سال ۱۹۹۸ پیشنهاد شده است [10]. روش ICA در برابر PCA که فقط اطلاعات درجه دوم را در نظر می گیرد گشتاورهای درجه بالاتر را نیز در نظر می گیرد و قدرت بیان بالاتری نسبت به روش PCA دارد. روش ICA یک حالت کلی از روش PCA است. در این روش بردارهای انتقال الزاما متعامد نیستند، لذا پراکندگی داده ها بهتر نشان داده می شود. برای استفاده از ICA در شناسایی افراد دو روش پیشنهاد شده است. در روش اول تصاویر به عنوان متغیر و پیکسلها به عنوان مشاهده در نظر گرفته شده و در روش دوم پیکسلها به عنوان متغیر و تصاویر به عنوان مشاهده در نظر گرفته می شوند. در حالت کلی بردارهای بدست آمده در طراحی اول بیشتر خصوصیات محلی چهره را بیان می کنند در حالی که در طراحی دوم بردارها بیشتر خصوصیات کلی چهره را دارا بوده و شبیه به چهره هستند. از آنجایی که هر چهره از ترکیب خطی چند چهره خاص تولید می شود با استفاده از بسط ICA یک فضای چهره برای شناسایی تشکیل می دهیم. همانطور که گفتیم ICA حالت کلی تری نسبت به PCA است در واقع ما در PCA با یک فرض که خیلی هم دقیق نیست یعنی گوسی بودن توزیع تصاویر، تصویر را تقریب می زنیم. مشکل روش PCA این است که تنها قادر به جداسازی وابستگی های خطی بین اجزاست و وابستگی های از درجات بالاتر را نادیده می گیرد یکی از این ویژگی های مرتبه بالاتر فاز تصویر است. بارتلت با تغییر فاز یک تصویر و نشان دادن این موضوع که با تغییر فاز تصویر ماهیت تصویر تغییر می کند نا کارآمد بودن PCA را اثبات کرد و پیشنهاد کرد که برای استخراج ویژگی از روش ICA استفاده شود چون ICA امان های مرتبه بالاتر را نیز در نظر می گیرد و شامل اطلاعات فاز

---

<sup>۱</sup> Independent Component Analysis

<sup>۲</sup> Bartlett

نیز هست. بارتلت طی آزمایشاتی که انجام داد به نتایج زیر رسید:

۱. در صورت برابر بودن ابعاد ویژگی در دو بسط PCA و ICA در بیشتر موارد ICA عملکرد بهتری نسبت به PCA دارد.

۲. اگر اندازه تصویر را تغییر دهیم مقاومت ICA نسبتاً بهتر است.

۳. پایداری ICA در برابر نویز نسبت به PCA بهتر است.

## ۱-۲-۱-۲ مقایسه روشهای PCA و ICA

در مقاله ای که بروس<sup>۱</sup> و همکارا [11] برای مقایسه این دو روش ارائه کردند نتایج زیر به دست آمد: این آزمایشات بر روی پایگاه داده فریت<sup>۲</sup> انجام شده است. این پایگاه دارای تعداد ۱۴۱۲۶ عکس از ۱۱۹۶ فرد مختلف و ۳۶۵ عکس المثنی می باشد. عکس المثنی عکس از همان افراد است حدود ۲ سال بعد گرفته شده است. تصاویر استفاده شده از این پایگاه داده به چهار قسمت تقسیم شده اند قسمت fb: شامل ۱۱۹۵ عکس می باشد که این عکس ها در یک زمان از اشخاص گرفته شده است و تنها تفاوت در عکس ها تغییر اندک در حالت چهره است

قسمت تکراری اول dup 1: شامل ۷۲۲ عکس است که ۲ سال بعد از افراد گرفته شده است

قسمت تکراری 2 dup 2: شامل ۳۲۲ عکس که بعد از ۱۸ ماه از افراد گرفته شده است

قسمت fc: شامل ۱۹۲ عکس است که روشنایی تصویر در آنها تغییر کرده است در این مقاله، اندازه بردار ویژگی را برای هر دو روش برابر در نظر گرفته اند و ۴۰ درصد از بردارهای ویژه غیر صفر را انتخاب می کنند. برای تعیین کلاسه بندی تصویر از توابع متریک مختلف استفاده شده است. تابع متریک یا تابع فاصله، تابعی است که فاصله ای را بین عناصر یک مجموعه تعیین می کند. مجموعه ای

---

<sup>۱</sup> M. Bruce

<sup>۲</sup> FERET

که متریک روی آن تعریف می‌شود، فضای متریک نامیده می‌شود.

یک تابع متریک روی مجموعه  $X$  تابعی است که شرایط زیر در مورد آن صدق می‌کند:

۱. اصل جدایی یا منفی نبودن: برای هر جفت المان، خروجی متریک مقداری بزرگتر مساوی ۰ است.

۲. اصل انطباق یا هویت غیرقابل تشخیص: تنها در صورتی خروجی متریک برابر ۰ است که هر جفت المان ورودی یکسان باشند. از سوی دیگر، زمانی که دو المان ورودی یکسان باشند، قطعاً خروجی تابع فاصله (متریک) برابر ۰ خواهد بود.

۳. تقارن: خروجی متریک برای فاصله بین المان  $x$  و المان  $y$  و فاصله بین المان  $y$  و  $x$  یکسان است.

۴. نابرابری مثلثی: خروجی متریک برای فاصله بین دو المان  $x$  و  $z$  کوچکتر مساوی جمع خروجی متریک برای فاصله  $x$  و  $y$  و فاصله  $y$  و  $z$  است. در اینجا از چهار نوع تابع؛ فاصله متریک (شهر بلوک)<sup>۱</sup>، فاصله اقلیدسی<sup>۲</sup>، فاصله کسینوس<sup>۳</sup> و فاصله ماهانوبیس<sup>۴</sup> استفاده شده است که نتایج به دست آمده در جدول شکل ۲-۵ مقایسه روش های PCA و ICA آمده است

| Probe Set    | ICA (InfoMax) Arch. I |        | ICA (InfoMax) Arch. II |        | PCA    |        |        |             |
|--------------|-----------------------|--------|------------------------|--------|--------|--------|--------|-------------|
|              | Cosine                | L2     | Cosine                 | L2     | L1     | L2     | Cosine | Mahalanobis |
| fafb (1195)  | 73.72%                | 75.90% | 82.26%                 | 74.90% | 80.42% | 72.80% | 70.71% | 75.23%      |
| fafc (194)   | 5.67%                 | 5.15%  | 51.03%                 | 35.57% | 20.62% | 4.64%  | 4.64%  | 39.69%      |
| dup I (722)  | 36.15%                | 32.96% | 48.48%                 | 37.81% | 40.30% | 33.24% | 35.32% | 39.34%      |
| dup II (234) | 14.53%                | 14.53% | 32.48%                 | 25.64% | 22.22% | 14.53% | 15.38% | 24.36%      |
| Total (2345) | 50.62%                | 50.70% | 64.31%                 | 55.31% | 57.31% | 49.17% | 48.83% | 56.16%      |

شکل ۲-۵- مقایسه روش های PCA و ICA [11]

<sup>۱</sup> City block

<sup>۲</sup> Euclidean distance

<sup>۳</sup> cosine distance

<sup>۴</sup> Mahalanobis

با توجه به نتایج به دست آمده می توان این گونه تحلیل کنیم که :

۱. همانطور که انتظار داریم نتایج به دست آمده با فاصله کسینوس برای ICA نتایج بهتری را دربردارد

چون بسط ICA شامل اطلاعات زاویه یا فاز می باشد

۲. اگر شرایط ثابت باشد (حالت fb) نتایج به دست آمده از PCA و ICA تفاوت چندانی باهم ندارند

۳. در حالت های تغییر چهره با توجه به نتایج می بینم که مقاوت روش ICA بیشتر است و نتایج بهتری به ما می دهد.

۴. در وضعیت fc که نور تصاویر تغییر میکند باز هم مقاومت ICA از PCA بیشتر است.

البته با استناد به این آزمایش نمی توان گفت که همیشه روش ICA عملکرد بهتری نسبت به PCA دارد.

## ۲-۱-۳ آنالیز تفکیک پذیری خطی<sup>۱</sup> (LDA)

این روش اولین بار توسط بلهومر ارایه شده است [2]. به طور کلی اگر داده ها در یک کلاس متمرکز باشند و فاصله کلاسه های مختلف از یکدیگر زیاد باشد تولید یک تابع برای جداسازی این کلاس ها بسیار ساده خواهد بود، آنالیز تفکیک پذیری خطی که بیشتر با نام فیشر<sup>۲</sup> شناخته می شود بر این اساس کار می کند. در این روش هدف این است که داده های مربوط به یک کلاس تا حد امکان در زیر فضای جدید ایجاد شده به هم نزدیک و داده های کلاسه های مختلف از هم دور باشند، به عبارت دیگر پراکندگی بین کلاسی داده ها حداکثر و پراکندگی درون کلاسی داده ها حداقل بشود. برای رسیدن به این هدف دو ماتریس پراکندگی درون کلاسی و بین کلاسی را تشکیل می دهیم. ماتریس پراکندگی بین کلاسی، کوواریانس ماتریس تفاضل میانگین هر کلاس با میانگین کل است و نشان دهنده فاصله

<sup>۱</sup> linear discriminant Analysis

<sup>۲</sup> Fisher



و پراکندگی بین کلاسها می باشد. ماتریس پراکندگی درون کلاسی، کوواریانس ماتریس تفاضل داده‌ها با داده‌ی میانگین همان کلاس است و بیانگر میزان پراکندگی داده‌های هر کلاس می باشد. در این روش برای این که پراکندگی بین کلاس ها ماکزیمم و پراکندگی درون کلاس مینیم شود (به طور همزمان) باید رابطه زیر که شاخص فیشر است ماکزیمم بشود:

$$J(w) = \frac{|S_B|}{|S_W|} \quad (4-2)$$

که در رابطه بالا  $S_B^1$  و  $S_W^2$  به ترتیب نشان دهنده پراکندگی بین کلاس ها و درون کلاس ها می باشند و با روابط زیر به دست می آیند:

$$S_B = \sum_{i=1}^c N_i (x_i - \mu)(x_i - \mu)^T \quad (5-2)$$


$$S_W = \sum_{i=1}^c \sum_{x \in X_i} (x_k - \mu_i)(x_k - \mu_i)^T \quad (6-2)$$

در روابط بالا  $N_i$  تعداد نمونه ها در کلاس  $i$  ام،  $c$  تعداد کل کلاسها،  $\mu_i$  میانگین نمونه ها در کلاس  $i$  ام و  $X_i$  نشان دهنده مجموعه نمونه های هر کلاس می باشد. در شکل ۲-۶ بردار فضای ویژگی با اعمال LDA بر روی داده های ORI را میبینیم

---

<sup>1</sup>Between-class

<sup>2</sup>Within-class



شکل ۲-۶- بردار اول پایه با اعمال LDA [2]

نکته ای که در اجرای این روش باید مورد توجه قرار بگیرد این است که باید تعداد نمونه های آموزشی در مقایسه با فضای ابعاد نمونه ها متناسب باشد در صورتی که تعداد نمونه های آموزشی در برابر اندازه ویژگی ها کم باشد نتیجه خوبی در بر نخواهد داشت. یکی از راه حل های پیشنهاد شده برای این مشکل این است که ما ابتدا با اعمال روش PCA ابعاد ویژگی ها را کاهش دهیم و سپس با اعمال روش LDA به فضای مطلوب برای کلاسه بندی برسیم.

## ۲-۱-۴ روشهای غیر خطی

در روشهای PCA، ICA و LDA فرض بر این است که در فضای  $P$  بعدی جدید داده ها به صورت خطی تفکیک پذیر هستند در حالی که در برخی حالات امکان جدا کردن داده ها با یک یا چند صفحه وجود ندارد. مثال روشنی برای این حالت OR منطقی است که در فضای دو بعدی قابلیت جدا شدن با یک خط را ندارد. در این حالت داده ها را ابتدا به یک فضای با ابعاد بالا منتقل می کنند سپس از روشهای آماری برای جداسازی داده ها استفاده می شود، به این امید که در این فضای جدید امکان تفکیک پذیری داده ها با صفحه فراهم شود.

## ۱-۴-۱-۲ روش KPCA<sup>۱</sup>

در این روش ابتدا به وسیله یک تابع غیر خطی مثل  $\varphi(x)$  داده ها از فضای ورودی به فضای جدید انتقال می یابند و در این فضای جدید بسط PCA بر روی داده ها اعمال می شود اگر ما المان های ماتریس کرنل را به صورت زیر تعریف کنیم

$$k_{ij} = [\varphi(x_i) \cdot \varphi(x_j)] \quad (۷-۲)$$


اثبات شده است که حاصل بسط KPCA از حل مساله مقدار ویژه برای عبارت زیر به دست می آید

$$mw = kw \quad (۸-۲)$$

برای مثال در شکل زیر یک دسته داده را می بینید که به صورت دو بعدی در فضا وجود دارند همانطور که از شکل معلوم است این داده ها به صورت خطی جدا نمی شوند. برای جدا سازی این داده ها به صورت خطی آنها را توسط یک تابع غیر خطی به فضای سه بعدی منتقل می کنیم همانطور که در شکل ۷-۲ می بینیم در فضای سه بعدی امکان جداسازی با یک صفحه به صورت خطی امکان پذیر است.

---


<sup>۱</sup> Kernel Principal component analysis



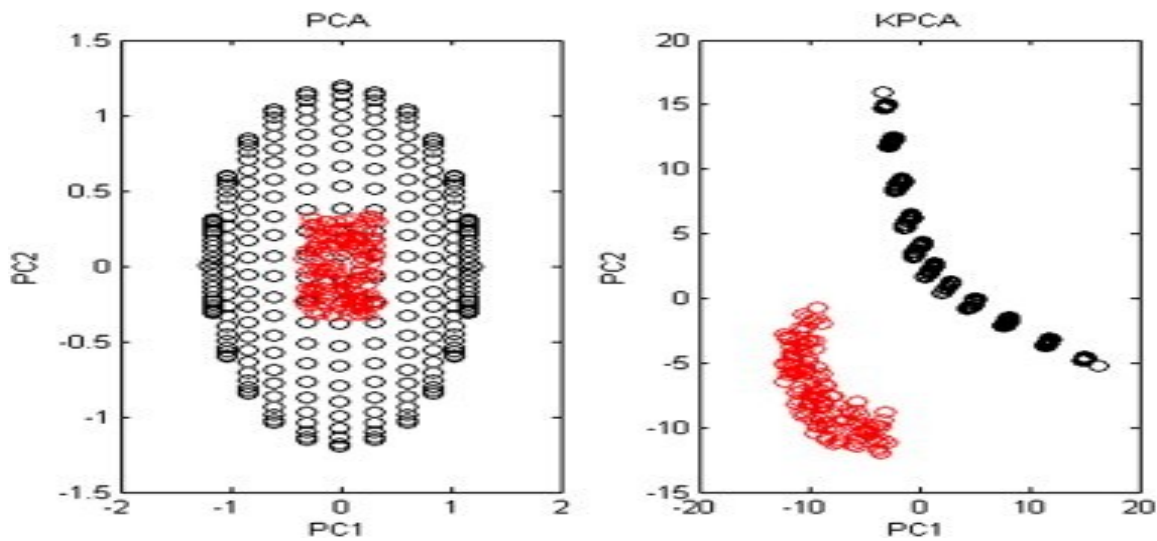
شکل ۷-۲ اعمال یک Kernel به تابع دوبعدی برای انتقال به فضای سه بعدی

[12]

در شکل های زیر تفاوت KPCA و PCA را مشاهده می کنید



شکل ۸-۲ فضای اصلی توزیع داده ها




شکل ۹-۲- نتیجه اعمال PCA و KPCA

در روش پیشنهادی یانگ [13] که بر اساس ترکیب KPCA و KFDA بود نتایج نشان داد که این الگوریتم می تواند نتایج بهتری نسبت به روشهای خطی داشته باشد.

## ۵-۱-۲ روشهای مبتنی بر ویژگی های محلی

روشهای مبتنی بر ویژگی های محلی شامل سه مرحله کلی، تراز کردن تصویر، استخراج ویژگی و کلاسه بندی می باشد که در شکل ۱۰-۲ می بینید



شکل ۱۰-۲- مراحل کلاسه بندی محلی [14]

در بیشتر این سیستم ها ابتدا تصویر ورودی باید بر اساس یک سری پیش پردازش مرتب و تنظیم

شود. این پیش پردازشها می تواند شامل چرخش، انتقال و تغییر مقیاس باشد. بعد از تنظیم تصویر ورودی، تصویر بلوک بندی شده و بعد از استخراج ویژگی کلاسه بندی صورت می پذیرد.

