


آموزش کاربرد پردازش تصویر با پایتون

امیرحسین ملک زاده



سخن نویسنده

من فارق التحصیل رشته برق - کنترل دانشگاه سراسری کاشان هستم. بخاطر فعالیتیم در زمینه رباتیک، پردازش تصویر و هوش مصنوعی برای من جذاب بودند و همیشه علاقه‌مند بودم در این زمینه‌ها مطالعه داشته باشم تا در نهایت در سال ۱۳۹۵ این اتفاق برای من رقم خورد. کتابی که شما در حال خواندن آن هستید در حقیت یادداشت‌های من در زمان یادگیری پردازش تصویر بود که پس از کمی اصلاحات تصمیم گرفتم تا آن را منتشر کنم تا افراد دیگری بتوانند از تجربه‌های هرچند اندک من استفاده نمایند. این کتاب براساس اسناد ارائه شده توسط انجمن opencv و چندین سایت دیگر جمع‌آوری شده. باتوجه به تغییرات در نسخه‌های مختلف کتابخانه opencv ممکن است در برخی توابع تغییراتی بوجود آمده باشد که با جست و جو در اینترنت میتوانید این مشکل را حل نمایید. این کتاب در سال ۱۳۹۵ - ۱۳۹۶ یادداشت شده است. از آنجا که این کتاب نسخه نخست است که منتشر می‌شود ممکن است دارای برخی اشکالات نگارشی باشد که پیشاپیش از شما عذرخواهی میکنم. امیدوارم خواندن این کتاب برای شما مفید باشد و دریچه‌ای باشد برای ورود شما به دنیای عظیم پردازش تصویر. در آخر تشکر میکنم از همه دوستانی که مرا در انتشار این کتاب تشویق نمودند.

فهرست

۹	پردازش تصویر چیست؟
۹	کتابخانه OpenCV
۱۰	مبانی
۱۰	تصویر چیست
۱۰	فضاهای رنگی
۱۳	سخنی با خوانندگان
۱۴	شروع کار با کتابخانه OpenCV
۱۴	خواندن و نوشتن تصویر
۱۸	نمایش تصویر با matplotlib
۱۹	خواندن یک دنباله ویدیویی
۲۱	دسترسی به پیکسل های یک تصویر
۲۵	خواص یک تصویر
۲۶	توابع رسم شکل روی تصویر
۲۹	ایجاد کنترل کننده Trackbar (اختیاری)
۳۱	Image ROI
۳۷	ایجاد قاب برای تصاویر (اختیاری)
۴۰	تکنیک های اندازه گیری و بهبود عملکرد
۴۰	عملیات محاسباتی
۴۴	عملگر های منطقی
۴۸	تبدیل فضای رنگ تصاویر
۵۰	تبدیل هندسی تصاویر
۵۴	انتقال
۵۵	چرخش
۵۶	محاسبه تابع تبدیل

۵۷	تبدیلات هندسی پیچیده تر
۵۹	تبدیل پرسپکتیو
۶۱	تغییر مقیاس
۶۲	اعمال threshold روی تصویر
۶۷	اعمال فیلتر بر روی تصویر
۶۷	فیلتر چیسست
۶۸	فیلتر BLURING
۷۰	فیلتر Gaussian
۷۱	فیلتر median
۷۲	فیلتر Bilateral
۷۳	فیلتر با هسته دلخواه
۷۵	تشخیص لبه
۷۵	فیلتر Laplacian
۷۸	فیلتر Scharr
۸۲	عملگر Canny
۸۳	ریخت شناسی یا Morphology
۸۳	تصاویر باینری :
۸۴	ریخت شناسی :
۸۵	عملیات های ریخت شناسی
۸۵	Erosion
۸۶	Dilation
۸۷	عملگر Closing
۸۸	عملگر Morphological Gradient
۸۸	عملگر Top Hat
۸۹	عملگر Black Hat
۸۹	ساخت یک Kernel متفاوت

۹۱	کانتورها
۹۱	کانتور چیست
۹۶	توابع کانتور
۱۰۲	خصوصیات هندسی یک کانتور
۱۰۳	سایر توابع کانتور
۱۰۳	رسم خط بر کانتور
۱۰۴	Mask کانتور
۱۰۴	: Max min Value & Location
۱۰۴	: Mean Color
۱۰۴	Extreme Point
۱۰۵	: convexity defect
۱۰۶	وضعیت یک نقطه نسبت به کانتور
۱۰۷	تشخیص شباهت دو شکل
۱۰۹	hierarchy یا سلسله مراتب
۱۱۴	هیستوگرام
۱۱۴	هیستوگرام چیست
۱۱۴	محاسبه هیستوگرام تصویر
۱۱۷	Equalization Histogram بهبود کنتراست با
۱۱۹	هیستوگرام دو بعدی
۱۲۱	تشخیص محتوای خاصی از تصویر
۱۲۵	مقایسه محتوای دو تصویر با هیستوگرام
	مباحث تکمیلی
	Error! Bookmark not defined.
۱۲۸	تطابق الگو (Template Matching)
۱۳۲	تشخیص خطوط
۱۳۵	تشخیص دوائر در تصویر
۱۳۷	watershed یا الگوریتم آبگیر

۱۴۰		الگوریتم Grab Cut
۱۴۴		درک ویژگی‌های یک تصویر و تطابق دو تصویر
۱۴۴		درک ویژگی‌های یک تصویر
۱۴۶		تشخیص گوشه‌های تصویر با الگوریتم هریس
۱۴۷		یافتن گوشه‌ها با الگوریتم shi_tomasi
۱۵۰		الگوریتم SIFT
۱۵۴		الگوریتم SURF
۱۵۷		الگوریتم FAST
۱۶۰		BRIEF
۱۶۱		الگوریتم ORB
۱۶۳		تطبیق ویژگی‌ها با Brue_Force
۱۶۸		تطبیق ویژگی‌ها با FLANN
۱۷۰		یافتن شی با استفاده از تطابق و هوموگرافی
۱۷۴		پردازش دنباله‌های ویدیویی
۱۷۴		الگوریتم meanshift
۱۷۸		الگوریتم CamShift
۱۸۱		الگوریتم Optical flow
۱۸۵		الگوریتم Background Subtraction
۱۸۵		الگوریتم BackgroundSubtractorMOG
۱۸۷		الگوریتم BackgroundSubtractorMOG۲
۱۸۸		الگوریتم BackgroundSubtractorGMG
۱۸۹		یادگیری ماشین
۱۸۹		الگوریتم KNN (k nearest neighbour)
۱۹۳		ساخت برنامه OCR برای خواندن اعداد لاتین
۱۹۶		ساخت برنامه OCR برای خواندن حروف لاتین
۱۹۸		برنامه خواندن دست خط (OCR) با الگوریتم SVM :

۲۰۵.....	الگوریتم خوشه‌بندی K-Means
۲۱۵.....	تشخیص شی در opencv (تشخیص چهره با haar-cascades) :
۲۱۹.....	شناسایی چهره (face recognize) (اختیاری)

پردازش تصویر چیست؟

پردازش تصویر یعنی انجام عملیاتی بر روی تصویر برای تولید یک تصویر مطلوب جدید یا استخراج اطلاعات لازم. هنگامی که شما با گوشی هوشمند خود عکس برداری می‌کنید. گوشی شما با استفاده از پردازش تصویر، عکس شما را از نظر رنگ اصلاح می‌کند و نویزهای آن را حذف می‌کند تا شما تصویر مطلوب تری بدست آورید. هنگامی که شما در اینستاگرام خود رنگ‌بندی یک تصویر را تغییر می‌دهد، به عکس خود استیکر و متن اضافه می‌کند درحقیقت بر روی تصویر پردازش انجام می‌دهید تا تصویر جدید مطلوب خود را بدست آورید. از سوی دیگر پردازش تصویر می‌تواند اطلاعات مورد نیاز ما را از تصویر استخراج نماید. برای مثال هنگام عکس برداری با گوشی هوشمند خود متوجه شده اید که گوشی شما در تصویر برای فوکوس بهتر، چهره های موجود در تصویر را شناسایی می‌کند یا هنگامی که در جاده با سرعت غیر مجاز رانندگی می‌کنید، دوربین‌های نظارتی پلاک شما را از تصویر استخراج می‌نمایند. پردازش تصویر در زمینه‌های مختلفی مانند، نظامی، کشاورزی، خدماتی و... کاربرد دارد. و با پیشرفت روز به روز تکنولوژی، کامپیوترهایی که قدرت دیدن دارند، بخشی از زندگی ما هستند و خواهند بود.