## ۱-۵-۱-۲ ویولت گابور<sup>۱</sup>


یکی از روشهای مورد توجه برای استخراج ویژگی استفاده از فیلترهای چند فرکانسی جهت دار یا MSMD می باشد، که فیلتر گابور یکی از این فیلترها می باشد. فیلتر گابور در حوزه مکان یک موج سینوسی است که با یک پوش گوسی مدوله می شود و هر فیلتر گابور را می توان در حوزه مکان یا زمان تعریف کرد. تابع اصلی فیلتر گابور به صورت (۹-۲) می باشد.

$$\psi_{\mu,\nu}(z) = \frac{\|K_{\mu,\nu}\|^2}{\sigma^2} \exp\left(-\frac{\|K_{\mu,\nu}\|^2 \|z\|^2}{2\sigma^2}\right) \left[ \exp(iK_{\mu,\nu}z) - \exp\left(-\frac{\sigma^2}{2}\right) \right] \quad (9-2)$$


$$K_{\mu,\nu} = K_{\nu} e^{i\phi_{\mu}} \quad (10-2)$$

در این رابطه  $\mu$  جهت فیلتر و  $\nu$  مقیاس فیلتر،  $z=(x,y)$  که  $K_{\nu} = \frac{K_{max}}{f^{\nu}}$ ،  $\phi_{\mu} = \frac{\pi\mu}{8}$  و  $K_{max}$  نشان دهنده بیشترین فرکانس و  $f$  بیانگر فاکتور فاصله بندی بین هسته ها در حوزه فرکانس می باشد. معمولاً برای این که بتوان تا جایی که امکان دارد ویژگی های متفاوت از یک تصویر در جهت ها و مقیاس های مختلف استخراج گردد باید پارامترهای فیلتر گابور به درستی انتخاب بشوند که انتخاب این پارامترها روش خاص و مشخصی ندارد و بیشتر به صورت تجربه و مشاهده تعیین می شوند. برای مثال در شکل ۱-۲ که هشت جهت و پنج مقیاس به صورت  $\sigma = f\sqrt{2}$ ،  $\mu \in \{0, \dots, 7\}$  و  $\nu \in \{0, \dots, 4\}$  در نظر گرفته شده است.  $K_{max} = \frac{\pi}{2} 2\pi$

<sup>1</sup> Gabor wavelet



(a)



(b)

شکل ۱۱-۲-ویولت گابور: a: قسمت حقیقی فیلتر گابور با ۸ جهت و پنج مقیاس b: دامنه فیلتر گابور در چند مقیاس مختلف [15]

فیلتر گابور هم در حوزه مکان وهم در حوزه زمان قابل تعریف است. در صورتی که فیلتر در حوزه مکان باشد باید با تصویر ورودی کانوال بشود. در صورتی تصویر ورودی  $I(x,y)$  باشد کانوال به صورت زیر تعریف می شود:


$$O_{\mu,\nu}(z) = I(z) * \psi_{\mu,\nu}(z) \quad (11-2)$$

که \* عملگر کانولوشن می باشد و  $O_{\mu,\nu}(z)$  نتیجه کانولوشن تصویر با تابع گابور می باشد. با توجه به این که ضرب در حوزه فرکانس سریع تر از عمل کانولوشن می باشد می توانیم ابتدا از تصویر تبدیل فوریه سریع FFT بگیریم و با فیلتر گابور حوزه فرکانس ضرب کنیم ونتیجه به دست آمده را با گرفتن عکس تبدیل فوریه به حوزه مکان برگردانیم.

$$\mathcal{F}\{O_{\mu,\nu}(z)\} = \mathcal{F}\{I(z)\} * \mathcal{F}\{\psi_{\mu,\nu}(z)\} \quad (12-2)$$

$$O_{\mu,\nu}(z) = \mathcal{F}^{-1} \left\{ \mathcal{F}\{I(z)\} * \mathcal{F}\{\psi_{\mu,\nu}(z)\} \right\} \quad (13-2)$$

شکل (۱۲-۲) نشان دهنده یک فیلتر گابور اعمال شده بر روی یک تصویر می باشد



شکل ۱۲-۲- فیلتر گابور a: قسمت حقیقی b: دامنه تصویر [15]


با توجه به این که فیلتر گابور تغییرات دامنه شدت تصویر را در فرکانس های خاص در نظر می گیرد نسبت به تغییرات روشنایی تصویر مقاوم است .

در روشی که در [3] ارائه شد و بیشتر با نام گراف الاستیکی<sup>۱</sup> (EBGM) شناخته می شود. چهره به

<sup>1</sup> Elastic Baunch Graph Matching(EBGM)



صورت یک گراف که از نقاط برجسته مثل دهان، بینی و... تشکیل شده در نظر گرفته می شود و تعدادی ضریب برای هر کدام از این نقاط با اعمال یک فیلتر گابور به دست می آید که به این ضرایب جت<sup>۱</sup> می گویند و این ضرایب به عنوان ویژگی برای شناسایی مورد استفاده قرار می گیرند.




شکل ۲-۱۳- نمونه ای از گراف چهره از پایگاه داده FRET [16]

## ۲-۵-۱-۲ روش الگوی باینری محلی<sup>۲</sup> (LBP)

یکی از روشهای استخراج ویژگی آماری الگوی باینری محلی یا LBP می باشد که اولین بار توسط اجلامعرفی شد [4]. در LBP پایه، یک همسایگی ۳\*۳ از یک پیکسل در نظر گرفته می شود و پیکسل های همسایه توسط یک تابع منطقی با پیکسل وسط مقایسه می شوند و با صفر و یک جایگزین می گردند و در آخر جمع وزن دار پیکسل های همسایه با پیکسل وسط جایگزین می گردد.

<sup>۱</sup> Jet

<sup>۲</sup> Local Binary Patterns



شکل ۲-۱۴-عملگر الگوی باینری محلی [16]

برای بیان یک پیکسل با مختصات  $(x_c, y_c)$  به صورت کد دسیمال از رابطه زیر استفاده می کنیم :

$$LBP_{P,R}(x_c, y_c) = \sum_{p=0}^{P-1} s(i_p - i_c) 2^p \quad (۱۴-۲)$$

که در این رابطه  $i_c$  مقدار تصویر در نقطه مرکز همسایگی و  $i_p$  مقدار تصویر در همسایگی هابا شعاع R می باشد و تابع S نیز با رابطه زیر تعریف می شود

$$s(x) = \begin{cases} 1 & \text{if } x \geq 0 \\ 0 & \text{if } x < 0 \end{cases} \quad (۱۵-۲)$$

با محاسبه هیستوگرام بر روی تصویر LBP می توانیم به اطاعات بافت مهم برسیم. در سالهای اخیر روشهای زیادی با استفاده از روش LBP ارائه شده است برای مثال د [17] روشی به نام LTP ارائه شد. در این روش که تنها تفاوت آن با LBP جایگزین کردن یک مقدار غیر صفر به جای آستانه، برای اندازه گیری اختلاف بین پیکسل مرکزی و همسایه ها می باشد نتایج به دست آمده بیانگر تفاوت این روش نسبت به تغییر روشنایی تصاویر می باشد.

## ۳-۵-۱-۲ تبدیل ویژگی غیر حساس به بزرگنمایی<sup>۱</sup> (SIFT)

توصیفگر SIFT یکی از بهترین روشها برای استخراج ویژگی هایی است که حساسیت کمی نسبت به چرخش<sup>۲</sup>، بزرگنمایی<sup>۳</sup>، تغییر زاویه دید، تغییرات نور و کشیدگی تصویر<sup>۴</sup> داشته باشند. اجرای این روش معمولاً در چهار مرحله صورت می گیرد (۱) تعیین نقاط کلیدی<sup>۵</sup> در فضا (۲) حذف نقاط غیر قابل اطمینان (۳) تعیین جهت گیری<sup>۶</sup> (۴) محاسبه نقاط کلیدی توصیف کننده (۵) تطبیق

در گام اول باید نقاط جذاب که نقاط کلیدی نامیده می شوند را در فضای مقیاسی تعیین کنیم برای این کار از یک تابع گوسین استفاده می کنیم. در صورتی که فضای مقیاسی  $L(x, y, \sigma)$  و تابع گوسین  $G(x, y, \sigma)$  و تصویر ورودی  $I(x, y)$  باشد طبق معادله (۲-۱۶) فضای مقیاسی، با کانولوشن تصویر ورودی با تابع گوسی به دست می آید

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \quad (۱۶-۲)$$

$$G(x, y, \sigma) = \frac{1}{2\sigma^2} \exp - \left( \frac{x^2 + y^2}{2\sigma^2} \right) \quad (۱۷-۲)$$

$\sigma$  نشان دهنده انحراف استاندارد می باشد. حال برای انتخاب نقاط کلیدی ابتدا با تفریق سطوح مقیاسی مجاور هم فضای جدید  $D(x, y, \sigma)$  را به دست می آوریم:

$$D(x, y, \sigma) = L(x, y, k\sigma) - L(x, y, \sigma) \quad (۱۸-۲)$$

<sup>۱</sup>Scale- Invariant Feature Transform

<sup>۲</sup>Rotation


<sup>۳</sup>Scale

<sup>۴</sup>Affine

<sup>۵</sup>Keypoint

<sup>۶</sup>orientation

مرحله بعدی به دست آوردن ماکزیمم و مینیمم محلی در  $D(x, y, \sigma)$  می باشد که با مقایسه هر پیکسل با همسایگی های ۲۶ گانه در یک ناحیه  $3 \times 3$  صورت می گیرد اگر نقطه مورد نظر بزرگتر یا کوچکتر از همه نقاط بود به عنوان نقطه کلیدی انتخاب می شود.



شکل ۲-۱۵- مقایسه یک پیکسل با همسایه های ۲۶ گانه برای به دست آوردن اکسترمم های محلی

[18]

در گام دوم باید نقاطی که خیلی مهم نیستند را حذف کنیم برای این منظور دو پارامتر در نظر گرفته می شود. پارامتر اول محاسبه مقدار  $|D(x, y, \sigma)|$  برای هر نقطه کلیدی می باشد با محاسبه این مقدار در صورتی که اندازه آن از یک آستانه مشخص کمتر باشد به این معنی است که آن نقطه شامل کنتراست<sup>۱</sup> کمی است در نتیجه این نقطه کلیدی را حذف می کنیم.

<sup>1</sup> Contrast

پارامتر دوم محاسبه نسبت انحنای اصلی<sup>۱</sup> برای هر نقطه کلیدی می باشد تا از روی این مقدار نقاط پیک ضعیف را در تابع اختلاف گوسین  $D(x, y, \sigma)$  به دست آوریم. با در نظر گرفتن یک آستانه نقطای که انحنای آنها از آستانه بیشتر باشد حذف می شوند.

گام سوم تعیین جهت برای نقاط کلیدی می باشد که این کار توسط هیستوگرام جهت گیری گرادیان صورت می گیرد.


$$m(x, y) = \sqrt{((L(x+1, y) - L(x-1, y)))^2 + (L(x, y+1) - L(x, y-1))^2} \quad (19-2)$$

$$\theta(x, y) = \frac{\tanh(L(x, y+1) - L(x, y-1))}{(L(x+1, y) - L(x-1, y))} \quad (20-2)$$

$\theta(x, y)$  بیانگر جهت گیری گرادیان و  $m(x, y)$  نشان دهنده دامنه گرادیان است. در مرحله چهارم توصیفگر نقاط کلیدی که همان بردار ویژگی مورد نظر ما می باشد تشکیل می گردد برای این منظور ابتدا دامنه و جهت گرادیان در اطراف نقاط کلیدی محاسبه می شود سپس با توجه به ابعاد مورد نظر برای انتخاب ویژگی تصویر به بخش هایی تقسیم می گردد و هیستوگرام هر بخش محاسبه می گردد. برای مثال اگر تصویر به ناحیه های  $4*4$  تقسیم شود و ما ۸ جهت گرادیان را برای آن در نظر بگیریم طول بردار ویژگی ما  $4*4*8$  برای هر نقطه می شود.

---

<sup>۱</sup>Principal Curvatures



شکل ۲-۱۶- تولید توصیفگر نقاط کلیدی با محاسبه دامنه و جهت گرادیان اطراف نقاط کلیدی (شکل چپ) محاسبه هیستوگرام جهت در یک ناحیه ۴\*۴ (شکل چپ) [18]

## ۶-۱-۲ مقایسه روشها

تا اینجا ما دو روش کلی شناسایی مبتنی بر ویژگی کلی و محلی را بررسی کردیم که با توجه به نتایج به دست آمده در تحقیقات می توان گفت که روش های مبتنی بر ویژگی محلی به علت مقاومت در برابر نویز (تغییر روشنایی، اندازه تصویر، تغییر حالت چهره و...) موفقیت بیشتری دارند. در عین حال اگر ما تصویر بدون نویز داشته باشیم این روش ویژگی کلی می باشد که برتری دارد.

در تحقیق [19] که بر روی پایگاه داده FRET انجام شد نشان می دهد که روش LBP در حالتی که میزان روشنایی تصویر تغییر می کند نسبت به روش SIFT عملکرد بهتری دارد. اما روش فیلتر گابور نسبت به هر دو این روشها نتیجه بهتری به ما می دهد.

## ۲-۲ روشهای مبتنی بر تصویر سه بعدی

روش شناسایی بر اساس تصویر سه بعدی در سال های اخیر برای غلبه بر مشکلاتی که در روش دو بعدی وجود دارد مورد توجه قرار گرفته است. با توجه به این که در تصویر سه بعدی اطلاعات مورد استفاده عمق نقطه می باشد میزان شدت روشنایی، مواردی مثل تغییر میزان نور، آرایش صورت، رنگ پوست و همچنین زاویه تابش نور به صورت تأثیری بر اطلاعات ما ندارد و تصویر ما ثابت است. ویژگی مهم دیگر تصویر سه بعدی این است که این تصاویر قابلیت چرخش در فضا را دارد و در صورتی که تصویر ما از زاویه دلخواه گرفته نشده باشد می توان آن را چرخاند و در زاویه دلخواه معادل آن را به دست آورد. در حال حاضر اکثر سیستم های تصویر برداری سه بعدی تنها این قابلیت را دارند که از رویه قابل رویت چهره تصویر را بگیرند (مشکل در استخراج عمق مو) هر چند روشهایی برای استخراج کامل رویه وجود دارد که برای کاربرد شناسایی که عملی باشد مقرون به صرفه نیست. با توجه به اینکه رویه ای که توسط اسکنر های لیزری معمول به دست می آید کامل نیست به آن تصویر ۲.۵ بعدی هم می گویند. اطلاعات رویه چهره به دو صورت ابر نقطه<sup>۱</sup> و نقشه عمقی<sup>۲</sup> ذخیره می شوند.

در حالت ابر نقطه ای اطلاعات به صورت  $[x y z]$  می باشد که در آن الزامات مختصات نقطه عدد صحیح نیست و می توان برای مختصات یک نقطه بیش از یک نقطه عمق را ذخیره کرد. اما در حالت نقشه عمقی اطلاعات به صورت یک ماتریس بیان می شود در نتیجه مختصات نقاط عدد صحیح می باشد و امکان ذخیره دو مقدار برای یک نقطه وجود ندارد. مزیت ذخیره داده به صورت نقشه عمقی این است که می توان این تصویر را به صورت تصویر شدت روشنایی در نظر گرفت و تقریباً تمام روشهایی که برای تصویر دو بعدی به کار می رود را بر روی تصاویر نقشه عمقی اجرا کرد. در اینجا ما دوباره روشهای شناسایی را به دو دسته تقسیم می کنیم. روش اول مبتنی بر استخراج ویژگی از کل تصاویر

---

<sup>۱</sup> Pointcloud

<sup>۲</sup> Depth Map

می باشد و روش دوم مبتنی بر استخراج ویژگی به صورت محلی است.

## ۱-۲-۲ روش PCA و LDA

نحوه اجرای این روشها در بخش ۱-۲-۱ و ۱-۲-۳ آورده شده است. در [20] روش PCA را بر روی ۲۲۲ تصویر سه بعدی که از ۳۷ فرد مختلف با ۶ حالت چهره متمایز گرفته شده بود اجرا کردند. در این روش ابتدا هر تصویر را توسط بینی تراز کرده و با اعمال PCA فضای ویژگی را کاهش دادند و در نتیجه کمترین مقدار خطایی که به دست آمد حدود ۱۷.۸ درصد بوده است. در [21] با اجرای روش LDA بر روی ۱۴۷۰ عکس از ۲۳۰ شخص متفاوت نتیجه بهتری نسبت به روش PCA به دست آوردند و کمترین میزان خطا در آزمایش آنها حدود ۱۵.۳ درصد بوده است.

## ۲-۲-۲ روش فاصله هاسادروف<sup>۱</sup>

فاصله هاسادروف یکی از معیار های تعیین میزان شباهت بین دو مجموعه می باشد که به طور گسترده در حل مسایل مختلف کاربرد دارد. طبق تعریف فاصله هاسادروف برای دو مجموعه A و B به صورت زیر تعریف می گردد.

$$H(A, B) = \max(h(A, B), h(B, A)) \quad (21-2)$$

که در رابطه بالا h معروف به هاسادروف مستقیم می باشد و با رابطه زیر تعیین می شود

$$h(A, B) = \max_{a \in A} \min_{b \in B} \|a - b\| \quad (22-2)$$

که  $\|x\|$  بیانگر نرم عبارت می باشد. هر چه فاصله نقاطی که در A و B هستند کم تر باشد  $h(A, B)$

مقدار کم تری دارد. به همین ترتیب  $h(B, A)$  نیز مقدار کمتری دارد. علاوه بر این  $H(A, B) =$

$H(B, A)$  زمانی کم هستند که  $h(A, B)$  و  $h(B, A)$  مقدار کمی داشته باشند.

---

<sup>۱</sup>Hausdorff Distance



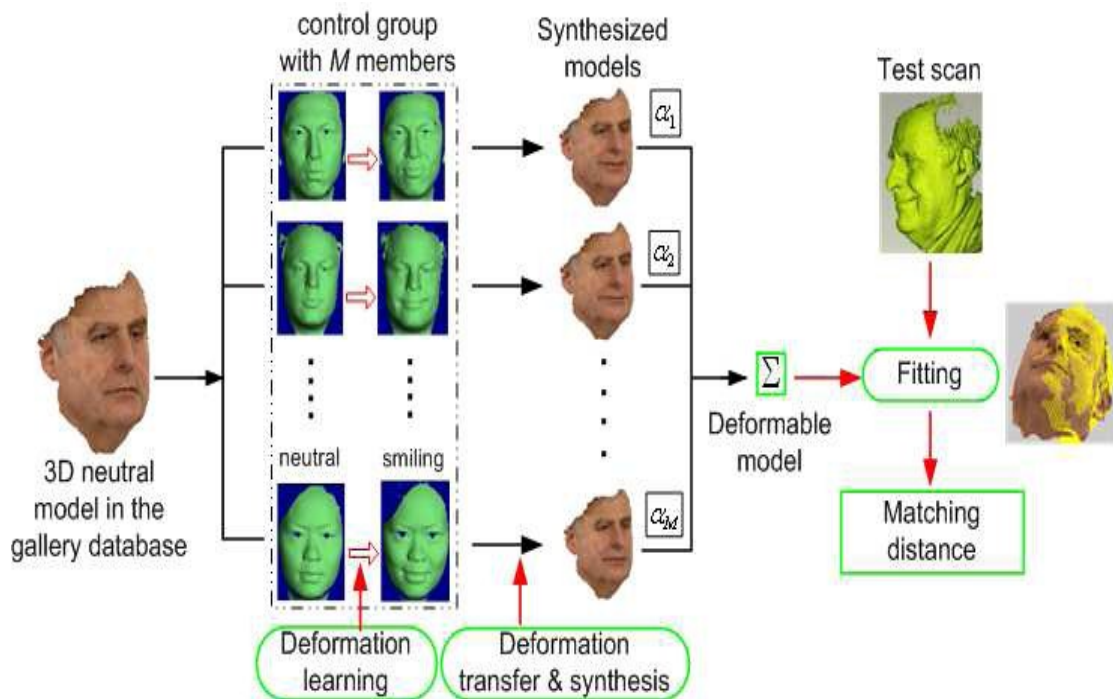
طبق [22] که با اجرای الگوریتم فاصله هاسادروف بر روی ۲۴۰ تصویر سه بعدی صورت گرفت (۱۰ تصویر از ۲۴ نفر) در بعضی از حالات درصد کامل تشخیص نیز حاصل شد. در مقاله دیگر [23] و الگوریتم PCA و هاسادروف بر روی تصاویر سه بعدی پایگاه 3D-RMA اعمال شد که نتیجه به دست آمده برای الگوریتم هاسادروف میزان خطای EER بین ۳ تا ۵ درصد را نشان می دهد و برای PCA میزان EER بین ۵ تا ۷ درصد می باشد.

### ۳-۲-۲ مدل دگردیس<sup>۱</sup>

چهره انسان غیر ثابت است و با توجه به حالت انسان وضعیت چهره اش نیز تغییر می کند و این موضوع یکی از مشکلاتی است که در سیستم های شناسایی وجود دارد. یکی از روش هایی که برای غلبه بر این مشکل ارایه شد روش مدل دگردیس می باشد. که در این روش برای هر تصویر موجود در گالری، توسط گروه کنترل، حالت های مختلف چهره ساخته می شود و از این تصویر ساخته شده برای شناسایی استفاده می کنیم. گروه کنترل شامل قالب هایی از حالات مختلف چهره می باشد. نحوه اجرای این روش به صورت نمودار زیر می باشد.

---

<sup>۱</sup> Deformable Model



شکل ۲-۱۷- مراحل اجرای روش مدل دگر دیس [24]

## ۴-۲-۲ روشهای جزء نگر شناسایی چهره سه بعدی

روش ویژگی های محلی معولا نسبت به روش کل نگر موفق تر می باشد. این روش را می توانیم بر اساس نوع ویژگی استخراج شده به دسته هایی مانند نقطه مبنا<sup>۱</sup>، انحنا مبنا<sup>۲</sup>، بخش مبنا<sup>۳</sup>، توصیفگر عمومی<sup>۴</sup> و ترکیب ویژگی های مختلف<sup>۵</sup> تقسیم بندی کنیم.

### ۱-۴-۲-۲ روش نقطه مبنا

در این روش اطلاعات ناهمسان از مجموعه نقاط اصلی استخراج می گردد. مثلا فاصله لبه بین نقاط

<sup>۱</sup>Point based

<sup>۲</sup>Curve based

<sup>۳</sup>Region based

<sup>۴</sup>General descriptor

<sup>۵</sup>Multiple shape feature fusion

ویا زاویه بین لبه ها می تواند جزء این ویژگی ها باشند. در روش پیشنهادی [25] ابتدا تعداد ۲۵ نقطه از چهره به صورت دستی مشخص می شوند. سپس فاصله بین این نقاط توسط دو معیار اقلیدسی<sup>۱</sup> و ژئودسیک<sup>۲</sup> (کوتاه ترین خط ترسیم شده بین دو نقطه در روی سطح) به عنوان ویژگی محاسبه می شود و برای تصمیم گیری نهایی LDA را بر روی ویژگی ها اعمال می کنیم. با اجرای این روش روی ۱۱۲۸ عکس از ۱۰۵ نفر نتیجه به دست آمده نشانگر عملکرد بهتر در حالتی است که از فاصله ژئودسیک استفاده می کنیم در این حالت میزان خطا EER حدود ۱.۳ درصد گزارش شده است و در حالت فاصله اقلیدسی میزان خطای EER حدود ۱.۶ درصد است.

## ۲-۴-۲-۲ روش انحنا مینا

در این روش برای تشخیص از مقایسه انحناهای متناظر در تصاویر سه بعدی استفاده می شود. در روش پیشنهادی [25] ابتدا چهره را توسط انحناهای اصلی بخش بندی کرده سپس یک طرح متقارن از چهره که در برابر تغییرات مقاوم است را جدا می کنند. در آزمایش آن ها که بر روی نمونه های کمی انجام شد درصد شناسایی کامل به دست آمد.

در روش [26] ابتدا انحناهای تصویر در نقاط برجسته لبه ها<sup>۳</sup> و دره ها<sup>۴</sup> محاسبه می شود. گرافی که از ترکیب این انحناها به دست می آید می تواند به عنوان ویژگی برای تطبیق تصویرها به کار می رود. نتیجه اجرای این روش بر روی پایگاه داده GAVAB دقت شناسایی ۹۱ درصد را نشان می دهد.

در روش [27] آنها با محاسبه انحناهای اصلی تصاویر لبه را به دست آوردند. در تصاویر لبه خط هایی به دور نقاط مهم چهره مثل چشم ها، بینی و دهان وجود دارد. سپس آنها با استفاده از معیار فاصله هاساروف به مقایسه تصاویر لبه برای شناسایی استفاده کردند. با اجرای این روش بر روی پایگاه داده

<sup>۱</sup>Euclidean

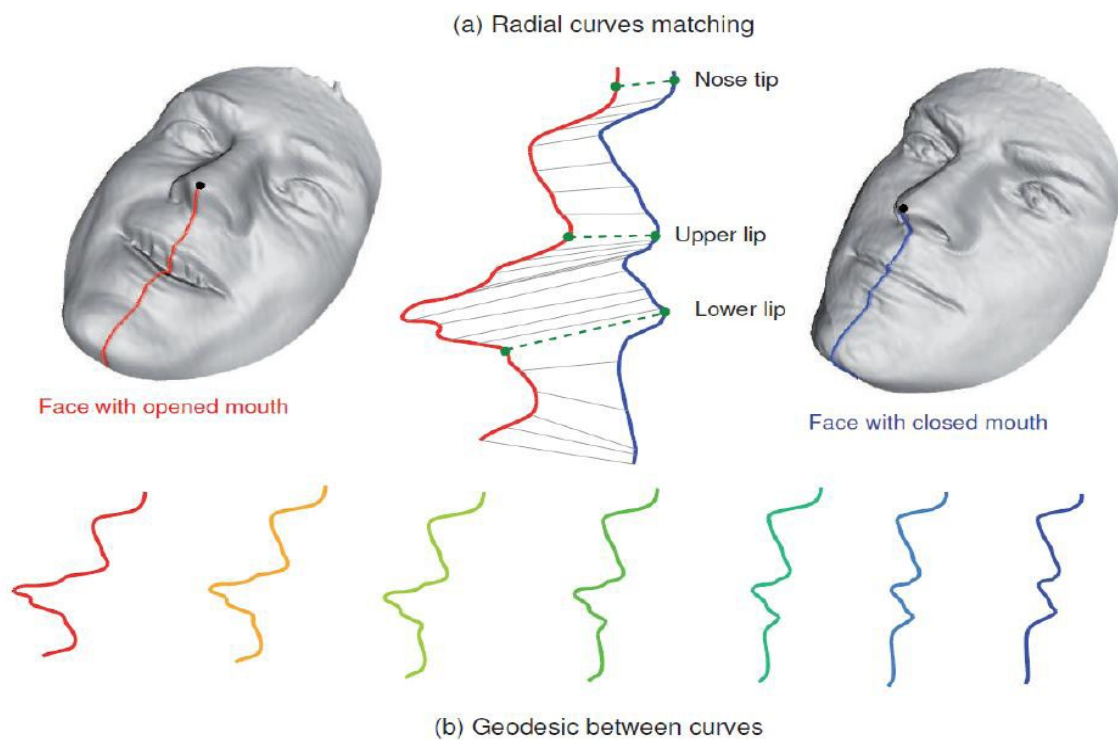
<sup>۲</sup>Geodesic

<sup>۳</sup>Salient ridges

<sup>۴</sup>Ravines

GAVAB نتیجه شناسایی در حالت طبیعی ۹۳.۵ درصد می باشد و در حالت چهره همراه با لبخند دقت شناسایی ۸۲ درصد است.

در [28] انحنای شعاعی<sup>۱</sup> را برای شناسایی معرفی کردند. در این روش برای توصیف هر چهره از مجموعه ای از انحنای شعاعی که از نوک بینی شروع شده اند استفاده می شود. برای مقایسه نیز از معیار فاصله ژئودسیک استفاده شد. با اجرای این روش بر روی پایگاه GAVAB دقت شناسایی ۹۰ درصد گزارش شده است. مراحل اجرای این روش در شکل آمده است.



شکل ۲-۱۸- انحنای شعاعی [28]

## ۲-۲-۲-۲ روشهای مبتنی بر بخش بندی

به طور کلی سطح چهره را می توان به قسمت های سخت و غیر سخت تقسیم بندی کرد. در این روش ما به دنبال این هستیم که ابتدا بخش های غیر سخت (انعطاف پذیر) را تشخیص داده سپس اثر این بخش ها را با کم کردن وزن آنها کاهش بدهیم. در روش پیشنهاد [29] از امضای نقاط برای توصیف

<sup>۱</sup>Radial Curves

چهره استفاده شده است. با توجه به این که در تمام سطح چهره تنها بخش پایین بینی و بالای پیشانی جزو بخش های سخت هستند از این بخش ها برای تطبیق استفاده شد نتیجه اجرا شده بر روی یک دیتای کوچک دقت شناسایی کامل را به ما می دهد.


در روش پیشنهادی [30] از خطوط همتراز<sup>۱</sup> برای بخش بندی تصویر عمق استفاده شد علاوه بر این آنها در روش خود نمونه برداری را در وضعیت های تکراری انجام دادند. دقت شناسایی این روش بر روی ۷۰ عکس از ۳۵ نفر حدود ۹۳ درصد بوده است.

در روش پیشنهادی [31] بخش بندی تصویر توسط انحنای گوسین انجام شد و بردار ویژگی شامل اطلاعاتی از زاویه فاصله انحنای می باشد. اجرای این روش بر روی قسمتی از داده های GAVAB دقت ۷۸ درصد را مشخص می کند.

در روش [32] ابتدا سطح چهره مانند شکل ۲-۱۹ توسط یک روش خودکار بریده می شود. سپس از هر قسمت ویژگی انحنای استخراج می گردد و توسط LDA کلاسه بندی می شود با اجرای این روش بر روی داده های FRGC دقت تشخیص ۹۷.۵ درصد به دست می آید. با اجرای همین روش بر روی داده های Bosphours دقت تشخیص ۹۸.۲ درصد به دست می آید.

---

<sup>۱</sup>Contour Lines



شکل ۲-۱۹ قسمت بندی تصویر در روش Alyuz [32]

#### ۴-۴-۲-۲ روش توصیفگر عمومی

در این روش برای استخراج ویژگی از تصاویر از عملیات بر روی همسایگی ها استفاده می شود. در [33] از ساختار پیچیده ویولت مشابه متریک<sup>۱</sup> (CW-SSIM) برای استخراج ویژگی استفاده کردند. این روش در برابر تغییرات کوچک هندسی صورت مقاوم و موثر است. مقایسه این روش با روش هاسادروف بر روی ۳۶۰ عکس از ۱۲ نفر نشان دهنده عملکرد بهتر این روش می باشد.

در [34] ابتدا اختلاف عمق بین همسایگی ها در تصویر عمق محاسبه می گردد سپس بر اساس نسبت هیستوگرام میزان تفاوت عمق هر تصویر مشخص می شود. نتیجه اعمال این روش بر روی داده های FRGC دقت ۸۷ درصد را نشان می دهد.

<sup>۱</sup>Complex Wavelet Structural Similarity Metrice

## ۵-۴-۲-۲ روش مبتنی بر چند نوع ویژگی

تمام روش هایی که در بالا مورد بررسی قرار گرفتند می توانند برای رسیدن به نتیجه بهتر با هم ترکیب بشوند. در تحقیق [34] ابتدا فضای چهره بر مبنای انحنا بخش بندی می شود سپس دو نوع ویژگی انحنا و اندازه متریک ویژگی ها برای شناسایی مورد استفاده قرار می گیرد. نتیجه این روش برای ۲۴ تصویر از ۸ نفر درصد کامل شناسایی را نشان می دهد.

در روش پیشنهاد [35] ابتدا تصویر سه بعدی که به صورت ابر نقطه است به شکل یک شبکه منظم تبدیل می شود. سپس مختصات بینی حساب می شود و به وسیله بینی نقاط محلی دیگر را نیز مشخص می کنیم. سپس با محاسبه گشتاورگوسین<sup>۱</sup> -هرمیت<sup>۱</sup> برای هر یک از این نقاط محلی، از آن به عنوان بردار ویژگی استفاده می کنیم. سپس با اعمال PCA ابعاد ویژگی را کاهش داده و در نهایت با استفاده از معیار نزدیکترین همسایه دسته بندی را انجام می دهیم. دقت شناسایی به دست آمده بر روی پایگاه داده 3D-RMA حدود ۷۲ درصد می باشد.