کتابخانه OpenCV

این کتابخانه ابتدا در سال ۱۹۹۹ توسط اینتل ساخته شد. OpenCV یک کتابخانه متن باز بوده و هر روز در حال گسترش است. این کتابخانه از طیف گسترده‌ای از زبان‌های برنامه‌نویسی نظیر `python`, `c++`, `java` و غیره پشتیبانی می‌کند و در سیستم عامل‌های مختلف نظیر ویندوز، اندروید، لینوکس، ios پیاده سازی می‌شود. شاید بتوان مهم ترین ویژگی این کتابخانه پردازش تصویر را در متن باز و رایگان آن دانست که این کتابخانه را تبدیل به پر طرفدارترین کتابخانه پردازش تصویر کرده است.

openCV-Python: یک API برای پایتون است که ترکیب قوی از زبان پایتون و API زبان `c++` می‌باشد. در این کتابخانه از ماژول `numpy` که یک کتابخانه قوی برای عملیات عددی استفاده شده است. تمام ساختارهای آرایه‌ای OpenCV به آرایه‌های `numpy` تبدیل می‌شوند

آموزش نصب opencv

برای نصب ابتدا لازم است که پایتون ۳ را بر بروی سیستم خود نصب نمایید. برای نصب OpenCV کافی است در پنجره `cmd` دستور زیر را وارد نمایید، در صورتی که اتصال شما به اینترنت برقرار باشد، این پکیج به صورت خودکار بر روی سیستم شما دانلود و نصب خواهد شد.

```
pip install opencv-python
```

مبانی پردازش تصویر

تصویر چیست

تصویر از تعدادی پیکسل تشکیل شده است. پیکسل کوچکترین واحد یک تصویر است که از یک رنگ تشکیل شده است در کامپیوتر و دیجیتال تصاویر در حقیقت آرایه ای از اعداد هستند. که ابعاد این آرایه برابر با ابعاد تصویر ما می باشد. برای مثال برای نمایش یک تصویر سیاه و سفید $480 * 640$ از یک آرایه با 640 ستون و 480 سطر استفاده می شود. آرایه تصویر علاوه بر داشتن سطر و ستون دارای پارامتر دیگری با نام عمق می باشد که این پارامتر بر اساس فضای رنگی تصویر متفاوت است

0	1	1	2	2	2	1	1	0
1	2	4	5	5	5	4	2	1
1	4	5	3	0	3	5	4	1
2	5	3	-12	-24	-12	3	5	2
2	5	0	-24	-40	-24	0	5	2
2	5	3	-12	-24	-12	3	5	2
1	4	5	3	0	3	5	4	1
1	2	4	5	5	5	4	2	1
0	1	1	2	2	2	1	1	0


فضاهای رنگی

فضای رنگی یک تصویر قرار دادی است که نمایش و ذخیره رنگ ها در کامپیوتر را مشخص می کند که دارای انواع مختلفی می باشد. در ادامه تعدادی از پرکاربردترین فضاهای رنگی را توضیح خواهیم داد.


فضای رنگی خاکستری : همانگونه که از نام این فضای رنگی مشخص است، این فضا برای ذخیره و نمایش تصاویر سیاه و سفید کاربرد دارد. در این فضا هر پیکسل با یک عدد مشخص می شود، که در سیستم ۸ بیتی این عدد مقداری بین ۰ تا ۲۵۵ می باشد که ۰ به معنای سیاه مطلق و ۲۵۵ به معنای سفید است. آرایه متناظر با یک تصویر سیاه و سفید، یک آرایه دو بعدی می باشد که ابعاد آن برابر است با : عرض تصویر * طول تصویر




فضای رنگی RGB: این فضای رنگ برای نمایش تصاویر رنگی کاربرد دارد و نزدیک ترین فضای رنگی به درک انسان می‌باشد. در این فضا کلیه رنگ‌ها، از ترکیب سه رنگ اصلی قرمز، سبز و آبی تشکیل می‌شوند. در این فضای رنگی هر پیکسل با سه عدد مشخص می‌شود که این اعداد متناسب با مقدار سه رنگ اصلی می‌باشند و در سیستم ۸ بیتی، مقداری بین ۰ تا ۲۵۵ دارند که ۰ به معنای نبودن آن رنگ و ۲۵۵ به معنای کامل بودن آن است. برای مثال پیکسل [۲۵۵, ۰, ۰] نشان دهنده قرمز خالص و پیکسل [۰, ۱۰۰, ۰] نشان دهنده آبی کم رنگ می‌باشد. از این رو در این فضای رنگی، آرایه متناظر با تصویر سه بعدی بوده و دارای ابعاد زیر است $3 * W * H$ می‌باشد. در حقیقت تصویر در این فضای رنگی، از قرار گرفتن سه تصویر با رنگ‌های اصلی بر روی هم ایجاد می‌شود



فضای رنگی CMYK: این فضای رنگ در چاپ تصاویر رنگی کاربرد دارد و از چهار رنگ سیاه، زرد، آبی کمرنگ و صورتی تشکیل می‌شود. این رنگ‌ها در حقیقت همان فضاها را اشتراکی در فضای رنگی RGB هستند.



فضای رنگی HSV : این فضای رنگی از سه پارامتر رنگ (hue) ، میزان اشباع رنگ (saturation) و میزان نور (value) تشکیل شده است. این فضای رنگ در پردازش تصاویر رنگی بسیار کاربرد دارد که علت آن در فصل‌های بعدی توضیح داده می‌شود. در این فضای رنگ هر پیکسل با سه مقدار مشخص می‌شود که متناظر با سه پارامتر گفته شده می‌باشند. با استفاده از پارامتر hue ما رنگ مورد نظر خود را می‌توانیم از حلقه رنگی برگزینیم. پارامتر saturation میزان اشباع رنگ را مشخص می‌کند. شاید اگر تاکنون دست به نقاشی با رنگ‌هایی مثل ابرنگ یا اسپری و... شده باید متوجه اشباع رنگ شدید. فرض کنید می‌خواهید یک آسمان را در نقاشی خود رنگ کنید. ابتدا قلموی خود را به رنگ آبی اغشته می‌کنید و شروع به رنگ زدن آسمان می‌کنید اما ممکن است در بار نخست آسمان آبی شما کم رنگ باشد یا به اصطلاح میزان اشباع آن کم باشد. پس بار دیگر قلموی خود را به رنگ آبی اغشته می‌کنید و آسمان را مجدد رنگ آمیزی می‌کنید. اینبار بدون آنکه رنگ خود را تغییر دهید آسمان شما پررنگ تر می‌شود. در حقیقت شما رنگ آبی خود را تغییر نمی‌دهد بلکه میزان اشباع آن را تغییر می‌دهید تا رنگی با اشباع بیشتر، داشته باشید. اما در آخر پارامتر value میزان تاثیر نور بر رنگ شما را مشخص می‌کند. فرض کنید یک جسم قرمز در دست دارید اگر شما در مکانی با نور مناسب قرار بگیرید شما جسم خود را قرمز روشن‌تری می‌بینید. اما اگر حال چراغ‌ها را خاموش کنید شما جسم خود را تیره تر می‌بینید. اما در واقع رنگ جسم شما تغییر نکرده است تنها میزان نور آن تغییر کرده است و چه بسا در تاریکی مطلق شما جسم خود را کاملاً سیاه ببینید. در فضای رنگی RGB با تغییر نور، هر سه پارامتر RGB ممکن است تغییر کنند و اصالت رنگ جسم شما از بین برود. اما در فضای رنگی HSV تغییر نور تنها بر روی پارامتر V موثر است و Hue و saturation رنگ شما را تغییر نمی‌دهد. پس به راحتی می‌توان در فضای رنگی HSV تاثیر نور را تحت کنترل داشته باشید. از این رو همانند فضای رنگ RGB، تصاویر در این فضای رنگ با یک آرایه سه بعدی نمایش داده میشوند



سخنی با خوانندگان

در این کتاب هدف اصلی پیاده سازی الگوریتم‌های پردازش تصویر با کتابخانه `opencv` و زبان `python` می‌باشد. ما در این کتاب به بررسی تئوری‌های پردازش تصویر، جزئیات الگوریتم‌ها نخواهیم پرداخت و مباحث تا حد نیاز برای بکارگیری کاربردی پردازش تصویر ارائه شده است. شما می‌توانید در صورت علاقه به کتاب مبانی پردازش تصویر گنزالس مراجعه نمایید. این کتاب به زبان فارسی نیز ترجمه گردیده است. توصیه اینجانب آن است که در ابتدا الگوریتم‌های پردازش تصویر را در عمل فراگرفته و در نهایت برای درک بهتر، جزئیات الگوریتم‌های ارائه شده را مطالعه نمایید.