در روش پیشنهادی [37] بردار ویژگی ترکیبی از هفت انحنا به همراه برخی از زاویه ها و فاصله می باشد و برای دسته بندی از SVM استفاده شده است. نتیجه به دست آمده دقت حدود ۹۵ درصد را نشان می دهد. در مقاله [36] به ازای هر تصویر ۳۰ ویژگی متفاوت که ترکیبی از فاصله، زاویه، انحنا و موارد دیگر می باشد محاسبه می شود. برای دسته بندی از دو روش PCA و SVM بر روی بخشی از داده های GAVAB استفاده شد (شامل تصاویر با دید از جلو) نتیجه حاصل به ترتیب ۸۲ و ۹۰.۱۶ را نشان می دهد. در صورتی که از تصاویر شامل چرخش نیز استفاده کنیم جواب ها به ۷۶.۲ و ۷۷.۹ درصد می رسد.

---

<sup>1</sup> Gaussian-Hermite Moments

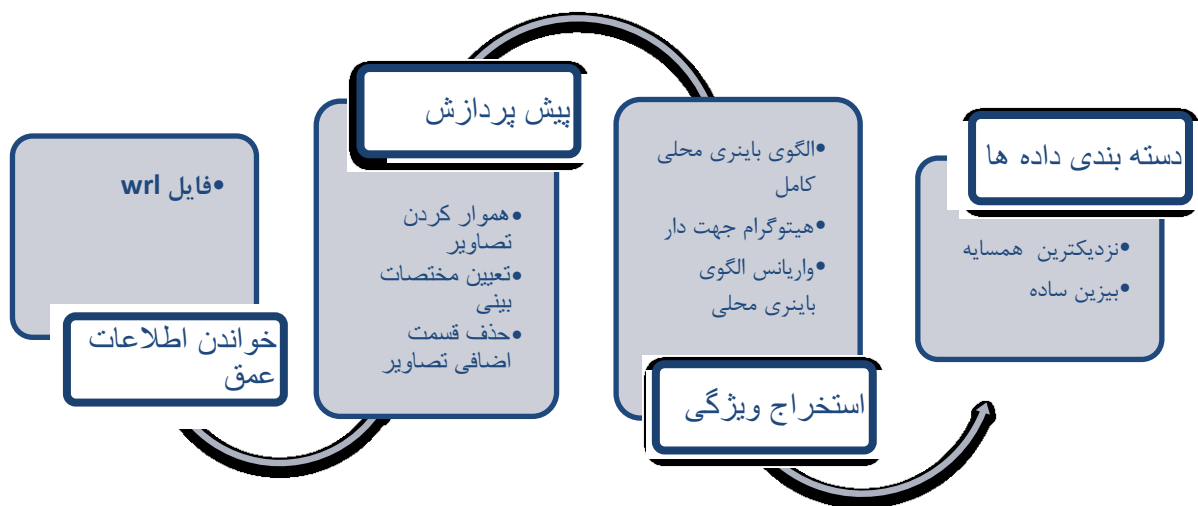




**۳: روش پیشنهادی**

### ۳-۱ کلیات روش پیشنهادی


در این بخش به بررسی روش پیاده شده در این تحقیق می پردازیم. به طور کلی در روش پیشنهادی ، ابتدا اطلاعات عمق هر تصاویر از فایل های WTI استخراج می شود و پس از آن پیش پردازش های مورد نیاز برای حذف نویز و مسطح کردن تصاویر انجام می گیرد، در مرحله بعد موقعیت نوک بینی تعیین می شود و با توجه به مختصات نوک بینی قسمت های اضافی تصاویر حذف می گردد. در مرحله بعد استخراج ویژگی توسط روش های ارائه شده انجام می گیرد و در صورت نیاز ابعاد ویژگی توسط روش LDA کاهش می یابد. در مرحله آخر کلاسه بندی داده ها توسط روش های K- نزدیکترین همسایه و بیزین ساده انجام می گیرد. کلیات روش پیشنهادی در مراحل مختلف در شکل ۱-۱ آمده است



شکل ۳-۱- کلیات روش پیشنهادی

## ۲-۳ دیتابیس تصویر سه بعدی<sup>۱</sup>

تعداد زیادی دیتا بیس تصویر سه بعدی در حال حاضر وجود دارد که از جمله معروفترین آنها می توان از XM2VTS ، USF3D ، 3DRMA ، 3DTE C ، GAVAB ، BU-3DFE ، FRGC v2.0 ، FRAV3D را نام برد [37]. از بین این دیتابیس ها دیتا بیس FRGCv2.0 دارای بیشترین تعداد تصویر می باشد و همچنین دیتا بیس 3DTEC شامل عکسهایی از دوقلوهای همسان می باشد و دیتا بیس های FRGC v2.0 ، BU-3DFE ، Gavab از لحاظ شامل بودن اکثر تغییرات حالت چهره مورد قبول می باشند. در این پایان نامه ما از دیتابیس Gavab استفاده کرده ایم. این پایگاه داده شامل ۵۴۹ تصویر از چهره ۶۱ نفر می باشد که توسط دوربین Minolta Vivid700 تهیه شده است. تصاویر از ۴۵ مرد و ۱۶ زن که سن آنها بین ۱۸ تا ۴۰ می باشد گرفته شده است. از هر نفر ۹ عکس گرفته شده است که هر کدام از این عکس ها شامل یک تغییر در حالت چهره می باشد. در تصویر زیر بخشی از تصاویر گرفته شده برای یک فرد را می بینیم.



شکل ۲-۳- تصویر دیتا بیس Gavab [38]


<sup>۱</sup>3d face database

## ۳-۳ پیش پردازش

جهت آماده سازی تصاویر برای استخراج ویژگی چند مرحله برای پیش پردازش روی تصاویر انجام می شود. در مرحله اول با توجه به خطاهای موجود در تصویر برداری سه بعدی، تصاویر ورودی را برای حذف نویز مورد پردازش قرار می دهیم و نویزهای حفره<sup>۱</sup> و پرش<sup>۲</sup> را حذف می کنیم. در مرحله بعد با پیدا کردن مختصات نوک بینی، قسمت های اضافی تصاویر مثل ناحیه گردن و گوش را حذف می کنیم.

### ۱-۳-۳ حذف نویز پرش

نویز پرش یا سوزنی به نقاطی در تصاویر گفته می شود که مقدار پیکسل در آن نقطه با مقادیر همسایه ها خیلی متفاوت است. که در شکل ۳-۳ نویز پرش را مشاهده می کنیم.



شکل ۳-۳-نویز پرش [28]

برای حذف این نویز می توان از روش های فیلتر کردن و یا آنالیز های ژئومتریک<sup>۳</sup> استفاده کرد. متداول-ترین روش برای حذف این نویز استفاده از فیلتر میانگین<sup>۴</sup> می باشد که با توجه به ساده بودن این فیلتر بسیار مورد استفاده قرار می گیرد. در این روش مقدار هر پیکسل با مقدار میانگین

---

<sup>۱</sup>Hole  
<sup>۲</sup>Spike  
<sup>۳</sup>Geometrical  
<sup>۴</sup>Median

همسایگی‌ها جایگزین می‌شود. البته می‌توان از روش فیلتر گوسین<sup>۱</sup> نیز برای حذف نویز پرش استفاده کرد. در دسته دوم روش‌ها از ویژگی‌های ژئومتریک برای حذف این نویز استفاده می‌شود. برای مثال در یکی از این روش‌ها ابتدا نقاط پرش توسط یک مقدار آستانه مشخص می‌شود. این مقدار آستانه بر اساس میانگین فاصله بین همسایگی‌ها و مقدار انحراف استاندارد به دست می‌آید. بعد از مشخص شدن نقاط پرش، مقدار این نقاط حذف شده و با مقدار میانگین همسایگی‌ها جایگزین می‌گردد. در این تحقیق ما از روش فیلتر میانگین‌گیر برای حذف نویز پرش استفاده کرده ایم.

### ۲-۳-۳ حذف نویز حفره

حفره به نقاطی گفته می‌شود که اطلاعات عمق در آن نقطه وجود ندارد. این نویز در نقاطی بوجود می‌آید که نور تابیده شده از سنسور سه بعدی به درستی بازتاب نمی‌یابد. در نقاطی مثل مردمک چشم، اطراف بینی، ابروها و یا دهان بیشترین احتمال حضور این نویز وجود دارد. البته در صورت بسته بودن چشم و دهان در زمان تصویربرداری می‌توان نویز در این نقاط را کاهش داد. شکل زیر نمونه‌ای از وجود نویز حفره را نشان می‌دهد.




شکل ۳-۴- وجود نویز حفره، تصویر سمت راست نویز حفره را در مردمک چشم نشان می‌دهد و تصویر چپ نویز حفره را در ناحیه ابرو نشان می‌دهد.

<sup>۱</sup>Gaussian

برای پر کردن این حفره ها می توان از درون یابی مکعبی ویا عملیات مورفولوژی<sup>۱</sup> استفاده کرد.در این تحقیق ما از روش فیلتر ژئومتریک برای پر کردن مختصات حفره ها استفاده کردیم.

### ۳-۳-۳ تعیین رویه چهره

پس از انجام پیش پردازش های لازم برای حذف نویز،مختصات نوک بینی را تعیین می کنیم و بر اساس مختصات نوک بینی ،رویه چهره را از کل تصاویر استخراج می کنیم .تصاویر پایگاه داده علاوه بر چهره شامل اطلاعات اضافی مانند لباس ،گردن و گوش افراد نیز می باشد.برای حذف این اطلاعات اضافی ،ابتدا مختصات نوک بینی تعیین می شود سپس بر اساس مختصات نوک بینی یک مستطیل از تصویر را که فقط شامل رویه چهره می باشد را برش می دهیم .برای تعیین مختصات نوک بینی ،نقطه ای که کمترین میزان عمق را دارد انتخاب می کنیم.البته برای دقت بیشتر ابتدا یک فیلتر جمع کننده را به تصویر اعمال می کنیم تا ناحیه ای که عمق کمتری دارد مشخص تر شود.علت استفاده از این فیلتر این است که در صورتی که یک پیکسل به علت نویز دارای مقدار کم عمق باشد ،تاثیر آن را حذف کنیم تا به اشتباه به عنوان نوک بینی انتخاب نشود.در شکل ۳-۵ نمونه ای از این کار نشان داده شده است.



شکل ۳-۵-حذف قسمت اضافی تصاویر

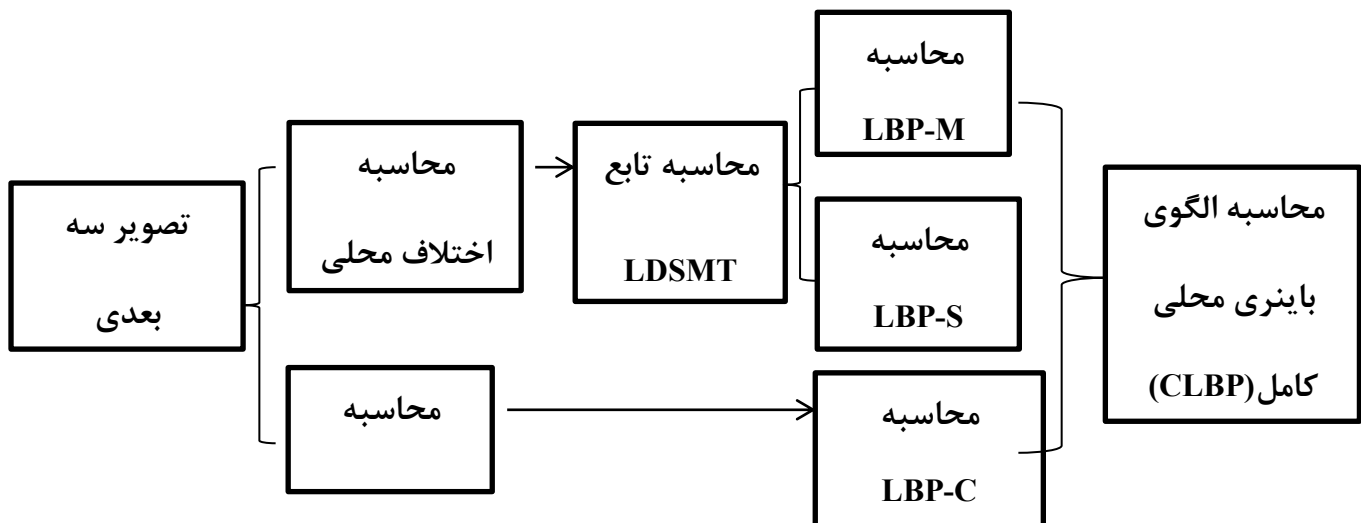
<sup>۱</sup>Morphological

## ۴-۳ استخراج ویژگی

یکی از مراحل مهم در شناسایی الگو استخراج ویژگی است ، فرایندی که در آن با انجام عملیاتی بر روی داده‌ها، ویژگی‌های بارز و تعیین‌کننده آن مشخص می‌شود. هدف استخراج ویژگی این است که داده‌های خام به شکل قابل استفاده‌تری برای پردازش‌های آماری بعدی درآیند. در قسمت بعد روش های استخراج ویژگی که در این تحقیق مورد استفاده قرار گرفت را بررسی می‌کنیم.

### ۱-۴-۳ الگوی باینری محلی کامل<sup>۱</sup>

الگوی باینری محلی (LBP)<sup>۲</sup> یکی از روش های پر کاربرد و ساده برای استخراج ویژگی از تصاویر می باشد. یکی از روش هایی که ما در این تحقیق برای استخراج ویژگی از تصاویر سه بعدی استفاده کردیم الگوی باینری محلی کامل می باشد که در شکل ۶-۳ مراحل محاسبه این ویژگی را مشاهده می کنید.



شکل ۶-۳- الگوریتم محاسبه الگوی باینری محلی کامل

<sup>۱</sup>Completa Local Binary Pattern (CLBP)

<sup>۲</sup>Local binary pattern (LBP)

### ۳-۴-۱-۱ الگوی باینری محلی پایه


روش الگوی باینری محلی (LBP) اولین بار توسط اجالا [4] معرفی شد. در LBP پایه یک همسایگی  $3 \times 3$  از هر پیکسل را در نظر می گیرند سپس هریک از این پیکسل های همسایه با پیکسل مرکزی مقایسه می شوند و در صورتی که مقدار بیشتری از پیکسل مرکزی داشته باشند کد ۱ و در غیر این صورت کد ۰ به آن همسایگی اختصاص داده می شود. در نهایت پیکسل مرکزی با جمع وزن دار باینری پیکسل های همسایه جایگزین می شود. کد LBP را می توان با تعداد همسایگی های مختلف طبق معادله (۳-۱) به دست آورد.

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p, S(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3-1)$$

که در رابطه بالا  $g_c$  بیانگر مقدار پیکسل مرکزی،  $g_p$  نشان دهنده مقدار پیکسل های همسایه می باشد. P نشان دهنده تعداد کل همسایه های درگیر و R نشان دهنده شعاع همسایگی می باشد. با فرض مختصات (۰ و ۰) برای  $g_c$ ، مختصات  $g_p$  با رابطه (۲) حساب می شود.

$$(R \cos(2\pi p / P), R \sin(2\pi p / P)) \quad (3-2)$$

در شکل ۳-۷ همسایگی های مختلف برای یک پیکسل نشان داده شده است.



شکل ۳-۷ همسایگی های مختلف برای یک پیکسل [16]

در صورتی که اندازه تصاویر ما  $I \times J$  باشد، هیستوگرام طبق معادله (۳-۶) از روی کد LBP تصاویر



حساب می شود.

$$H(K) = \sum_{i=0}^I \sum_{j=0}^I f(LBP_{P,R}(i, j), k), k \in [0, k], \quad f(x, y) = \begin{cases} 1, x = y \\ 0, otherwise \end{cases} \quad (3-3)$$

که H در این رابطه نشان دهنده حداکثر مقدار در الگوی LBP می باشد. با توجه به رابطه (3-6) خروجی LBP یک عدد باینری P بیتی است که می تواند  $2^P$  مقدار متفاوت داشته باشد. همچنین کد LBP به نحوه اندیس گذاری پیکسل های همسایه وابسته است، برای حل این مشکل کد باینری به دست آمده را می چرخانیم و حداقل مقدار به دست آمده از بین این کدها را به عنوان کد جدید در نظر می گیریم.


$$LBP_{P,R}^{ri} = \min\{ROR(LBP_{P,R}, i) | i = 0, 1, \dots, P - 1\} \quad (4-3)$$

در رابطه بالا ROR بیانگر چرخش به راست می باشد و  $ri$  بیانگر کد LBP است که به چرخش حساس است. در شکل بهبود یافته عملگر [39] LBP ابتدا معیاری به نام میزان یکنواختی یا همگنی تعریف می شود که بیانگر میزان تغییرات در کد باینری می باشد.

$$U(LBP_{P,R}) = |S(g_{p-1} - g_c) - S(g_0 - g_c)| + \sum_{p=1}^{p-1} |S(g_p - g_c) - S(g_{p-1} - g_c)| \quad (5-3)$$

در رابطه بالا  $U$  نشان دهنده میزان یکنواختی است. برای مثال در کد ۰۰۰۰۰۰۰۰ میزان  $U = 0$  و برای کد ۰۰۰۱۰۰۰۰ میزان  $U = 2$  می باشد. در این روش الگو هایی که میزان همگنی آن ها  $U \leq 2$  باشد به عنوان الگوی یکنواخت شناخته می شوند. در شکل 3-8 الگوهای یکنواخت برای همسایگی

با شعاع یک پیکسل نشان داده شده است.



شکل ۳-۸- الگوی یکنواخت برای (R=1,P=8) که دایره های سفید و سیاه نشان دهنده صفر و یک بودن بیت می باشد [40]

برای محاسبه الگوی باینری محلی یکنواخت از معادله (۳-۶) استفاده می کنیم.

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{p-1} s(g_p - g_c) & \text{if } U \leq 2 \\ P + 1 & \text{otherwise} \end{cases} \quad (۳-۶)$$

که در رابطه بالا  $u_2$  به معنی الگوی یکنواخت می باشد. با توجه به رابطه می بینیم که در کد LBP جدید، الگوهای همگن می توانند خروجی هایی از 0 تا P داشته باشند و الگوهای غیر همگن خروجی P+1 دارند.

### ۲-۱-۴-۳ هیستوگرام الگوی باینری محلی کامل

برای محاسبه الگوی باینری محلی کامل ابتدا اختلاف پیکسل های همسایه را با پیکسل مرکزی محاسبه می کنیم سپس بردار اختلاف به دست آمده را طبق رابطه (۸-۳) به دو بردار علامت و دامنه تبدیل می کنیم.

$$d_p = g_p - g_c \quad | \quad [p=0, 1, \dots, p-1] \quad (7-3)$$

$$d_p = s_p * m_p \quad \rightarrow \quad \begin{cases} s_p = \text{sign}(d_p) \\ m_p = |d_p| \end{cases} \quad (8-3)$$

در رابطه بالا  $d_p$  بردار اختلاف،  $s_p$  تابع علامت و  $m_p$  دامنه  $d_p$  می باشد. که رابطه (۸-۳) تبدیل اختلاف محلی علامت - دامنه نامیده می شود<sup>۱</sup> (LDSMT). شکل ۹-۳ یک مثال از این محاسبه این روش را نشان می دهد.

<sup>۱</sup>Local Difference Sign-Magnitude Transform

|     |    |    |
|-----|----|----|
| ۹   | ۱۲ | ۲۲ |
| ۱۱  | ۲۰ | ۳۴ |
| ۱۱۷ | ۱۴ | ۵۶ |

a

|     |    |    |
|-----|----|----|
| -11 | -8 | 2  |
| -9  |    | 14 |
| 97  | 64 | 36 |

b

|    |    |   |
|----|----|---|
| -1 | -1 | 1 |
| -1 |    | 1 |
| 1  | 1  | 1 |

c

|    |    |    |
|----|----|----|
| 11 | 8  | 2  |
| 9  |    | 14 |
| 97 | 64 | 36 |

d

شکل ۹-۳ a: یک بلوک ۳\*۳ b: محاسبه اختلاف هر پیکسل با پیکسل مرکزی c: محاسبه بردار علامت d: محاسبه بردار دامنه

در این مرحله، الگوی باینری محلی علامت و دامنه را حساب می‌کنیم. برای محاسبه الگوی باینری محلی علامت (LBPS)، ابتدا مقدار عمق هر پیکسل با پیکسل‌های همسایه مقایسه می‌شود و در صورت بزرگتر بودن کد ۱ و در صورت کمتر بودن کد ۰ به آن پیکسل اختصاص داده می‌شود. سپس طبق معادله (۱) در الگوی باینری محلی پایه کد LBPS را حساب می‌کنیم. برای محاسبه الگوی باینری محلی دامنه (LBPM) از رابطه زیر استفاده می‌شود:

$$LBP\_M_{p,R} = \sum_{p=0}^{p-1} t(m_p, C) 2^p, \quad t(x, C) = \begin{cases} 1, & x \geq C \\ 0, & x < C \end{cases} \quad (9-3)$$

در رابطه بالا C یک مقدار آستانه است که به طور تطبیقی تعیین می‌گردد و ما در این جا C را میانگین  $m_p$  در نظر گرفته ایم. کدهای LBP\_M و LBP\_S به دو طریق می‌توانند ترکیب شوند. روش اول هیستوگرام هر یک از کدها به طور جداگانه حساب می‌شود و در آخر این دو هیستوگرام به هم الحاق می‌شود که ویژگی به دست آمده در این روش را CLBP\_S\_M می‌نامیم. در روش دوم هیستوگرام به صورت دو بعدی با استفاده از LBP\_M و LBP\_S حساب می‌شود که ویژگی به دست آمده در این روش را CLBP\_S/M می‌نامیم. در صورتی که در رابطه (۹-۳) مقدار آستانه c را میانگین عمق تصویر در نظر بگیریم کد جدیدی به دست می‌آید که آن را LBP\_C می‌نامیم. مثل حالت قبل LBP\_S، LBP\_M و LBP\_C به دو طریق می‌توانند ترکیب شوند. در روش اول هیستو

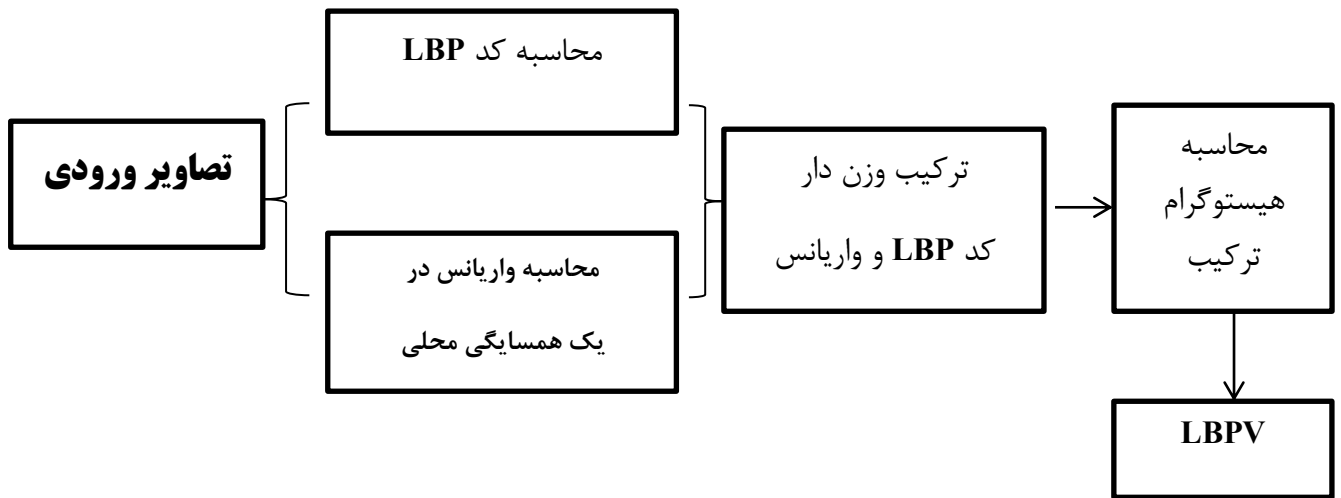
گرام ها جدا گانه حساب شده و در آخر به هم الحاق می شوند و ویژگی به دست آمده را CLBP\_S/M/C می نامیم. در روش دوم ابتدا هیستو گرام دو بعدی برای CLBP\_M/C یا CLBP\_S/C حساب می شود سپس هیستوگرام به دست آمده را به یک هیستو گرام یک بعدی تبدیل می کنیم تا بتوانیم آن را با یکی از هیستوگرام های CLBP\_M یا CLBP\_S به طور مشترک الحاق کنیم. ویژگی به دست آمده در این روش را CLBP\_M\_S/C یا CLBP\_S\_M/C می نامیم. در جدول ۱-۳ ویژگی های به دست آمده در این روش را می بینیم.

جدول ۱-۳ محاسبه ویژگی ها در الگوی باینری محلی کامل

| ویژگی استخراج شده | نحوه محاسبه                           |
|-------------------|---------------------------------------|
| CLBP_M            | هیستوگرام کد باینری دامنه (LBPM)      |
| CLBP_S            | هیستوگرام کد باینری علامت (LBPS)      |
| CLBP_M/C          | الحاق هیستوگرام کد باینری LBPC و LBPM |
| CLBP_S_M/C        | الحاق هیستوگرام های LBPS، LBPC و LBPM |
| CLBP_S/M          | هیستوگرام دو بعدی از LBPS و LBPM      |
| CLBP_S/M/C        | محاسبه CLBP_S/M و الحاق با CLBP_M/C   |

### ۳-۴-۲ هیستوگرام واریانس الگوی باینری محلی<sup>۱</sup>

این روش اولین بار توسط ژنهورا [40] برای شناسایی تصاویر بافت پیشنهاد شده است. برای محاسبه LBPV طبق شکل ۳-۱۰ عمل می‌کنیم.



شکل ۳-۱۰- الگوریتم محاسبه ویژگی LBPV

طبق الگوریتم بالا، در مرحله اول باید کد LBP را حساب کنیم. برای این منظور از رابطه (۳-۶) استفاده می‌کنیم که توضیحات آن در بخش ۳-۴-۱-۱ آمده است. حال باید مقدار واریانس را در یک همسایگی از پیکسل‌ها حساب کنیم. برای محاسبه واریانس از رابطه زیر استفاده می‌کنیم.

$$VAR_{P,R} = \frac{1}{P} \sum_{P=0}^{P-1} (g_P - \mu)^2 \quad (۱۰-۳)$$

$$\mu = \frac{1}{P} \sum_{P=0}^{P-1} g_P \quad (۱۱-۳)$$

در رابطه بالا R نشان دهنده شعاع همسایگی و P نشان دهنده تعداد پیکسل‌های درگیر در همسایگی

<sup>۱</sup>Local Binary Pattern Variance (LBPV)

می باشد.  $\mu$  مقدار میانگین همسایگی ها می باشد. بعد از محاسبه کد LBP و مقدار واریانس می توانیم ویژگی LBPV را با ترکیب وزن دار LBP و VAR به دست آوریم. نحوه ترکیب وزن دار این دو ویژگی و محاسبه هیستو گرام آنها طبق معادلات زیر انجام می گیرد.

$$LBPV_{P,R}(k) = \sum_{i=1}^I \sum_{j=1}^J w(LBP_{P,R}(i, j), k), k \in [0, K] \quad (12-3)$$

$$w(LBP_{P,R}(i, j), k) = \begin{cases} VAR_{P,R}(i, j), & LBP_{P,R}(i, j) = k \\ 0 & otherwise \end{cases} \quad (13-3)$$

در این تحقیق استخراج ویژگی با این روش به دو شکل مختلف انجام شده است. در روش اول با اعمال الگوریتم LBPV به کل تصویر سه بعدی، یک بردار ویژگی از کل تصویر استخراج می کنیم که البته با تغییر شعاع همسایگی می توانیم بردار های ویژگی مختلفی به دست آوریم. در روش دوم ابتدا تصاویر ورودی را به بلوک های کوچکتر تقسیم بندی کرده، سپس با اعمال الگوریتم LBPV، بردار ویژگی هر بلوک را جداگانه حساب می کنیم و در نهایت با کنار هم قرار دان این بردار های ویژگی، یک بردار ویژگی به ازای تصویر ورودی به دست می آوریم. نتایج به دست آمده از این روش را در فصل ۴ بررسی خواهیم کرد.

### ۳-۴-۳ ویژگی های مبتنی بر انحنای اصلی<sup>۱</sup>

روش انحنای اصلی یک روش مبتنی بر هندسه چهره است. این روش در [41] معرفی شده است. آنها با محاسبه انحنای گوسی و میانگین انحنای علامت آنها برای دسته بندی سطوح استفاده کرده اند. در این تحقیق ما به شکل های مختلفی از این دو ویژگی استفاده کرده ایم که در ادامه به نحوه محاسبه

<sup>۱</sup>Principal curvature

این ویژگی ها می پردازیم.

در صورتی که تمام منحنی هایی که از نقطه  $p$  در سطح  $s$  می گذرند را  $c_i$  در نظر بگیریم ، هر یک از این  $c_i$  ها دارای یک انحنای  $k_i$  می باشد. کمترین مقدار این انحنا ها را با  $k_1$  و بیشترین مقدار انحنا را با  $k_2$  نشان می دهیم.  $k_1$  و  $k_2$  را انحنای اصلی سطح  $s$  می گویند. انحنای میانگین و انحنای گوسی را برای نقطه  $p$  با  $H$  و  $K$  نشان می دهند و برای محاسبه این دو انحنا از روابط (۳-۱۴) و (۳-۱۵) استفاده می شود.

$$K = k_1 * k_2 \quad (۳-۱۴)$$

$$H = \frac{1}{2}(k_1 + k_2) \quad (۳-۱۵)$$

در رابطه بالا \* نشان دهنده عملگر ضرب می باشد. اگر نقطه  $p$  در سطح  $s$  قرار گرفته باشد ، انحنای میانگین طبق رابطه (۳-۱۶) حساب می شود.

$$H = \frac{eG + gE - 2fF}{2(EG - F^2)} \quad (۳-۱۶)$$

در رابطه بالا  $E$  ،  $F$  و  $G$  ضرایب شکل اصلی اولیه و  $e$  ،  $f$  و  $g$  ضرایب شکل اصلی ثانویه نامیده می شوند که طبق روابط (۳-۱۷) تا (۳-۲۲) حساب می شوند.

$$E = 1 + h_u^2 \quad (۳-۱۷)$$

$$F = h_u * h_v \quad (۳-۱۸)$$

$$G = 1 + h_v^2 \quad (۳-۱۹)$$



$$e = \frac{h_{uu}}{\sqrt{1 + h_u^2 + h_v^2}} \quad (20-3)$$




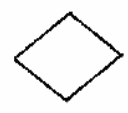



$$f = \frac{h_{uv}}{\sqrt{1 + h_u^2 + h_v^2}} \quad (21-3)$$

$$g = \frac{h_{vv}}{\sqrt{1 + h_u^2 + h_v^2}} \quad (22-3)$$

در روابط بالا  $h_u$  مشتق اول در راستای محور  $x$ ،  $h_v$  مشتق اول در راستای محور  $Y$  و  $h_{uv}$ ،  $h_{uu}$  و  $h_{vv}$  مشتق های دوم هستند. در شکل ۳-۱۱ میزان انحنای گوسی و میانگین سطوح مختلف آمده است.

| $K$ | $H$ | Local shape class   |
|-----|-----|---------------------|
| 0   | 0   | plane               |
| 0   | +   | concave cylindrical |
| 0   | -   | convex cylindrical  |
| +   | +   | concave elliptic    |
| +   | -   | convex elliptic     |
| -   | any | hyperbolic          |

|     |   |   |   |   |
|-----|---|---|---|---|
|     | $K$   | -   | 0   | + |
| $H$ | -   |  |  |   |
| 0   |  |  |  |   |
| +   |   |  |  |   |

شکل ۳-۱۱- سطوح مختلف و میزان انحنای گوسی و میانگین هر سطح [34]

در این تحقیق ما با ترکیب این ویژگی و ویژگی الگوی باینری محلی، یک روش جدید برای استخراج ویژگی را پیشنهاد کردیم. البته از این ویژگی به صورت جداگانه نیز استفاده کردیم که در ادامه به

نحوه استفاده از این ویژگی می پردازیم.