شروع کار با کتابخانه OpenCV

خواندن و نوشتن تصویر

پیش از هر ار برای شروع پردازش تصویر ما لازم داریم تا یک تصویر را از روی حافظه بخوانیم یا تصاویر دوربینمان را دریافت نماییم. برای خواندن یک تصویر از تابع `imread()` استفاده می‌کنیم. پارامترهای این تابع به صورت زیر می‌باشند.

`Imread( image Address , flags) -> dst`

Image Address: آدرس و نام تصویر همراه با پسوندش مورد نظر در این بخش در بین " " وارد می‌گردد. اگر سورس کد و تصویر ما در یک فایل قرار داشته باشند وارد کردن نام تصویر همراه با پسوندش کفایت می‌کند. پس به شما توصیه می‌کنیم که عکس مورد نظر خود را در یک پوشه کنار کد خود قرار دهید تا نیازی به وارد کردن آدرس نداشته باشید و در صورت جابه جایی فایل های خود برنامه شما بدون مشکل اجرا گردد.



Brief.py - D:\Electrical And Programming office\2-Open CV\project\python\BRIEF\Bri...

File Edit Format Run Options Window Help

```
import cv2
```

```
img=cv2.imread ("Wall-E.jpg" , 0)
```

تذکر: در آدرس تصویر به جای وارد کردن / باید // را وارد نمایید

Flags : این پارامتر میتواند یکی از سه پرچم زیر باشد. همچنین می توان به جای این پرچم ها مقادیر عددی متناظرشان که در داخل پرانتز نوشته شده اند را به کار ببریم

۱- IMREAD_COLOR : تصویر را به عنوان یک تصویر رنگی لود می کند (می توان از مقدار عددی ۱ نیز به جای پرچم فوق استفاده نمود)

۲- IMREAD_GRAYSCALE : تصویر را به عنوان یک تصویر خاکستری لود میکند (می توان از مقدار عددی ۰ نیز به جای پرچم فوق استفاده نمود)

۳- IMREAD_UNCHANGED : تصویر را همراه کانال آلفا لود می کند. (می توان از مقدار عددی -۱ نیز به جای پرچم فوق استفاده نمود)

و در صورتی که مقدار این flag را مشخص نکنید، مقدار پیش فرض آن یعنی ۱ در نظر گرفته می شود.

کانال آلفا چیست؟

شاید پیش از این با تصاویری مانند آیکون ها، مواجه شده باشید که بخش هایی از این تصاویر حذف شده باشند. اگر با فتوشاپ کار می کنید قطعا خودتان این کار را انجام داده اید. به چنین تصاویری کانال آلفا می گویند.

```
img0 = cv2.imread ("cat.JPG")
img1 = cv2.imread ("C:\\Users\\Amir_PC\\Desktop\\image.jpg" )
img2 = cv2.imread ("face.jpg" , 0)
cv2.imshow("image1" , mat)
```

مثال :

حالا که توانستیم یک تصویر را اصطلاحاً لود نماییم، قدمی بعدی نمایش تصویر است تا از اجرای درست مرحله قبل مطمئن شویم و همچنین تغییراتی را که در ادامه بر روی تصویر ایجاد می کنیم را بتوانیم به صورت بصری مشاهده نماییم. برای نمایش یک تصویر از تابع imshow() استفاده می کنیم که پارامتر های آن به صورت زیر می باشد.

imshow(" Windows name " , image)

Windows name : نام پنجره ای که تصویر در آن نمایش داده می شود. این نام می تواند کاملاً دلخواه باشد.

Image : نام تصویری که می خواهیم آن را نمایش دهیم.

مثال:

```
>>> mat=cv2.imread("cat.JPG")
>>> cv2.imshow("image1" , mat)
```

در گام آخر می‌خواهیم نحوه ذخیره ی یک تصویر در **opencv** را توضیح دهیم. گاهی لازم است تا ما پس از انجام پردازش بر روی تصویر، تصویر نهایی را ذخیره نماییم. برای ذخیره یک تصویر از تابع **imwrite()** استفاده می‌کنیم.

Imwrite (" image Name & Address" , imag) -> retval (bool)

image Name & Address : آدرس و نامی که می‌خواهیم تصویر را با آن ذخیره کنیم. اگر آدزی برای تصویر وارد نکنیم و تنها نام آن را بنویسیم، تصویر در فایل سورس کد ذخیره می‌شود.

Imag : نام تصویری که می‌خواهیم ذخیره کنیم.

مثال :

```
Cv2.imwrite ("C:\\Users\\Amir_PC\\Desktop\\my.jpg", img )
```

در کد بالا تصویر **img** در آدرس فوق و با نام **my** و فرمت **jpg** ذخیره می‌شود.

برای یک درک بهتر از توابعی که تاکنون آموزش دیده ایم. یک مثال جامع بیان می‌کنیم. در مثال زیر ما یک تصویر را به طور خاکستری لود می‌کنیم و آن را نمایش می‌دهیم سپس اگر کلید **S** را فشار دهیم تصویر ذخیره می‌شود و اگر **ESC** را فشار دهیم کلیه پنجره ها بسته می‌شوند

```
import cv2

img = cv2.imread('messi5.jpg',0)
cv2.imshow('image',img)

k = cv2.waitKey(0)

if k == 27:          # wait for ESC key to exit
    cv2.destroyAllWindows()
elif k == ord('s'):
    cv2.imwrite('messigray.png',img)
    cv2.destroyAllWindows()
```

در `opencv` لازم است تا پس از نمایش یک تصویر، تابع `cv2.waitKey()` را فرخوانی کنیم. اگر ورودی این تابع مقدار صفر باشد، برنامه منتظر زدن کلید از سوی کاربر می‌شود و اگر عددی غیر از صفر باشد، تابع به میزان عدد وارد شده بر حسب میلی ثانیه منتظر فشرده شدن کلید از سوی کاربر می‌شود و اگر کاربر در این زمان، کلیدی را از صفحه کیبورد فشار ندهد، برنامه به کار خود ادامه می‌دهد. خروجی این تابع یک مقدار عددی است که نشان دهنده کد کلیدی است که کاربر فشار داده. اگر این مقدار -۱ باشد یعنی کاربردی کلیدی را فشار نداده است. برای مثال کد ۲۷ نشان دهنده کلید `Esc` کیبورد است که در مثال بالا استفاده شده یا خروجی تابع `ord('s')` مقدار کد کلید `s` از صفحه کلید را باز می‌گرداند. استفاده از تابع `waitkey` به ویژه برای نمایش تصاویر در حلقه‌ها امری ضروری است. نمایش یک تصویر، امری زمان بر است و این تابع درحقیقت فرصتی برای اجرای آن فراهم می‌سازد. بنابراین اگر از این تابع استفاده ننماییم، دستور نمایش تصویر به `CPU` ارسال می‌شود و بیش از آنکه `cpu` فرصت نمایش تصویر را پیدا کند، دستور نمایش تصویر بعدی ارسال می‌گردد و بدین ترتیب تصویر ما به درستی به نمایش در نمی‌آید

نمایش تصویر با matplotlib

کتابخانه matplotlib یک از کاربردی ترین کتابخانه های پایتون بوده و این کتابخانه برای ترسیم و نمایش انواع تصاویر، آرایه ها است و انواع نمودار ها می باشد. نمایش تصویر با matplotlib امکانات ویژه ای در اختیار ما قرار می دهد مانند ذخیره عکس، زوم کردن و...

برای نصب matplotlib دستور مقابل را در CMD وارد کنید : `pip install matplotlib`

این کتابخانه دارای ماژول های بسیاری است. اما ماژول مورد استفاده ما pyplot می باشد. از این رو ماژول pyplot را از این کتابخانه لود میکنیم. برای نمایش یک تصویر در pyplot از تابع imshow() استفاده می کنیم. پارامتر نخست این تابع تصویر مورد نظر است. این تابع پارامتر های زیادی دارد که ما به طرح یک مثال بسنده می کنیم. پس از فراخوانی تابع فوق برای مشخص کردن عنوان های محور های X و Y از توابع xticks() و yticks() از ماژول pyplot استفاده می کنیم. ورودی این توابع رشته ای است که روی محور ها نشان داده می شود. در مثال زیر از آنجا که نمی خواهیم برچسبی بر روی محور های X, Y نمایش داده شوند، مقدار ورودی این توابع را خالی می گذاریم در نهایت با استفاده از تابع show() از همین ماژول تصویر را نمایش می دهیم.