در مرحله اول باید کد LBP را حساب کنیم. برای این منظور از رابطه (۳-۶) استفاده می کنیم. بعد از محاسبه کد LBP، میانگین گوسی (K) و انحنای میانگین (H) را حساب می کنیم و در نهایت ویژگی های LBPK و LBPH را با ترکیب وزن دار انحنای گوسی و انحنای میانگین با کد LBP به دست می آوریم. نحوه ترکیب وزن دار این دو ویژگی و محاسبه هیستو گرام آنها طبق معادلات زیر انجام می گیرد.

$$LBPK_{P,R}(k) = \sum_{i=1}^I \sum_{j=1}^J w_K(LBP_{P,R}(i,j), k), k \in [0, K] \quad (۲۳-۳)$$

$$w_k(LBP_{P,R}(i,j), k) = \begin{cases} \mu_k(i,j), & LBP_{P,R}(i,j) = k \\ 0 & otherwise \end{cases} \quad (۲۴-۳)$$

در رابطه بالا  $\mu_k$  میانگین انحنای گوسی در یک همسایگی برای یک پیکسل است که طبق رابطه زیر حساب می شود.

$$\mu_k = \frac{1}{p} \sum_{p=1}^{p-1} K_p \quad (۲۵-۳)$$

در رابطه بالا p تعداد همسایه های در گیر در محاسبه میانگین و K میانگین گوسی می باشد. برای محاسبه ی LBPH مانند روش بالا عمل می کنیم که محاسبات آن در زیر آمده است.

$$LBPH_{P,R}(k) = \sum_{i=1}^I \sum_{j=1}^J w_H(LBP_{P,R}(i,j), k), k \in [0, K] \quad (۲۶-۳)$$

$$w_H(\text{LBP}_{P,R}(i,j),k) = \begin{cases} \mu_H(i,j) & , \text{LBP}_{P,R}(i,j) = k \\ 0 & \text{otherwise} \end{cases} \quad (27-3)$$

$$\mu_H = \frac{1}{p} \sum_{p=1}^{p-1} H_p \quad (28-3)$$

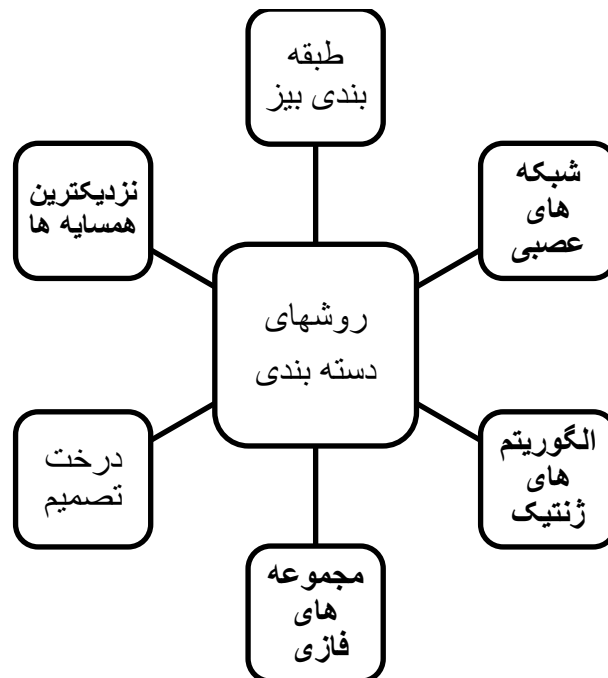
در رابطه بالا  $\mu_H$  متوسط انحنای میانگین در یک همسایگی برای یک پیکسل می باشد. در فصل ۴ نتایج به دست آمده از این روش گزارش شده است.

### ۳-۵ انتخاب ویژگی ها

عملکرد مطلوب هر دسته بند وابسته به ویژگی های ورودی آن می باشد. برخی از ویژگی های به دست آمده در مرحله استخراج ویژگی دارای ابعاد زیادی هستند ، که این ویژگی ها قبل از ورود به مرحله دسته بندی باید مورد تحلیل قرار گرفته و تعدادی از آنها که اطلاعات بیشتری برای دسته بندی در اختیار ما قرار می دهند را انتخاب کنیم. در این تحقیق ما از روش LDA برای تحلیل داده ها استفاده کرده ایم. برخلاف روش PCA که تحلیل بردار ویژگی را بدون در نظر گرفتن اطلاعات کلاسی داده ها انجام می دهد، روش LDA با در نظر گرفتن اطلاعات دسته هر کلاس ، بردار ویژگی را به شکلی تغییر می دهد که بهترین جداسازی شکل بگیرد. روش LDA به دنبال کم کردن فاصله ویژگی های درون کلاسی و افزایش فاصله بین کلاس ها می باشد. نحوه محاسبه روش LDA در ۱-۲-۳ آمده است. در این تحقیق با اعمال این روش بر روی ماتریس ویژگی ، این ماتریس را به شکلی مرتب می کنیم که ویژگی هایی که بیشترین تاثیر را در جداسازی داده ها دارند در ابتدا و ویژگی های که کمترین تاثیر را در جداسازی دارند در انتهای ماتریس ویژگی قرار بگیرند. در مرحله بعد می توان ویژگی های کم اهمیت را از ماتریس ویژگی حذف کرد ، البته تا جایی می توانیم ویژگی ها را حذف کنیم که درصد شناسایی دچار کاهش نشود.

## ۶-۳ روش دسته بندی

دسته بندی عبارتست از تخصیص داده ها و یا هر مجموعه ای از اشیا به مجموعه مشخصی از دسته ها. در این فرایند بر اساس داده های توزیع شده ، مدل اولیه ای ایجاد می گردد مدل ایجاد شده بر پایه ی یکسری داده های آموزشی (داده هایی که بر چسب کلاس انها مشخص و شناخته شده است ) حاصل می آید . سپس این مدل برای دسته بندی داده های جدید مورد استفاده قرار می گیرد ، به این ترتیب با بکار گیری مدل بدست آمده ، تعلق داده های جدید به یک دسته قابل پیشگویی می باشد . به طور کلی فرآیند دسته بندی شامل دو مرحله است ، در مرحله اول یک مدل بر اساس داده های آموزشی شکل می گیرد و در مرحله دوم شماره دسته داده های جدید بر اساس مدل تعیین می شود. در شکل ۱۲-۳ مهمترین روش های دسته بندی آمده است.



شکل ۱۲-۳- مهمترین روش های دسته بندی داده ها

در این تحقیق ما از روش های دسته بندی ساده بیزی و نزدیکترین همسایه استفاده کردیم در قسمت

بعد به توضیح این دو روش می پردازیم.

### ۳-۶-۱-۱ روش دسته بندی ساده بیزی<sup>۱</sup>

الگوریتم های یادگیری بیزی به طور صریح بر روی احتمالات فرض های مختلف کار می کنند. دسته بندهای بیزی، دسته بندهای آماری هستند که اعضای دسته را به صورت احتمالی پیشگویی می کنند. یک روش بسیار کاربردی یادگیری بیزی، روش یادگیرنده ساده بیزی می باشد که عموماً روش طبقه بندی ساده بیزی نامیده می شود. مقایسه الگوریتم های کلاسه بندی نشان داده است که یک کلاسه بند بیزی ساده از نظر کارایی با کلاسه بندهای درخت تصمیم و شبکه های عصبی قابل رقابت است و در برخی موارد بهتر از آنها عمل می کند. همچنین کلاسه بندهای بیزی میزان دقت و سرعت بالایی را هنگامی که در دیتابیس های بزرگ به کار برده می شوند، ارائه می دهند. روش بیزی محتمل ترین طبقه یا مقدار هدف  $v_{MAP}$  را با داشتن مقادیر ویژگی  $a_1, a_2, \dots, a_n$  که توصیف کننده نمونه جدید است را شناسایی می کند.

$$v_{MAP} = \arg \max_{v_j \in V} P(v_j | a_1, a_2, \dots, a_n) \quad (29-3)$$

با استفاده از قضیه بیز می توان عبارت بالا را به صورت زیر بازنویسی کرد

$$v_{MAP} = \arg \max_{v_j \in V} \frac{P(a_1, a_2, \dots, a_n | v_j) P(v_j)}{P(a_1, a_2, \dots, a_n)} = \arg \max_{v_j \in V} P(a_1, a_2, \dots, a_n | v_j) P(v_j) \quad (30-3)$$

فرض روش طبقه بندی ساده بیزی بر اساس این ساده سازی است که مقادیر ویژگی ها با داشتن مقادیر تابع هدف از یکدیگر مستقل شرطی می باشند. به عبارت دیگر، این فرض بیانگر این است که به شرط مشاهده خروجی تابع هدف احتمال مشاهده صفات  $a_1, a_2, \dots, a_n$  برابر ضرب احتمالات هر صفت به طور جداگانه می باشد. اگر این را جایگزین معادله بالا کنیم روش طبقه بندی ساده بیزی به

---

<sup>۱</sup>Naïve Bayes

دست می آید.

$$v_{NB} = \arg \max_{v_j \in V} P(v_j) \prod_i P(a_i | v_j) \quad (3-31)$$


که  $V_{NB}$  خروجی طبقه‌بندی ساده بیزی برای تابع هدف می‌باشد. تعداد جملات  $P(a_i | v_j)$  که در این روش باید محاسبه شوند برابر تعداد ویژگی‌ها ضرب در تعداد دسته‌های خروجی برای تابع هدف می‌باشد که این مقدار از تعداد جملات  $P(a_1, a_2, \dots, a_n | v_j)$  بسیار کمتر است. نتیجه اینکه یادگیری ساده بیزی سعی در تخمین مقادیر مختلف  $P(v_j)$  و  $P(a_i | v_j)$  با استفاده از میزان تکرار آنها در داده‌های آموزشی دارد. این مجموعه تخمین‌ها متناظر با فرض یاد گرفته شده است. سپس از این فرض برای طبقه بندی نمونه‌های جدید استفاده می‌شود که این کار با استفاده از فرمول بالا صورت می‌گیرد.

### ۳-۶-۱-۲ دسته بند K نزدیکترین همسایه<sup>۱</sup>

یکی از دسته بند های بسیار پر کاربرد و ساده دسته بند K نزدیکترین همسایه یا KNN می باشد. این دسته بند مستقل از تخمین چگالی احتمال می باشد و می تواند داده های جدید را مستقسما دسته بندی کند. در این روش، تصمیم‌گیری اینکه یک نمونه جدید در کدام دسته قرار گیرد با بررسی تعدادی (k) از شبیه ترین نمونه ها یا همسایه‌ها انجام می‌شود. در بین این k نمونه، تعداد نمونه ها برای هر کلاس شمرده می شوند، و نمونه جدید به کلاسی که تعداد بیشتری از همسایه‌ها به آن تعلق دارند نسبت داده می‌شود. شکل ۳-۱۰ محدوده همسایگی نمونه N را نشان می دهد. در این محدوده، بیشتر همسایه ها در کلاس X قرار گرفته اند.

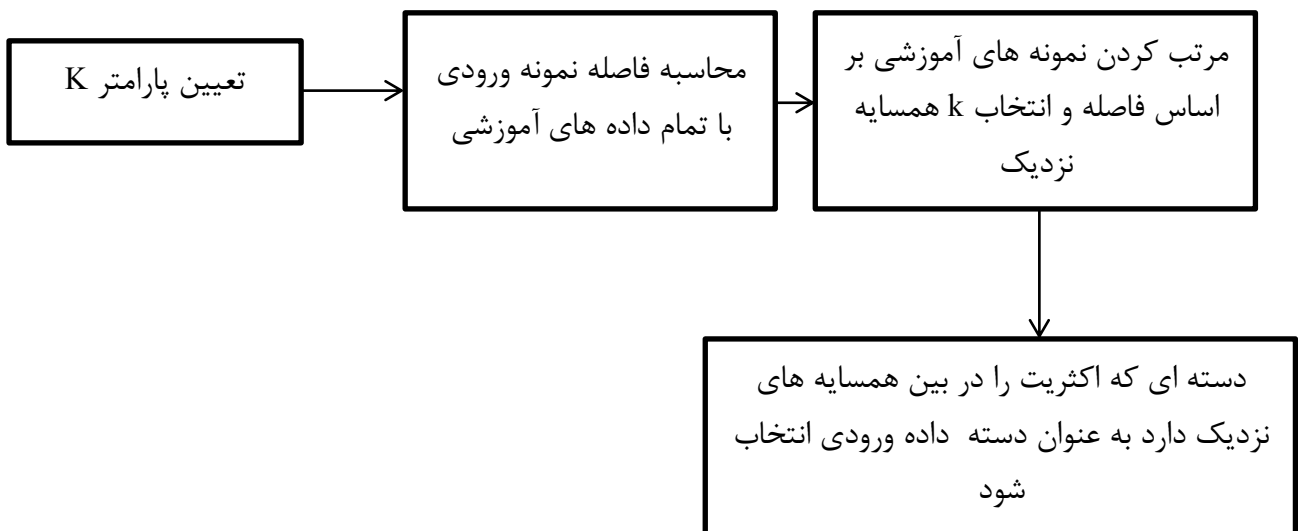
---

<sup>۱</sup>K-nearest neighbor



شکل ۳-۱۳- محدوده همسایگی

در شکل ۳-۱۳ یک مثال از روش دسته بندی  $K$  نزدیکترین همسایه آمده است. در این مثال ابتدا شعاع همسایگی را آن قدر افزایش می دهیم که تعداد  $k=9$  داده درون شعاع قرار بگیرند. حال در این همسایگی تعداد ۷ عدد از نمونه  $X$  و تعداد ۲ نمونه از داده  $Y$  موجود می باشد. در مرحله تست باید تعیین کنیم که داده  $N$  متعلق به کدام کلاس است. با توجه به این که داده  $N$  در محدوده همسایگی بالا قرار گرفته و در این محدوده فراوانی داده های  $X$  بیشتر از  $Y$  است، داده  $N$  در دسته  $X$  قرار می گیرد. الگوریتم روش  $K$  نزدیکترین همسایه به صورت شکل ۳-۱۴ می باشد.



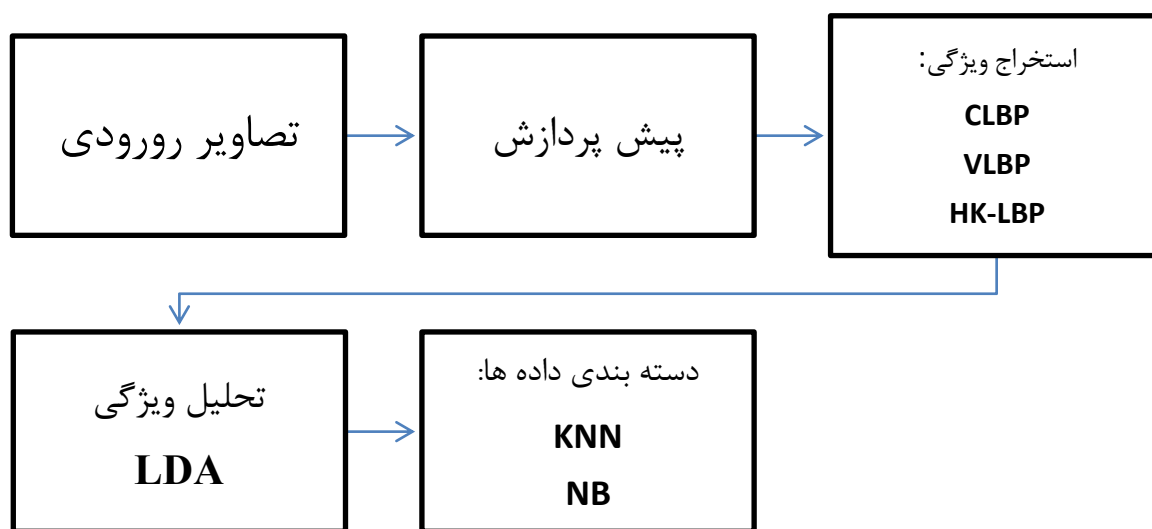
شکل ۳-۱۴- الگوریتم دسته بندی  $k$  نزدیکترین همسایه

## ۴: نتایج آزمایشات



## ۴-۱ کلیات پیاده سازی

در این فصل به بررسی نتایج به دست آمده از آزمایشات انجام شده بر روی تصاویر پایگاه داده GAVAB می پردازیم. پیاده سازی آزمایشات در محیط برنامه نویسی Matlab 2012 b انجام شده است. روال کلی سیستم پیشنهادی به این شکل است که ابتدا یک پیش پردازش بر روی تصویر انجام می گیرد. در مرحله بعدی توسط یکی از روش های معرفی شده در فصل سوم یک بردار ویژگی از هر تصویر استخراج می شود. سپس در صورت زیاد بودن ابعاد این ویژگی ها، برای عملکرد بهتر سیستم دسته بندی، ابعاد ویژگی توسط روش LDA کاهش می یابد و در نهایت دسته بندی داده ها توسط یکی از روش های ساده بیزی یا نزدیکترین همسایه انجام می گیرد.