مثال

```
numpy as np
import cv2
from matplotlib import pyplot as plt

img = cv2.imread('messi5.jpg',0)
plt.imshow(img, cmap = 'gray', interpolation = 'bicubic')
plt.xticks([], plt.yticks([]))  # to hide tick values on X and Y axis
plt.show()
```



خواندن یک دنباله ویدیویی

در کتابخانه `opencv` علاوه بر آنکه ما می‌توانیم بر روی یک تصویر پردازش کنیم، می‌توانیم بر روی یک دنباله ویدیویی نیز پردازش انجام دهیم. یک دنباله ویدیویی از تصاویری به نام فریم در فواصل زمانی یکسان و کوتاهی تشکیل شده است. عملیات پردازش بر روی تصویر و ویدیو یکسان است. در دنباله ویدیویی تنها به جای پردازش بر روی یک تصویر، ما بر روی فریم های یک فیلم به صورت تصاویر جداگانه پردازش انجام می‌دهیم

برای خواندن یک دنباله ویدیویی در `opencv` ابتدا لازم است تا یک شی از کلاس `VideoCapture` بسازیم. ورودی متد سازنده این کلاس می‌تواند نام فایل ویدیویی مورد نظر و یا `id` یک دوربین برای دریافت تصاویر زنده از آن باشد. آیدی دوربین پیشفرض یک سخت افزار برای مثال وب کم لبتاب شما یا دوربین برد های رزبری پای برابر با مقدار ۰ است و آیدی دوربین دوم ۱ و با همین روند ادامه دارد. پس از تعریف آبجکت از کلاس `VideoCapture` ما می‌توانیم با متد های این کلاس کار با دنباله ویدیویی را آغاز نماییم. در زیر به معرفی متدهای این کلاس می‌پردازیم.

`read() -> retVal (bool) , frame`

این متد برای خواندن فریم های دنباله ویدیویی به کار می‌رود. این تابع پارامتر ورودی ندارد. خروجی دوم این تابع `(frame)` فریم جاری و خروجی اول `(ret)` یک مقدار بولین است و اگر خواندن فریم بدون مشکل انجام شود مقدار `true` و در غیر این صورت مقدار `false` را باز می‌گرداند. از این خروجی میتوان برای تشخیص پایان ویدیو بهره برد.

`isOpened() -> retVal (bool)`

این تابع مشخص می‌کند که آیا فایل ویدیویی یا دوربین لود شده است یا خیر. خروجی این تابع یک مقدار `bool` است. اگر `true` باشد یعنی یک فایل باز شده و اگر `false` باشد یعنی فایل ویدیویی باز نشده است.

`get( probl) -> retVal / set( probl, value) -> retVal (bool)`

```
>>>cap.get(3)
640
>>>cap.get(4)
480
>>>cap.set(3,320)
>>>cap.set(4,240)
```

تابع `get()` می‌تواند برخی از ویژگی های فریم ها را دریافت کرد. ورودی این تابع عددی بین ۰ تا ۱۸ است که هر مقدار عددی یک از خصوصیات فایل ویدیویی را بر میگرداند. همچنین می‌توان توسط تابع `set` مقدار هر کدام از این خصوصیات را به مقدار مورد نظر تغییر داد. برای مثال ویژگی‌های ۳ و ۴ عرض و طول فریم ها را نشان میدهند. که می‌توان آنرا به مقدار مورد نظر نیز تغییر داد.

معرفی تابع release

گاهی نیاز است پس از دسترسی به سخت افزار دوربین و دریافت فریم، سخت افزار را رهاسازی نماییم تا اجازه دسترسی آن را به بخش های دیگر و نرم افزارهای دیگر بدهیم. برای مثال هنگامی که شما در حال خواندن از وب کم لبتاب خود هستید، امکان استفاده نرم افزار های دیگر از وب کم شما نیست و تا زمانی که شما سخت افزار دوربین خود را آزاد ننمایید این دسترسی برای بخش های دیگر بسته خواهد بود. تابع فوق وظیفه رهاسازی دوربین را دارد.

Open(Video Address OR Camera ID) -> retVal (bool)

این تابع برای باز کردن یک دنباله ویدیویی جدید مورد استفاده قرار می گیرد. ورودی این تابع آدرس فایل و یا آیدی دوربین مورد نظر می باشد.

مثال : در مثال زیر یک دنباله ویدیویی را از دوربین با آیدی ۰ (دوربین پیشفرض که در لب تاب همان وب کم شما است) میخوانیم و پس از تبدیل هر فریم آن به فضای رنگ خاکستری آن را نمایش می دهیم.

```
import numpy as np
import cv2
cap=cv2.VideoCapture (0)

while (True):

    ret,frame=cap.read()
    gray= cv2.cvtColor (frame , cv2.COLOR_RGB2GRAY )
    cv2.imshow (" WebCam", gray)
```

ذخیره دنباله ویدیویی : برای ذخیره یک دنباله ویدیویی ابتدا باید یک شی از کلاس VideoWriter تعریف کنیم. متد سازنده این کلاس شامل چهار پارامتر به صورت زیر است.

VideoWriter ("Out Video Name" , fourCC , frame per second , video size) -> retVal (bool)

Out Video Name : در این پارامتر نام فایل خروجی و فرمت آن را مشخص می کنیم.

fourCC : این پارامتر یک کد چهار بیتی است که کدک ویدیویی را مشخص می کند. و بستگی به پلتفرمی که روی آن پیاده سازی میکنیم دارد.

۱- برای ویندوز - < DIVX و ...

۲- برای لینوکس -> WMV۱ , WMV۲ , X۲۶۴ , DIVX, XVID, MJPG و ...

Frame per second : نرخ فریم فایل خروجی را مشخص میکند.

Vide size : سائز فایل خروجی را بر اساس طول و عرض فریم ها به صورت یک دوتایی دریافت می کند

مثال : در مثال زیر ما یک دنباله ویدیویی را از یک آدرس میخوانیم و با تغییری در آن ، آن را به عنوان یک فایل جدید ذخیره می نماییم

```
import numpy as np
import cv2

cap = cv2.VideoCapture('vist.avi ')

# Define the codec and create VideoWriter object
fourcc = cv2.VideoWriter_fourcc(*'XVID')
out = cv2.VideoWriter('output.avi',fourcc, 20.0, (640,480))

while(cap.isOpened()):

    ret, frame = cap.read()

    if ret==True:
        frame= cv2.cvtColor (frame , cv2.COLOR_RGB2GRAY )

        # write the flipped frame
        out.write(frame)
        cv2.imshow('frame',frame)

        if cv2.waitKey(1) & 0xFF == ord('q'):
            break
    else:
        break

cap.release()
out.release()
```

دسترسی به پیکسل های یک تصویر

همان طور که پیش از این گفته شد در کامپیوتر هر تصویر در حقیقت یک آرایه است. که هر درایه آن متعلق به یک ویژگی رنگی یک پیکسل است. بنابراین همانطور که به درایه های یک آرایه دسترسی مستقیم داریم. می توانیم به پیکسل های یک تصویر نیز دسترسی داشته باشیم. برای دسترسی به یک پیکسل مشخص کافی است شماره سطر و ستون آن پیکسل را بدانیم و در تصاویر رنگی شماره کانالی از پیکسل را که می خواهیم تغییر دهیم. نکته مهم آن است که در **opencv** نقطه بالا و سمت چپ تصویر مختصات (۰,۰) است و با حرکت در راستای طول تصویر به سمت راست مختصات **x** یا شماره ستون افزوده می شود و با حرکت به سمت پایین مختصات **y** یا شماره سطر افزایش می یابد.

Img[row number , column number]

Img[row number , column number , channel number]

نکته : ترتیب کانال ها در **opencv** در کانال رنگی **RGB** به صورت **BGR** است.