شکل ۴-۱-۱-۴-۱ روال کلی سیستم پیشنهادی

## ۴-۲ نتایج روش استخراج ویژگی CLBP

در این قسمت به بررسی نتایج به دست آمده توسط روش الگوی باینری محلی کامل یا CLBP می پردازیم. ویژگی استخراج شده از هر تصاویر با در نظر گرفتن سه شعاع همسایگی مختلف به دست آمده است، همچنین برای عملکرد بهتر سیستم و اینکه ویژگی ها از لحاظ ابعاد با هم قابل مقایسه باشند با اعمال روش LDA ابعاد ویژگی ها را کاهش داده و به ازای هر تصویر ۱۰ ویژگی را انتخاب می کنیم. در جدول ۴-۱ ابعاد هر یک از ویژگی های استخراج شده، قبل از اعمال کاهش ویژگی آمده است. برای اطمینان از اعتبار نتایج ارائه شده، روش پیشنهادی را ۱۰ بار اجرا کرده و میانگین نتایج به دست آمده را به عنوان نتیجه نهایی گزارش کرده ایم. در جدول ۴-۲ نتایج با در نظر گرفتن ۷۰ درصد کل داده ها به عنوان مجموعه آموزش و بقیه داده ها به عنوان تست، به دست آمده است. در جدول ۴-۳، با در نظر گرفتن ۳۰ درصد داده ها به عنوان مجموعه آموزش و ۷۰ درصد داده ها برای تست نتایج دیگری به دست آمده است.

جدول ۱-۴- ابعاد هر یک از ویژگی ها قبل از کاهش ویژگی

| ویژگی استخراج شده | LBP_(R=1,P=8) | LBP_(R=2,P=16) | LBP_(R=3,P=24) |
|-------------------|---------------|----------------|----------------|
| CLBP_S            | ۱۰            | ۱۸             | ۲۶             |
| CLBP_M            | ۱۰            | ۱۸             | ۲۶             |
| CLBP_M/C          | ۲۰            | ۳۶             | ۵۲             |
| CLBP_S_M/C        | ۳۰            | ۵۴             | ۷۸             |
| CLBP_S_M          | ۱۰۰           | ۳۲۴            | ۶۷۶            |
| CLBP_S/M/C        | ۲۰۰           | ۶۴۸            | ۱۳۵۲           |

جدول ۲-۴- نتایج روش CLBP با در نظر گرفتن ۷۰ درصد داده ها برای آموزش


| ویژگی استخراج شده | LBP_(R=1,P=8) |       | LBP_(R=2,P=16) |       | LBP_(R=3,P=24) |       |
|-------------------|---------------|-------|----------------|-------|----------------|-------|
|                   | KNN           | NB    | KNN            | NB    | KNN            | NB    |
| CLBP_S +LDA       | 52.86         | 54.26 | 60.92          | 64.25 | 68.28          | 68.73 |
| CLBP_M+LDA        | 60.81         | 62.23 | 69.09          | 71.98 | 75.63          | 75.78 |
| CLBP_M/C+LDA      | 79.64         | 81.21 | 81.31          | 83.03 | 84.29          | 86.91 |
| CLBP_S_M/C+LDA    | 80.24         | 82.51 | 83.66          | 84.45 | 90.36          | 91.81 |
| CLBP_S_M+LDA      | 81.25         | 85.8  | 93.44          | 94.47 | 94.09          | 95.03 |
| CLBP_S/M/C+LDA    | 90.34         | 93.52 | 94.67          | 95.33 | 95.84          | 96.47 |

جدول ۳-۴- نتایج روش CLBP با در نظر گرفتن ۳۰ درصد داده ها برای آموزش

| ویژگی استخراج شده | LBP_(R=1,P=8) |       | LBP_(R=2,P=16) |       | LBP_(R=3,P=24) |       |
|-------------------|---------------|-------|----------------|-------|----------------|-------|
|                   | KNN           | NB    | KNN            | NB    | KNN            | NB    |
| CLBP_S +LDA       | 40.21         | 41.86 | 50.74          | 53.12 | 58.28          | 61.73 |
| CLBP_M+LDA        | 44.68         | 46.63 | 56.21          | 60.49 | 66.63          | 67.38 |
| CLBP_M/C+LDA      | 64.33         | 67.52 | 67.66          | 70.51 | 78.21          | 80.38 |
| CLBP_S_M/C+LDA    | 66.09         | 71.23 | 72.66          | 75.36 | 85.26          | 88.81 |
| CLBP_S_M+LDA      | 78.52         | 80.66 | 92.74          | 93.05 | 93.09          | 94.13 |
| CLBP_S/M/C+LDA    | 89.64         | 90.33 | 93.84          | 94.22 | 93.84          | 94.89 |

## ۱-۲-۴ تحلیل نتایج روش CLBP


با مقایسه نتایج به دست آمده مشاهده می شود که با افزایش شعاع همسایگی برای استخراج ویژگی ، ویژگی های بهتری به دست می آید و نتیجه شناسایی تا حد زیادی تغییر می کند برای مثال در ویژگی  $CLBP\_S\_M/C$  ، با افزایش شعاع همسایگی و تعداد همسایگی ها از  $(R=1, P=8)$  به  $(R=3, P=24)$  دقت شناسایی از ۷۱ درصد به ۸۸ درصد می رسد. شکل ۲-۴ نشان دهنده تاثیر افزایش شعاع همسایگی بر دقت شناسایی می باشد که براساس دو ویژگی  $CLBP\_M$  و  $CLBP\_S/M/C$  رسم شده است.



شکل ۲-۴ نمودار تاثیر اندازه شعاع همسایگی برای استخراج ویژگی در شناسایی


با مقایسه هر یک از ویژگی ها مشاهده می کنیم که ویژگی  $CLBP\_S/M/C$  که به صورت ترکیبی به دست می آید ، بهترین دقت شناسایی را به ما می دهد. این ویژگی در حالتی که تعداد داده های آموزشی را ۷۰ درصد در نظر بگیریم و با شعاع ۳ و تعداد ۲۴ همسایگی ، ویژگی را استخراج کنیم و با روش LDA ، تعداد ۱۰ ویژگی مهمتر را انتخاب کنیم ، با کلاسه بند ساده بیزی دقت ۹۶.۴۷ درصد

را به ما می دهد. در صورتی که تعداد داده های آموزشی را ۳۰ درصد کل داده ها در نظر بگیریم باز هم این ویژگی نتیجه خوبی به ما می دهد و دقت ۹۴.۸۹ درصد را نتیجه می دهد. در شکل ۲-۴ دقت شناسایی هریک از ویژگی ها با هم مقایسه شده است.



شکل ۳-۴- مقایسه دقت هریک از ویژگی ها با یکدیگر توسط دسته بند ساده بیزی

همچنین با مقایسه نتایج به دست آمده می بینیم که دسته بند ساده بیزی عملکرد بهتری نسبت به دسته بند نزدیکترین همسایه نشان می دهد. شکل ۴-۴ عملکرد دو دسته بند ساده بیزی و نزدیکترین همسایه را نشان می دهد.



شکل ۴-۴- نمودار مقایسه عملکرد دسته بند ساده بیزی و نزدیکترین همسایه

### ۳-۴ مقایسه نتایج روش LBPK و LBPH، LBPV

در این قسمت نتایج به دست آمده از این سه روش را بررسی می کنیم. ویژگی استخراج شده از هر تصویر به دو روش انجام گرفته است. در روش اول هر یک از این سه ویژگی به صورت مستقیم از کل تصاویر استخراج شده اند. در روش دوم ابتدا هر تصویر به بلوک های کوچکتر تقسیم می شود و سپس با اعمال هر کدام از روش های بالا استخراج ویژگی از بلوک ها انجام می گیرد و در نهایت ویژگی های استخراج شده از بلوک ها کنار هم قرار می گیرد تا بردار ویژگی را برای یک تصویر تشکیل دهد. در این تحقیق ما هر تصویر را به بلوک های  $3 \times 3$  و  $4 \times 4$  تقسیم بندی کرده ایم. هر یک از ویژگی های بالا با در نظر گرفتن شعاع همسایگی  $R=1$  و تعداد  $P=8$  همسایه، محاسبه می شود. برای تحلیل و کاهش ابعاد ویژگی از روش LDA، استفاده شده است. نتایج به دست آمده بر اساس در نظر گرفتن ۷۰ درصد داده های کل برای آموزش در جدول ۴-۴ آورده شده است.




جدول ۴-۴- نتایج روش های LBPV، LBPH و LBPK با در نظر گرفتن ۷۰ درصد داده ها برای آموزش

| روش  | کل تصویر |       | بلوک ۳*۳ |       | بلوک ۴*۴ |              |
|------|----------|-------|----------|-------|----------|--------------|
|      | KNN      | NB    | KNN      | NB    | KNN      | NB           |
| LBPV | 68.11    | 60.33 | 84.43    | 89.27 | 91.22    | <b>93.33</b> |
| LBPK | 53.66    | 52.11 | 81.91    | 86.92 | 92.65    | <b>93.84</b> |
| LBPH | 56.84    | 60.27 | 90.54    | 92.59 | 95.05    | <b>96.36</b> |

با توجه به جدول ۴-۴ می بینیم که ویژگی LBPH عملکرد بهتری نسبت به دو روش دیگر دارد. طبق نتایج به دست آمده با قطعه بندی تصویر به بلوک های کوچکتر، عملکرد شناسایی سیستم افزایش می یابد (شکل ۴-۵)، ولی در مقابل زمان محاسبات سیستم نیز زیاد می شود. در این تحقیق ما حداکثر از یک بلوک بندی ۴\*۴ استفاده کردیم، با توجه به آزمایشات انجام شده افزایش تعداد بلوک ها بیش از این تعداد تاثیر چندانی بر دقت سیستم ندارد و فقط زمان پردازش افزایش می یابد. در جدول ۴-۵ نتایج با در نظر گرفتن ۳۰ درصد داده ها برای آموزش و ۷۰ درصد داده ها برای تست آمده است.

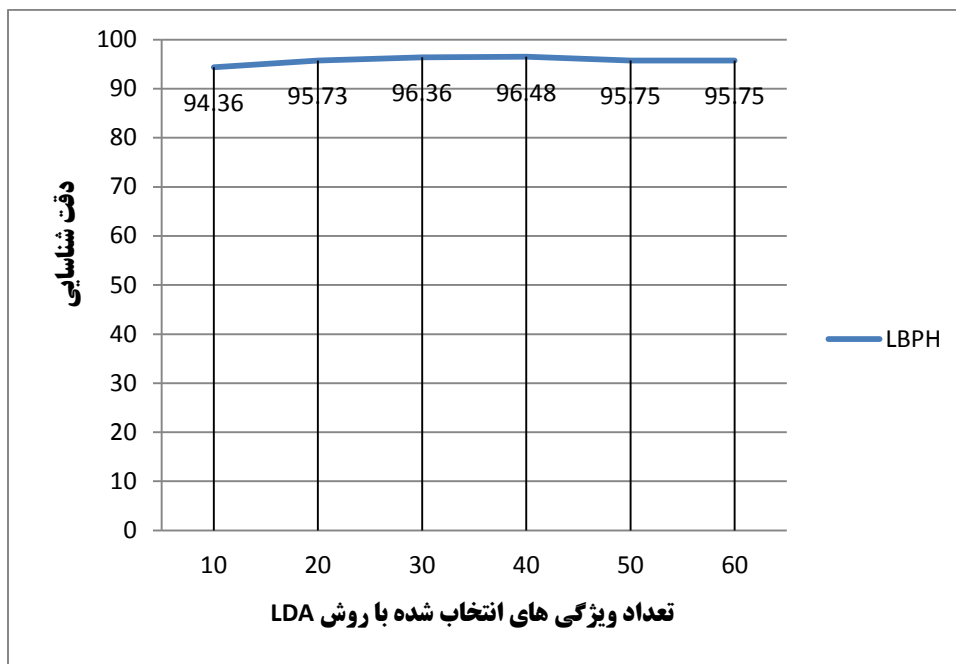
جدول ۴-۵- نتایج روش های LBPV، LBPH و LBPK با در نظر گرفتن ۳۰ درصد داده ها برای آموزش

| روش  | کل تصویر |       | بلوک ۳*۳ |       | بلوک ۴*۴ |              |
|------|----------|-------|----------|-------|----------|--------------|
|      | KNN      | NB    | KNN      | NB    | KNN      | NB           |
| LBPV | 51.71    | 50.01 | 79.71    | 82.66 | 82.83    | <b>85.66</b> |
| LBPK | 39.96    | 40.02 | 73.53    | 80.08 | 85.02    | <b>87.05</b> |
| LBPH | 44.23    | 45.85 | 83.63    | 87.02 | 87.56    | <b>88.46</b> |



شکل ۴-۵- مقایسه دقت شناسایی با افزایش بلوک بندی تصویر

همانطور که در بخش های قبل گفته شد در این تحقیق ما از روش LDA برای تحلیل ویژگی ها استفاده کرده ایم. در شکل ۴-۶ نمودار دقت شناسایی سیستم با توجه به تعداد ویژگی های انتخاب شده توسط روش LDA آمده است. ما با در نظر گرفتن توان محاسبات سیستم کامپیوتری، تعداد ۳۰ ویژگی را به عنوان بهترین تعداد برای دسته بندی در نظر گرفتیم.



شکل ۴-۶- دقت شناسایی بر اساس تعداد ویژگی‌های انتخاب شده با LDA

## ۴-۴ نتایج روش‌های کل نگر

در این قسمت نتایج به دست آمده با روش‌های PCA و LDA ارائه می‌شود. در روش اول، ابتدا تمام تصاویر موجود در پایگاه داده را به صورت یک ماتریس سطری مرتب می‌کنیم، که هر سطر این ماتریس نشان دهنده اطلاعات عمق یکی از تصویرهای پایگاه داده است، سپس با اعمال روش PCA ابعاد این ماتریس ویژگی را کاهش می‌دهیم و در نهایت دسته بندی داده‌ها انجام می‌شود. همچنین این کار بر روی ماتریس‌های انحنای گوسی و انحنای میانگین نیز انجام می‌گیرد.

در روش دوم بعد از کاهش ابعاد ویژگی توسط PCA، روش LDA را برای تحلیل داده‌ها و دسته بندی بهتر بر روی ماتریس ویژگی اعمال می‌کنیم.

جدول ۴-۶- نتایج روش های کل نگر با در نظر گرفتن ۷۰ درصد داده ها برای آموزش


| نوع ویژگی        | PCA   |       | PCA+LDA |       |
|------------------|-------|-------|---------|-------|
|                  | NB    | KNN   | NB      | KNN   |
| انحنای گوسی K    | ۵۲.۱۴ | ۶۳.۴۳ | ۸۸.۲۸   | ۹۰.۱۴ |
| اطلاعات عمق      | ۷۶.۸۲ | ۷۶.۴۳ | ۸۹.۱۴   | ۸۹.۸۵ |
| انحنای میانگین H | ۷۸.۸۱ | ۷۹.۲۷ | ۸۹.۶۸   | ۹۱.۰۹ |

جدول ۴-۷- نتایج روش های کل نگر با در نظر گرفتن ۳۰ درصد داده ها برای آموزش


| نوع ویژگی        | PCA   |       | PCA+LDA |       |
|------------------|-------|-------|---------|-------|
|                  | NB    | KNN   | NB      | KNN   |
| انحنای گوسی K    | ۴۱.۳۲ | ۴۸.۴۴ | ۸۱.۸۵   | ۸۵.۱۲ |
| اطلاعات عمق      | ۶۴.۸۵ | ۶۶.۴۲ | ۷۷.۷۱   | ۷۸.۷۴ |
| انحنای میانگین H | ۶۸.۱۶ | ۶۸.۸۳ | ۸۵.۲۸   | ۸۵.۸۵ |

با مقایسه نتایج به دست آمده مشاهده می شود که ویژگی انحنای میانگین عملکرد بهتری نسبت به ویژگی های عمق و انحنای گوسی دارد و این ویژگی حتی با کاهش تعداد نمونه های آموزشی از ۷۰ درصد به ۳۰ درصد داده ها باز هم عملکرد قابل قبولی به ما ارائه می کند.

نتیجه دیگری که می توان از جدول نتایج گرفت تاثیر اعمال تحلیل LDA برای تحلیل ویژگی ها می باشد که در شکل ۴-۷ و شکل ۴-۸ این موضوع نشان داده شده است.



شکل ۴-۷- نمودار تاثیر استفاده از LDA بر روی عملکرد سیستم با دسته بند KNN



شکل ۴-۸- نمودار تاثیر استفاده از LDA بر روی عملکرد سیستم با دسته بند ساده بیزی

## ۴-۵ سرعت پردازش روش های اجرا شده

زمان لازم برای عملیات استخراج ویژگی و دسته بندی تصاویر در این بخش بررسی می شود. محاسبات انجام شده توسط یک پردازنده Intel Cori3 3110M با سرعت 2.4 GHZ و رم ۴ گیگا بایت انجام شده است. زمان های ارائه شده در جدول شامل زمان خواندن و پیش پردازش تصاویر نمی باشد و فقط زمان استخراج ویژگی و دسته بندی را نشان می دهد.