بیایید با یک مثال درک بهتری نسبت به این موضوع پیدا کنیم

```
>>> import cv2
>>> import numpy as np

>>> img = cv2.imread('messi5.jpg')

>>> px = img[100,110]
>>> print(px)
[157 166 200]

# accessing only blue pixel
>>> blue = img[100,110,0]
>>> print blue
157
>>> img[100,110] = [255,255,255]
>>> print img[100,110]
[255 255 255]
```

در ابتدا ما کتابخانه **opencv** و کتابخانه **numpy** را فرخوانی می‌کنیم. کتابخانه **numpy** را می‌توان به جرئت کاربردی ترین کتابخانه پایتون دانست که رد پای آن در بسیاری از کتابخانه های پایتون و برنامه‌های مختلف می‌توان دید. در **opencv** نیز کتابخانه **numpy** یکی از پایه ها و ستون های اصلی این کتابخانه است. این کتابخانه قابلیت های بسیاری برای کار با آرایه‌ها در پایتون به ما می‌دهد از این رو استفاده از این کتابخانه در پردازش تصویر که هر عکس در حقیقت یک آرایه است، دور از ذهن نیست. در گام بعدی ما یک تصویر با نام 'messi5.jpg' را لود کرده در در متغیر **img** قرار می‌دهیم. **img** در اینجا در حقیقت تصویر ما یک تصویر رنگی است، بنابراین داده‌های آن به شکل یک آرایه سه‌بعدی ذخیره می‌شوند. ابعاد این آرایه به صورت (عرض تصویر، طول تصویر، ۳) هستند که بعد سوم نشان‌دهنده کانال‌های رنگی **B**، **G** و **R** است

برای مثال، اگر بخواهیم مقدار پیکسلی که در سطر ۱۰۰ و ستون ۱۱۰ قرار دارد را بخوانیم، می‌توانیم آن را در متغیری به نام **px** قرار دهیم. با چاپ **px**، مقدار [۲۰۰, ۱۶۶, ۱۵۷] نمایش داده می‌شود.

چون تصویر رنگی است، هر پیکسل دارای سه مقدار است:

مقدار ۱۵۷ مربوط به کانال آبی (B)

مقدار ۱۶۶ مربوط به کانال سبز (G)

مقدار ۲۰۰ مربوط به کانال قرمز (R)

این مقادیر با هم ترکیب شده و رنگ نهایی پیکسل را در تصویر ایجاد می‌کنند. لازم به ذکر است که هر درایه در تصویر از نوع **unsigned char** است و بنابراین مقداری بین ۰ تا ۲۵۵ دارد.

برای مثال، اگر پیکسل مورد نظر دارای رنگ سبز خالص باشد، مقدار آن برابر [۰, ۲۵۵, ۰] خواهد بود؛ یعنی تنها کانال سبز فعال است و به مقدار کامل خود (۲۵۵) تنظیم شده است.

همچنین می‌توانیم مقادیر هر کانال را به صورت جداگانه بخوانیم. برای مثال، جمله زیر مقدار کانال آبی پیکسل در سطر ۱۰۰ و ستون ۱۱۰ را برمی‌گرداند که در مثال ما برابر ۱۵۷ است.

Img[100,110,0]

```
import cv2
img=cv2.imread ("img.jpg")

for i in range(200,800 ):
    img[20,i] = [0,0,255]

cv2.imshow("res", img)
cv2.waitKey(0)
```

بیایید

یک مثال دیگر را بررسی کنیم. اینبار قصد داریم با دسترسی مستقیم به پیکسل‌های یک تصویر یک قرمز بر روی تصویر رسم نماییم. برای این کار کافی است پیکسل‌هایی را که خط مورد نظر ما از آن‌ها عبور میکند را مقدارشان را برابر [۰,۰,۲۵۵] قرار دهیم.



حال بیایید و یک مثال دیگر را بررسی کنیم. در این مثال می‌خواهیم مقدار سبز کلیه پیکسل‌های یک تصویر را حذف کنیم. برای این کار کافی است تا مقدار کانال یکم را برای همه پیکسل‌های تصویر برابر ۰ قرار دهیم.

```
import cv2

img=cv2.imread ("img.jpg")

for i in range(536):
    for j in range(858):
        img[i,j,1] = 0

cv2.imshow("res", img)
cv2.waitKey(0)
```



همان طور که مشاهده می کنید رنگ سبز در تصویر فوق فیلتر شده و کل تصویر تنها از ترکیب رنگ های قرمز و آبی حاصل گردیده و از این رو ما آن را به صورت طیفی از بنفش مشاهده می کنیم.

حال اگر تصویر ما خاکستری باشد اوضاع چگونه خواهد شد؟ در این صورت از آنجا که کانال رنگی نداریم آرایه تصویر ما یک آرایه دو بعدی خواهد بود و هر پیکسل تنها دارای یک مقدار می باشد که میزان روشنایی پیکسل را مشخص می کند. این مقدار اگر برابر ۰ باشد پیکسل مد نظر ما سیاه رنگ، اگر برابر ۲۵۵ باشد پیکسل ما سفید و هر مقداری بین این دو یک طیف خاکستری خواهد بود. همانند قبل می توانیم به راحتی به پیکسل های تصویر دسترسی داشته ، مقدار آن ها را بخوانیم و یا تغییر دهیم

```
>>> img=cv2.imread ("img.jpg",0)
>>> img[100,200]
172
>>> img[100,200] = 255
>>> img[100,200]
255
>>> img[100,200,0]
Traceback (most recent call last):
  File "<pyshell#13>", line 1, in <module>
    img[100,200,0]
IndexError: too many indices for array: array is 2-dimensional, but 3 were indexed
```

همچنین دسترسی و مقدار دهی پیکسل های یک تصویر توسط توابع `item()` و `itemset()` نیز امکان پذیر می باشد

`Item(row number , column number , channel number)`

`Itemset((row number, column number , channel number) , pixel new value)`

```
# accessing RED value
>>> img.item(10,10,2)
59

# modifying RED value
>>> img.itemset((10,10,2),100)
>>> img.item(10,10,2)
100
```

خواص یک تصویر

هر تصویر دارای ویژگی های منحصر به فرد خود است، مانند ابعاد، تعداد پیکسل ها و نوع داده هر پیکسل. دانستن این ویژگی ها می تواند در بسیاری از موارد به ما کمک کند. در ادامه، برخی از این ویژگی ها معرفی شده اند.

خاصیت `shape` ابعاد و تعداد کانال های یک تصویر را برمی گرداند.

- مقدار اول تعداد سطرهای تصویر را نشان می دهد، یا به عبارت دیگر، تعداد پیکسل های موجود در ارتفاع تصویر.
- مقدار دوم تعداد ستون های تصویر را مشخص می کند، یعنی تعداد پیکسل های موجود در عرض تصویر.
- اگر تصویر رنگی باشد، مقدار سوم تعداد کانال های تصویر را نشان می دهد.

اگر تصویر خاکستری باشد، تابع `shape` تنها دو مقدار برمی گرداند که سطر و ستون تصویر را مشخص می کنند و تعداد کانال ها در خروجی دیده نمی شود. `img.shap → (rows , columns , channels)`

```
>>> print img.shape
(342, 548, 3)
rows,cols,channels = img2.shape
```

خاصیت **size** تعداد پیکسل های یک تصویر را بر میگرداند. این مقدار می تواند از حاصل ضرب طول تصویر در عرض آن که از خاصیت **Shape** بدست می آیند نیز حاصل شود

```
>>> print img.size
562248
```

خاصیت **dtype** نوع پیکسل یک تصویر را بر میگرداند. که به صورت پیش فرض ۸ بیتی صحیح بدون علامت می باشد. یعنی هر درایه آرایه مقداری بین ۰ تا ۲۵۵ خواهد داشت

```
>>> print img.dtype
uint8
```

تمرین: برنامه ای بنویسید که یک تصویر را دریافت کند و تنها بخش هایی از تصویر که دارای رنگ قرمز هستند را نمایش دهد. راهنما: با بررسی مقدار پیکسل ها در یک حلقه تو در تو، پیکسل هایی که اختلاف کانال قرمز آن ها از هر دو کانال سبز و آبی بیشتر هستند را بدون تغییر و برای سایر پیکسل ها مقدار هر سه کانال پیکسل را برابر ۰ قرار دهید.

توابع رسم شکل روی تصویر

یکی از قابلیت های **opencv** امکان رسم اشکال هندسی بر روی یک تصویر است. گاهی این رسم شکل به عنوان هدف یک برنامه می باشد مانند نرم افزار **paint** ویندوز. گاهی ممکن است برای نمایش بصری یک فرایند پردازشی مورد استفاده قرار می گیرد مانند مستطیلی که نرم افزار دوربین گوشی شما اطراف صورت های شناسایی شده رسم می کند تا به کاربر اطلاعاتی که را پردازش نموده است به صورت گرافیکی نشان دهد. در زیر به معرفی توابع مختلف برای رسم اشکال مختلف بر روی تصویر می پردازیم. از آنجا که این بخش دارای فرآیند های واضحی بوده از توضیحات بیشتر خودداری کرده و تنها این توابع را معرفی می نمایم.

تابع () line: این تابع برای رسم یک خط روی شکل استفاده می شود.

`dst = line ( img , pt۱ , pt۲ , Color [, thickness , line type] )`

- **img:** تصویری که می خواهیم روی آن خط رسم کنیم
- **pt۱ , pt۲:** به ترتیب مختصات ابتدا و انتهای خط
- **Color:** رنگ خط مورد نظر که به صورت یک سه تایی وارد میشود (BGR)
- **Thickness:** ضخامت خط مورد نظر بر اساس پیکسل. اگر این پارامتر برای خطوط بسته مانند دایره ۱- داده شود. شکل مورد نظر به صورت **fill** تو پر رسم میگردد

- **Line type** : نوع خط نظیر نقطه چین بودن و... را مشخص می‌کند. مانند **LINE_AA** که برای خطوط منحنی مناسب است.

مثال :

```
import numpy as np
import cv2

img = cv2.imread("image.jpg")

cv2.line(img , (50,50 ) , (200,200) , (255,0,0) , 5)

cv2.imshow( "out" , img)
```



تابع **rectangle()**

این تابع برای رسم یک مستطیل روی تصویر مورد استفاده قرار می‌گیرد.

- **rectangle (img , pt₁ , pt₂ , Color [, thickness , line type]) ->dst**
- **pt₁,pt₂** : به ترتیب مختصات راس بالا سمت چپ و پایین سمت راست

مثال :

```
cv2.rectangle(img,(384,0),(510,128),(0,255,0),3)
```



تابع circle() :

برای رسم دایره روی تصویر کاربرد دارد

• dst -> circle (img , center , radius , Color [, thickness , line type])

```
cv2.circle(img,(447,63), 63, (0,0,255), -1)
```

مثال :

تابع ellipse :

این تابع برای رسم بیضی کاربرد دارد

dst -> ellipse (img , center , axes , angle , start angle , end angle [, Color , thickness])

- center : مختصات مرکز بیضی
- Axes : طول محور اصلی و فرعی بیضی که به صورت یک دوتایی وارد می شود.
- Angle : زاویه چرخش بیضی در جهت عقربه های ساعت
- Start/end angle : زاویه شروع و پایان قوس بیضی . برای مثال مقادیر ۰ , ۳۶۰ یک بیضی کامل رسم می کند

```
cv2.ellipse(img,(256,256),(100,50),0,0,180,255,-1)
```

مثال :

تابع polylines : برای رسم یک چند ضلعی و یا چند خط جدا مورد استفاده قرار می گیرد.

Polylines (img , pts , isClosed , Color [, thickness , line type]) ->dst

- **Pts** : این پارامتر آرایه‌ای از مختصات رئوس را تشکیل می‌دهد. هر دو مختصات متوالی در این آرایه تشکیل یک خط می‌دهند
- **isClosed** : اگر این پارامتر True باشد، خطوط ترسیمی به هم پیوسته و در غیر این صورت جداگانه ترسیم می‌شوند

مثال :

```
Pts=Np.array( [ [10,5] , [20,30] , [70,20] , [50,10] ] , np.uint16)
Pts.reshape((-1,1,2))
Cv2.polylines( img , pts , True , (0 , 255 , 255 )
```

نوشتن متن روی تصویر

برای نوشتن متن روی تصویر از تابع putText() استفاده می‌کنیم.

- **putText(img , text , org , font , Scale , color [, thickness , line type]) ->dst**
- **text** : متن مورد نظر که می‌خواهیم روی عکس بنویسیم.
- **Org** : مختصات شروع متن
- **Font** : فونت متن مورد نظر که از پرچم‌های پیشفرض نظیر (FONT_HERSHEY_SIMPLEX) استفاده می‌شود
- **Scale** : اندازه متن مورد نظر

مثال:

```
font = cv2.FONT_HERSHEY_SIMPLEX
cv2.putText(img,'OpenCV',(10,500), font, 4,(255,255,255),2,cv2.LINE_AA)
```

ایجاد کنترل کننده Trackbar (اختیاری)

گاهی لازم است برای تنظیم یک ویژگی در تصویر از کنترل‌کننده‌ای به نام **trackBar** یا همان نوار لغزان استفاده کنیم؛ همان ابزاری که با آن نور صفحه یا میزان صدای گوشی هوشمند خود را تنظیم می‌کنیم. برای ایجاد یک **trackBar** از تابع **createTrackbar** () استفاده می‌کنیم.

creatTrackbar("Trackbar name" , " windows name" , value , count , onChange)

- Trckbar name : نام نوار مورد نظر که در تصویر نیز به همین نام نشان داده می‌شود.
- Windows name : پنجره‌ای که منوی Trackbar روی آن نمایش داده می‌شود.
- Value : مقدار پیشفرض نوار لغزان
- Count : تعداد پله های نوار لغزان (ماکزیمم مقدار)
- onChange : نام تابعی دلخواه که به محض تغییر Trackbar فراخوانی می‌شود. این تابع باید یک پارامتر ورودی داشته باشد.

برای دریافت مقدار جاری Trackbar از تابع `getTrackbarPos()` استفاده میکنیم. این تابع نام Trackbar و windows را به عنوان پارامتر دریافت می‌کند

توجه شود که نام پنجره ای که track bar را به آن نسبت می‌دهید و نام پنجره ای که تصویر خود را در آن به نمایش می‌گذارید باید یکسان باشد.

```
import cv2
import numpy as np

def nothing(x):
    pass

mat = np.zeros ((640,480,3) , np.uint8 )
cv2.namedWindow ("image")

cv2.createTrackbar ("red","image",100,255,nothing)
cv2.createTrackbar ("green","image",100,255,nothing)
cv2.createTrackbar ("blue","image",100,255,nothing)


switch = '0 : OFF / 1 : ON'
cv2.createTrackbar (switch,"image" , 0,1,nothing)

while (True):

    key=cv2.waitKey(1)
    #print(key)
    if key==113:
        break
    #####
    r=cv2.getTrackbarPos ("red" , "image")
    g=cv2.getTrackbarPos ("green" , "image")
    b=cv2.getTrackbarPos ("blue" , "image")
    sw=cv2.getTrackbarPos (switch , "image")
    #####
    if sw==1:
        mat[:]=[b,g,r]

    cv2.imshow ("image" , mat)

pass
cv2.destroyAllWindows()
```



Imag ROI

به هر برشی از تصویر ROI میگویند. گاهی لازم است تا ما تنها بر روی بخش خاصی از تصویر پردازش کنیم برای اینکار ابتدا بخش مورد نظر از تصویر را برش داده و بخش برش داده شده را به عنوان یک تصویر جداگانه در نظر بگیریم و برش دهیم. برای برش یک تصویر ما از عملگر : در پایتون استفاده می‌کنیم. با استفاده از این عملگر می‌توانیم بخش خاصی از یک آرایه را برش دهیم. در صورتی که با این عملگر آشنا نیستید به لینک زیر مراجعه نمایید.

https://www.w3schools.com/python/numpy_array_slicing.asp

در مثال زیر ما تصویر توپ را در عکس برش داده و در متغیر ball قرار می‌دهیم سپس مقدار ball را برابر یک برش دیگر از تصویر قرار می‌دهیم و به این صورت ما یک کپی از توپ در تصویر ایجاد نمودیم

```
>>> ball = img[280:340, 330:390]
>>> img[273:333, 100:160] = ball
```





Split and merg

گاهی در پردازش تصویر لازم است تا ما تنها بر روی یک کانال رنگی از تصویر پردازش انجام دهیم. برای مثال فرض کنید می‌خواهیم رنگ سبز را در یک تصویر اصلاح کنیم برای اینکار کافی است تا پردازش خود را بر روی کانال سبز معطوف کنیم یا برای مثال می‌خواهیم. مستطیل‌های قرمز رنگ در یک تصویر را جداسازی برای این کار می‌توانیم در فضای رنگی HSV پردازش خود را تنها بر روی کانال‌های h و s انجام دهیم تا تاثیر نور بر روی رنگ را در نظر نگیریم. از این رو جداسازی و ادغام کانال‌های رنگی یکی از عملیات‌های کاربردی در پردازش تصویر است. برای جداسازی کانال‌های یک تصویر از تابع `split` استفاده می‌کنیم. ورودی این تابع تصویر ما و خروجی آن کانال‌های رنگی تصویر است که متناسب با فضای رنگی تصویر می‌توانند متفاوت باشند. در مثال زیر ما کانال‌های یک تصویر رنگی BGR را جدا سازی می‌کنیم. هر کدام از این کانال‌ها خود یک تصویر جداگانه می‌باشند.