جدول ۴-۸- زمان پردازش سیستم پیشنهادی با ویژگی های مختلف

| نوع ویژگی      | زمان استخراج ویژگی | زمان دسته بندی |          |
|----------------|--------------------|----------------|----------|
|                |                    | NB             | KNN      |
| CLBP(R=1,P=8)  | ۷.۰۷ ثانیه         | ۹۴ میلی ثانیه  | ۱۸۳ میلی |
| CLBP(R=2,P=16) | ۱۰.۳۱ ثانیه        |                | ثانیه    |
| CLBP(R=3,P=24) | ۱۳.۱۵ ثانیه        |                |          |
| LBPV           | ۸.۸۸ ثانیه         | ۱۶۰ میلی ثانیه | ۲۳۳ میلی |
| LBPH           | ۱۸ ثانیه           |                | ثانیه    |
| LBPV           |                    |                |          |

همچنین زمان کاهش ویژگی توسط روش PCA، ۰.۶۱۵ ثانیه می باشد. و مدت زمان لازم برای تحلیل ویژگی ها توسط روش LDA، ۶۲ میلی ثانیه می باشد.

## ۶-۴ مقایسه با روش های گذشته

نتایج به دست آمده در این تحقیق با روشهای گذشته، مقایسه شده است که نتیجه به دست آمده را در جدول ۹-۴ مشاهده می کنید.

جدول ۹-۴-مقایسه روش پیشنهادی با روش های گذشته

| روشهای مختلف         | دقت شناسایی |
|----------------------|-------------|
| CLBP                 | ۹۶.۴۷       |
| LBPH                 | ۹۶.۳۶       |
| هوانگ و همکاران [43] | ۹۵.۴۹       |
| دریرا و همکاران [29] | ۹۴.۶۷       |
| لی و همکاران [44]    | ۹۴.۴۸       |
| براتی و همکاران [45] | ۹۴          |
| موسوی و همکاران [46] | ۹۱          |
| انحنای میانگین+LDA   | ۹۱          |
| ماهور و همکاران [28] | ۷۸          |

**۵ نتیجه گیری**



## ۵-۱ نتیجه گیری

در این تحقیق یک سیستم شناسایی چهره با کمک تصاویر سه بعدی ارائه شده است. در روش پیشنهادی، بعد از پیش پردازش لازم برای حذف نویز و قسمت های اضافی تصویر، استخراج ویژگی با روش های مختلفی انجام گرفته است و ویژگی های به دست آمده توسط دو دسته بند نزدیکترین همسایه و ساده بیزی مورد بررسی قرار گرفته اند.

روش های پیاده شده در این تحقیق در دو گروه روش های کل نگر و جزء نگر دسته بندی می شوند. در روشهای کل نگر، ما از سه ویژگی عمق، انحنای میانگین و انحنای گوسی استفاده کرده ایم و با اعمال روش های PCA و LDA ابعاد هریک از این ویژگی ها را کاهش داده ایم. بهترین نتیجه به دست آمده در روش های کل نگر مربوط به ویژگی انحنای میانگین با دقت ۹۱.۰۹ درصد می باشد. که این دقت با ترکیب دو روش PCA و LDA حاصل می شود. مزیت این روش ساده بودن پیاده سازی و سرعت بالای اجرای آن می باشد.

در روش های جزءنگر ما از ویژگی های الگوی باینری محلی کامل (CLBP)، الگوی باینری مبتنی بر واریانس (VLBP)، الگوی باینری مبتنی بر انحنای گوسی (LBPK) و الگوی باینری محلی مبتنی بر انحنای میانگین (LBPH) استفاده کرده ایم. ویژگی های VLBP و CLBP در شناسایی چهره با کمک تصاویر دو بعدی مورد استفاده قرار گرفته اند و در این تحقیق ما برای اولین بار از این ویژگی ها بر روی تصاویر عمق استفاده می کنیم. همچنین ویژگی های LBPH و LBPK به عنوان دو روش جدید برای استخراج ویژگی در این تحقیق ارائه شده است.

در هریک از روش های جزء نگر از روش LDA باری کاهش ابعاد ویژگی ها استفاده شده است. نتایج مختلفی بر حسب ویژگی های مختلف به دست آمده است که بهترین نتیجه مربوط به روش LBP\_S/M/C با دقت ۹۶.۴۷ درصد می باشد.

ویژگی LBPH با دقت ۹۶.۳۶، ویژگی LBPK با دقت ۹۳.۸۴ و ویژگی VLBP با دقت ۹۳.۳۳ درصد دقت قابل قبولی را ارائه می کنند.

این آزمایش بر روی یک پایگاه داده (GAVAB) با تصویر هایی که شامل انواع وضعیت های نامطلوب در شناسایی چهره از قبل خندیدن، نگاه به بالا و پایین، چرخش سر به چپ و راست و همچنین حالت های تصادفی چهره است انجام شده است.

با توجه به نتایج به دست آمده و با در نظر گرفتن این نکته که تصویر سه بعدی مستقل از نور محیط می باشد، می توان گفت سیستم پیشنهادی در این تحقیق می تواند تا حدود زیادی مشکل تغییر روشنایی و تغییر حالت چهره، را در شناسایی چهره با تصویر دو بعدی حل کند.

## ۲-۵-۲ پیشنهادات برای کار های آینده

- ارائه روشهای دقیق تر برای حذف قسمت های اضافی تصاویر به منظور افزایش سرعت

سیستم

- ترکیب اطلاعات سه بعدی با اطلاعات شدت روشنایی به منظور افزایش دقت سیستم

شناسایی

- ارائه روش های دقیق به منظور تخمین زاویه چهره و چرخش چهره برای به دست آوردن

تصویر روبرو

- تعیین نقاط خاص روی چهره که با تغییر حالت چهره ثابت هستند و می توان از این نقاط

ویژگی های مقاوم استخراج کرد، برای مثال انحنای بینی

- [1] M. Turk and A. Pentland, "Eigenfaces for recognition," *Journal of Cognitive Neuroscience*, 1991.
- [2] P. Belhumeur, J. Hespanha and D. Kriegman, "Eigen faces vs Fisherfaces: Recognition Using Class Specific Linear Projection," *IEEE Trans*, pp. PAMI-19(7), 1997.
- [3] Wiskott L., Fellous R., Kruger N., Malsburg C, "Face recognition by elastic bunch graph," *IEEE Trans. Pattern Anal. Mach. Intell.* 19 (7), p. 775–779 , 1997.
- [4] T. Ojala and M. Pietikäinen, "A comparative study of texture measures with classification based on featured distributions," , *Pattern Recognition*, vol. 29, no. 1, pp. 51-59, 1996.
- [5] Z. L. Stan and K. J. Anil, Hndbook of face recognition.
- [6] D. A. Socolindky, A. Selinger and J. D. Nueheisel, "face recognition with visible and thermal infrared imagery," *Computer Vision and Image Understanding*, vol.91, no 1-2, pp. 72-114, 2003.
- [7] Y. Fu, G. Guo and T. S. Huang, "Age Synthesis and Estimation Via Faces:A Survey," *IEEE Trans. Pattern Anal. Mach. Intell*, vol.32, no.11, pp. 1955-1976, 2010.
- [8] K. Bowyer, K. Chang and P. Flynn, "A survey of approaches and challenges in 3d and multi-model 3d+2d face recognition," *CVIU*, pp. 1-15, 2006.
- [9] F. Samaria and A. Harter, "Parameteristaion fo Stochastice Model for Human Face Identification," *In Workshop on Applications of Computer Vision*, pp. 17-32, 1994.

- [10] H. Bartlett, M. Lades and J. T. Sejnowski, "Independent component representations for face recognition," in *Proceedings of SPIE*, vol. 3299, pp. 528-539, 1998.
- [11] A. Bruce, B. Kyngim and M. Bartlirt, "Recognizing Faces with PCA and ICA," 2002.
- [12] W. Gerstne, A. Germond and M. Hasler, "Kernel principal component analysis," *Springer Lecture Notes in Computer Science*, 1997.
- [13] H. M. Yang, "Face recognition using kernel methods," *Advances in Neural Information Processing Systems*, vol. 14, pp. 1-8, 2002.
- [14] J. Zou, Q. Ji and G. Nagy, "A Comprative Study of Local matching approach for face recognition," *IEEE Transactions on Image Processing*, vol.16,no.10, pp. 2617-2628, 2007.
- [15] C. Liu and H. Wechsler, "Gabor feature based classification using the enhanced fisher linear discriminate model for face recognition," *IEEE Transactions on Image Processing*, vol.11,no.4, pp. 467-476, 2002.
- [16] J. Luo and E. E Takikawa, ". Person-specific sift features for face recognition," in *Conference on Computer Vision and Pattern Recognition Workshop*, 2006.
- [17] T. Ahonen and A. Hadid, "Face recognition with Local Binary Patterns," in *European Conference on Computer Vision*, 2004.
- [18] X. Tan and B. Triggs, "Enhanced Local Texture Feature Sets for Face Recognition Under Difficult Lighting Conditions," *IEEE Transactions on Image Processing*, pp. 1635-1650, 2010.
- [19] D. G. Lowe, "Distinctive Image Features from Scale-Invariant Keypoints," *International Journal of Computer Vision*, pp. 91-110, 2004.
- [20] C. Heshner, A. Srivastava and G. Erlebacher, "Principal Component Analysis of Range Images for Facial Recognition," in *Proceedings of CISST*, Las Vegas, 2002.

- [21] T. Heseltine, N. Pears and J. Austin , "Three-dimensional face recognition A fishersurface approach," *Image Analysis and Processing, ICIAP*, 2004.
- [22] B. Achermann and H. Bunke, "Classifying range images of human faces with Hausdorff distance," in *15-th International Conference on Pattern Recognition*, 2000.
- [23] G. G. Pan, Z. Wu and Y. Pan, "Automatic 3D face verification from range data," in *International Conference on Acoustics, Speech, and Signal*, 2003.
- [24] X. Lu and A. Jain, "Deformation modeling for robust 3d face matching," *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 1377-1383, 2006.
- [25] S. Gupta, K. J. Aggarwal and M. Markey , "3D face recognition founded on the structural diversity of human faces," *IEEE Conf Computer Vision Pattern Recognition*, pp. 1-7, 2007.
- [26] J. Y. cartoux , J. T. Lapreste and M. Richetin , "face recognition by profile extraction from range images," *In workshop on Interpretation of 3d scenes* , pp. 194-199, 1989.
- [27] G. Antini, S. Berretti and P. Pala, "3D face Identification Based on Arrangement of Salient Wrinkles," *IEEE International Conference on MultiMedia and Expo*, pp. 85-86, 2006.
- [28] M. H. Mahoor and M. Abdol Mottaleb, "3D face recognition Based on 3d ridge line in range data," *IEE International Conference on Image Processing* , pp. 137-140, 2007.
- [29] H. Drira, B. Amor and M. Doadi, "Pose and expression-invariant 3D face recognition using elastic radial curves," in *British Machine Vision Conference*, 2010.

- [30] C. Chua, F. Han and Y. K. Ho , "3D human face recognition using point signature," in *IEEE International Conference on Automatic Face and Gesture Recognition* , 2000.
- [31] Y Lee, K. Park and J. Shim, "3D face recognition using statistical multiple features for the local depth information," in *16th International Conference on Vision Interface*, 2003.
- [32] A. B. Moreno and A. Sanchez, "face recognition using 3D surface-extracted descriptors," in *Irish Machine Vision and Image Processing Conference* , 2003.
- [33] N. Alyuz, B. Gokberk and L. Akarun, "Regional registration and curvature descriptors for expression resistant 3D face ecognition," , In *Proceedings of the IEEE 17th signal processing and communications applications conference*, p. 544–547, 2010.
- [34] S. Gupta, M. P. Sampat and Z. Wnag, "Facial range image matching using the Complex Wavelet Structural Similarity Metrics," in *IEEE Workshop on Applications of Computer Vision* , 2007.
- [35] G. Gordon, "Face recognition based on depth and curvature features," in *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1992.
- [36] C. Xu, T. Tan and Y. Wang, "Combining local features for robust nose location in 3d facial data," *IEEE International conference on Automatic Face and Gesture recognition*, pp. 308-311, 2004.
- [37] Y. Lee, K. Park and T. Yi, "3d face recognition using statistical multiple features for the local depth information," in *16th International Conference on Vision Interface*, 2003.
- [38] A. B Moreno, A. Sanchez and J. Velez, "Face recognition using 3D local geometrical features:PCA vs SVM," in *EEE Int. Symposium on Image and Signal Processing and Analysis*, 2005.

- [39] B. Preeti and M. Goyani, " 3D FACE RECOGNITION TECHNIQUES - A REVIEW," *International Journal of Engineering Research and Applications (IJERA)*, Vol. 2, pp. 787-793, 2012.
- [40] AB Moreno and A. Sanchez, "Gavabdb: A 3d face database," *Proc.2nd COST275 Work- shop on Biometrics on the Internet Fundamentals Advances and Applications*, pp. 77-82, 2004.
- [41] Ojala.T, M. Pietik and M. aenp, "Multiresolution gray scale and rotation invariant texture analysis with local binary patterns," *IEEE Trans. on Pattern Analysis and Machine Intelligence* , vol. 24, no. 7, pp. 971-978, 2002.
- [42] G. Zhenhua , Z. Lei and D. Zhang, "Rotation invariant texture classification using LBP variance (LBPV) with," *ELSEVIER Pattern Recognition 43* , pp. 706-719, 2010.
- [43] P. Besl and R. Jain , "Invariant surface characteristics for 3D object recognition in rangeimages," *Computer Vision, Graphics, and Image Processing*, vol. 33, p. 33–80, 1986.
- [44] D. Huang, "Rubost Face Recognition Based On Three Dimensional Data," 2011.
- [45] X. Li, j. Tao and H. Zhang, "Expression-Insensitive 3D Face Recognition using Sparse Representation," *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 2575-2582, 2009.
- [46] S. Berretti, A. D. Bimbo and P. Pala, "3D face recognition by modeling the arrangement of concave and convex regions," *Lecture Notes in Computer Science*, vol. 4398(1), pp. 10-18 , 2007.
- [47] M. H. Mousavi, K. Faez and A. Asghari, "Three dimensional face recognition using svm classifier," *Proc. of IEEE/ACIS Int. Conf. on Computer and Information Science*, pp. 208-213, 2008.

- [48] Y. Huang, Y. Wang and T. Tan, "Discriminating 3d faces by statistics of depth differences," in *Asian Conference on Computer Vision*, Vol 2, 2007.
- [49] P. Langley, W. Iba and K. Thompson, "An Analysis of Bayesian Classifiers," *10th Nat. Conf. on Artificial Intelligence*,, p. 223–228, 1992.





## Abstract

One of the biometric ways for identifying people could be using visage's features. As in this way physical contacts with persons are not needed, so it is very noticed socially. Two dimensional modern identifying systems, do well in controlled and steady conditions, although changes in image's lightings and visage's different gestures are going to be it's problems. But, three dimensional images can show objects regardless light level clearly.

This study aims to improve function of face's identifications systems in improper conditions such as lighting, gesture and uncontrolled positions by using three dimensional images information. This study is done on the base of data station (GAVAB) with images included different improper kinds of positions in identifying visages such as laughing, up and down glance, turning head to left and right and also accidental positions of face.

Methods of this study are categorized into two holistic and component based methods. In holistic methods we have used three characteristics of depth, mean curvature and Gaussian curvature. The best conclusion in holistic methods due to the mean curvatures features with 91.9 percent accuracy. Simplicity and high speed are the privileges of this method.

In component based methods we have used features of complete local binary patterns (CLBP), binary patterns based on variance (LBPV), binary patterns based on Gaussian curvature (LBPk) and binary patterns based on mean curvature (LBPH). Among these component based methods, best conclusion goes to LBP\_S/M/C method with 96.47 percent accuracy. Also in this study two specific new extraction methods (LBPH, LBPk) are introduced.

**Key Words:** three dimensional visage identification, GAVAB data station, holistic features, component based features





Shahrood University of Technology

Faculty of Electrical & Robotics Engineering

Electrical and Robatic Department

Thesis Submitted for the Degree of Master of Science

Face Recognition By Using Three-dimensional Images

Abolfazl Arab

Supervisor:

Dr.Omid Reza Marouzi

Winter 2014