یک اشتباه رایج: با جداسازی کانال‌های یک تصویر یک تصور رایج آن است که ما انتظار داریم که برای مثال کانال رنگی r قرمز رنگ باشد یا کانال b آبی رنگ باشد اما هر کانال رنگی یک آرایه دوبعدی است و از این رو یک تصویر خاکستری می‌باشد. پس با این حساب این تصویر سیاه و سفید چه درکی به ما می‌دهد. بیا باید کانال رنگی قرمز را در نظر بگیریم. این کانال یک نسخه سیاه و سفید از تصویر اصلی ما است. اما با این خاصیت که میزان روشنایی هر پیکسل نشان دهنده میزان رنگ قرمز آن پیکسل است. برای مثال اگر در ای تصویر خاکستری یک پیکسل سفید رنگ باشد یا به عبارت دیگر مقدار آن برابر ۲۵۵ باشد، نشان دهنده آن است که رنگ قرمز این پیکسل کامل است یا اگر مقدار آن برابر ۰ یا سیاه رنگ باشد نشان دهنده آن است که پیکسل فوق دارای هیچ رنگ قرمزی نیست. برای درک بهتر بیايد و مثال زیر را در نظر بگیرید



ما می‌خواهیم کانال‌های رنگی تصویر فوق را از یک دیگر جدا کرده و به صورت جداگانه نمایش دهیم. کد پروژه به صورت زیر می‌باشد

```
import cv2
img=cv2.imread ("sp.png")
b,g,r = cv2.split(img)

cv2.imshow('blue channel', b )
cv2.imshow('red channel', r )
cv2.imshow('green channel', g )
cv2.waitKey(0)
```



ببایید چند نوار رنگی را بررسی کنیم. نوار اول یک نوار قرمز رنگ است. همانطور که مشاهده می‌کنید این نوار در کانال های سبز و آبی به صورت تیره در آمده اما در کانال قرمز نسبتاً روشن بوده و به سفید میل می‌کند. و این نشان دهنده آن است که مقدار رنگ سبز و آبی نوار اول بسیار کم و مقدار رنگ قرمز آن زیاد است و ترکیب این سه همان رنگ قرمز خروجی را می‌سازند. نوار سوم و چهارم که به ترتیب سبز و آبی هستند در کانال های رنگی خود روشن و در دو کانال دیگر تیره می‌باشند. حال ببایید و نوار مشکلی رنگ را بررسی کنیم. رنگ مشکلی در حقیقت از نبود رنگ های اصلی به دست می‌آید از این رو این نوار در هر سه کانال سبز، قرمز و آبی کاملاً سیاه رنگ هستند و این نشان دهنده آن است که این نوار هیچگونه رنگ آبی، قرمز و سبزی ندارد. در مقابل رنگ سفید از ترکیب کامل سه رنگ اصلی بدست می‌آیند. بنابراین مقدار این نوار در هر سه کانال رنگی کامل سفید هستند. حال به سراغ رنگ های ترکیبی می‌رویم. نوار بنفش رنگ را در نظر بگیرید. رنگ بنفش از ترکیب رو رنگ اصلی آبی و قرمز به دست می‌آید. مطابق انتظار در تصاویر بالا مقدار این نوار در کانال های آبی و قرمز نسبتاً روشن و در کانال سبز تیره رنگ هستند و از سوی دیگر چون کانال آبی این نوار روشن تر از کانال قرمز است نشان دهنده آن است که مقدار رنگ آبی این نوار بنفش بیشتر از قرمز آن است. و در آخر نوار زرد رنگ، رنگ زرد از ترکیب دو رنگ سبز و قرمز تشکیل شده است. بنابراین مطابق انتظار در تصاویر بالا این نوار در کانال های قرمز و سبز روشن و در کانال آبی تیره رنگ است.

برای جداسازی کانال های رنگی می‌توانیم از عملگر : پایتون نیز به صورت زیر استفاده کنیم. در مثال زیر ما کلیه سطر و ستون های تصویر به ازای کانال ۰ که همان کانال آبی است را استخراج نمودیم.

```
>>> b = img[:, :, 0]
```

در مقابل ما می‌توانیم کانال های رنگی را به یک دیگر متصل نماییم و تصویر نهایی را ایجاد نماییم. اینکار با استفاده از تابع **merge** در **opencv** انجام می‌گیرد. ورودی این تابع یک چندتایی (**tuple**) از کانال های رنگی است و خروجی آن ترکیب کانال ها است. در مثال قبلی ما پس از جدا سازی کانال ها آن ها را مجدداً به یک دیگر متصل می‌نماییم . تصویر نهایی همان تصویر ورودی ما خواهد بود


```
import cv2
img=cv2.imread ("sp.png")
b,g,r = cv2.split(img)

res = cv2.merge((b,g,r ))
cv2.imshow('res', res)

cv2.waitKey(0)
```



توجه داشته باشید که ترتیب کانال های رنگی در ورودی تابع `merge` دارای اهمیت است. برای مثال اگر ما جای کانال قرمز و آبی را جابه جا کنیم تصویر ما به صورت زیر خواهد بود.



نتیجه تا حدی قابل پیشبینی بود. این طور نیست؟

تمرین : کانال های یک تصویر را جدا کرده و سپس مقدار درایه های کانال های سبز و آبی بر ۱۰ تقسیم کنید. و دوباره سه کانال را با هم ترکیب کنید. نتیجه چیست؟

توجه: به یاد داشته باشید که با تقسیم کانال بر ۱۰ نوع درایه های آن از `unsigned char` به نوع `float` تغییر پیدا می کند و لازم است تا مجدد با استفاده از تابع `astype()` نوع آن را به `np.uint8` باز گردانید.

ایجاد قاب برای تصاویر (اختیاری)

در `opencv` قابلیت ایجاد قاب در اطراف تصویر فراهم شده است. برای اینکار میتوان از تابع `copyMakeBorder()` استفاده کنید. این تابع کاربرد های بسیار دیگر در عملیات کانولوشن، صفر کردن و... دارد.

`copyMakeBorder( image , top , bottom , left , right , borderType [,value])`

- `image` : تصویر مورد نظر
- `Top,bottom,left,right` : حاشیه قاب از چهار طرف تصویر بر حسب پیکسل با این پارامتر ها مشخص می شود.
- `Border type` : نوع قاب را مشخص می کند که میتواند یکی از حالات زیر باشد
 - `BORDER_REFLECT` : این قاب به حالت آینه ای بوده و عناصر مرزی را بازتاب می کند
 - `(BORDER_REFLECT_DEFAULT) (BORDER_REFLECT_101)`: مانند حالت بالا بوده با کمی تفاوت
 - `BORDER_REPLICATE` : عناصر حاشیه به صورت سراسری تکرار می شوند
 - `BORDER_WRAP` : برای درک بهتر به مثال زیر توجه فرمایید
 - `BORDER_CONSTANT` : یک قاب با یک رنگ ثابت ایجاد می کند. رنگ این قاب در پارامتر `Value` مشخص می شود.

مثال

```

import cv2
import numpy as np


img=cv2.imread("image.jpg")


cons=cv2.copyMakeBorder(img , 20,20,20,20,cv2.BORDER_CONSTANT , value=(100,0,150))
Def=cv2.copyMakeBorder (img , 20,20,20,20, cv2.BORDER_DEFAULT )
iso=cv2.copyMakeBorder (img , 20,20,20,20, cv2.BORDER_ISOLATED,value=(255,0,0))
ref=cv2.copyMakeBorder (img , 20,20,20,20, cv2.BORDER_REFLECT)
ref101=cv2.copyMakeBorder (img , 20,20,20,20, cv2.BORDER_REFLECT_101 )
rep=cv2.copyMakeBorder (img , 20,20,20,20, cv2.BORDER_REPLICATE )
wrp=cv2.copyMakeBorder (img , 20,20,20,20, cv2.BORDER_WRAP )

cv2.imshow ("Orginal",img)
cv2.imshow ("Constant",cons)
cv2.imshow ("Default",Def)
cv2.imshow ("Isolated",iso)
cv2.imshow ("Reflect",ref)
cv2.imshow ("Reflect_101",ref101)
cv2.imshow ("Replicate",rep)
cv2.imshow ("Wrap",Wrap)

```

نتایج به صورت زیر می باشد:





تذکر : با اضافه شدن قاب به تصویر، اندازه تصویر به میزان حاشیه قاب افزایش می یابد

تکنیک های اندازه گیری و بهبود عملکرد

در پردازش تصویر به ویژه به صورت Real Time سرعت پردازش از اهمیت ویژه ای برخوردار است و بهینه سازی الگوریتم یک فرایند معمول در پردازش های سنگین تصویر است. برای بهینه سازی یک الگوریتم داشتن درک صحیحی از سرعت اجرا و حجم پردازشی آن یک عامل خوب برای مقایسه است تا با بررسی این مقادیر از بهینه تر شدن یا کندتر شدن سرعت اجرای الگوریتم خود اطمینان حاصل نماییم. برای این کار می توانیم از توابع زیر در **opencv** استفاده نماییم.

تابع **getTickCount()** تعداد کلاک ها را پس از یک کد نشان می دهد. بنابراین با فراخوانی این تابع قبل و بعد از یک کد، میتوان فهمید چند کلاک **cpu** برای اجرای آن کد، اختصاص یافته.

تابع **getTickFrequency** مقدار فرکانس را بر میگرداند.

```
e1 = cv2.getTickCount()
# your code execution
e2 = cv2.getTickCount()
time = (e2 - e1)/ cv2.getTickFrequency()
```

نکته: با ترکیب توابع بالا میتوان فهمید که برنامه برای اجرا چقدر زمان برده است


```
img1 = cv2.imread('messi5.jpg')

e1 = cv2.getTickCount()
for i in xrange(5,49,2):
    img1 = cv2.medianBlur(img1,i)
e2 = cv2.getTickCount()
t = (e2 - e1)/cv2.getTickFrequency()
print t
```

عملیات محاسباتی

همانطور که پیش از گفته شد هر تصویر یک آرایه است و مطابق هر آرایه دیگر می توان بر روی آن عملیات های حسابی مانند جمع و تفریق و یا عملیات های منطقی مانند **and** و **or** انجام داد. برای مثال فرض کنید ما می خواهیم یک لوگو بر روی یک تصویر قرار دهیم. به راحتی می توانیم تصویر لوگو را با تصویر مورد نظر جمع کنیم. البته لازم به ذکر است که ابعاد هر دو تصویر باید یکسان باشند. یا برای مثال فرض کنید فریم های متوالی یک دوربین را از یک دیگر تفریق کنیم در این صورت میتوان حرکت های انجام شده در دوربین را تشخیص دهیم. این دقیقاً همان کاری است که دوربین های مدار بسته با قابلیت **motion detection** انجام می دهند تا تنها هنگامی فیلم را ذخیره نمایند که در تصویر تحرکی رخ داده است تا در مصرف حافظه بهینه سازی شود. یا برای مثال فرض کنید می خواهید در یک تصویر رنگ قرمز را تشخیص دهید. از آنجا که بخش هایی از تصویر قرمز هستند که در کانال سبز و آبی مقدار کمی داشته و در کانال قرمز مقدار بالا دارند از این رو برای این کار کافی است تا کانال های آبی و سبز را از

کانال قرمز تفریق کنید و در تصویر حاصل پیکسل هایی را که دارای مقدار بالا مثلا بیشتر 100 هستند را به عنوان رنگ قرمز تشخیص دهید. یا فرض کنید یک تصویر مانند زیر و یک ماسک برای آن مطابق زیر داریم



با AND کردن دو تصویر بالا تنها بخش هایی از تصویر باقی می ماند که در ماسک مقدار سفید دارند و سایر بخش ها حذف شده و به رنگ مشکی در می آیند. بنابراین با توجه به مثال های بالا انجام عملیات های ریاضی بر روی یک تصویر می تواند کاربردی های زیادی در پردازش تصاویر داشته باشند.

عملیات جمع

برای جمع دو تصویر میتوان از تابع `add()` و یا عملگر جمع استفاده کرد. این دو راه در هنگام سر ریزی، نتایج متفاوتی دارند. در تابع `add` اگر نتیجه محاسبات بیشتر از ۲۵۵ باشند (سرریز رخ دهد) مقدار پیکسل برابر ۲۵۵ خواهد شد اما در استفاده از عمل جمع سرریز رخ می دهد. . برای مثال اگر حاصل جمع دو پیکسل برابر ۲۶۰ شود، مقدار حاصل برابر ۴ خواهد شد. (اعداد ذکر شده برای حالتی است که نوع یک تصویر `uint8` باشد)

مثال:

```
>>> print cv2.add(img1,img2) #250+10 = 260 => 255
[[255]]

>>> print x+y          # 250+10 = 260 % 256 = 4
[4]
```

همچنین برای جمع وزن دار دو تصویر از تابع `addWeighted()` استفاده میشود که ضربی از تصویر اول را با ضربی از تصویر دوم جمع میکند

```
img1 = cv2.imread('ml.png')
img2 = cv2.imread('opencv_logo.jpg')

dst = cv2.addWeighted(img1,0.7,img2,0.3,0)

cv2.imshow('dst',dst)
cv2.waitKey(0)
cv2.destroyAllWindows()
```



عملگر تفریق

برای تفریق دو تصویر از تابع `absdiff` استفاده می کنیم این تابع دو تصویر را به عنوان ورودی دریافت و قدر مطلق اختلاف آن ها را به عنوان خروجی باز میگرداند.

مثال :

در زیر ما یک برنامه برای نشان دادن حرکت در دوربین نمایش دادیم. در حلقه اصلی برنامه ابتدا یک فریم را از دوربین دریافت و سپس آن را به فضای رنگی سیاه و سفید می بریم. سپس اختلاف این فریم را از فریم قبلی حساب کرده و حاصل را در `diff` قرار می دهیم. سپس در یک حلقه پیکسل ها را بررسی می کنیم اگر مقدار اختلاف دو فریم متوالی در هر پیکسل بیشتر از ۵۰ باشد مقدار آن را برابر ۲۵۵ و در غیر این صورت برابر ۰ قرار می دهیم. این کار به این دلیل است که در فریم های متوالی همواره تغییراتی کمی در شدت نور هر پیکسل وجود دارد و ما با این کار از این تغییرات کم صرف نظر می کنیم. در نهایت پس از نمایش خروجی، مقدار فریم فعلی را در متغیر فریم قبلی کپی می کنیم و حلقه مجدد تکرار می شود. اجرای این برنامه به دلیل حلقه های `for` کمی زمان بر بوده و از این رو فریم ریت خروجی کم می باشد. پس از یادگیری توابع `threshold` می توانید به جای این حلقه های `for` تو در تو از این تابع استفاده کنید و سرعت اجرای برنامه خود را چند برابر کنید

```

import cv2
import numpy as np

cap = cv2.VideoCapture(0)
_, frame_prev = cap.read()
frame_prev = cv2.cvtColor(frame_prev, cv2.COLOR_BGR2GRAY )


while True :
    _, frame = cap.read()
    frame = cv2.cvtColor(frame, cv2.COLOR_BGR2GRAY )
    diff = cv2.absdiff( frame, frame_prev )
    h,w = frame.shape
    for i in range(h):
        for j in range(w):
            if diff[i,j] > 50 :
                diff[i,j] = 255


            else :
                diff[i,j] = 0

    cv2.imshow('motion', diff)
    cv2.imshow('frame', frame )
    cv2.waitKey(30)

    frame_prev= np.copy(frame)

```






عملگرهای منطقی

عملگرهای منطقی عملگرهایی هستند که به صورت بیتی بر روی پیکسل های یک تصویر اعمال می شوند و عبارتند از `and` , `or` , `not` و ...

معمولا از عملگرهای منطقی برای انجام عملیات بر روی ماسک ها استفاده می شوند. همانطور که پیش از این گفته شده ماسک ها تصاویر هستند که تنها دارای دو مقدار سیاه (۰) و سفید (۲۵۵) هستند. ماسک ها برای استخراج محتویات خاصی از تصویر کاربرد دارند. در بخش های بعدی ما با استفاده از عملیات هایی نظیر `threshold` و تشخیص لبه ماسک های مورد نظر خود را ایجاد می کنیم و در فرآیند هایی نظیر تشخیص کانتورها از این ماسک ها برای استخراج ویژگی های هندسی `object` مورد نظر استفاده می نماییم. پیش از این لازم است تا شما با انجام عملیات های منطقی آشنا باشید. برای نمونه در مثال قبل که یک برنامه برای تشخیص حرکت نوشتیم تصویر خروجی ما در حقیقت یک ماسک بود چرا که تنها از پیکسل های ۰ و ۲۵۵ تشکیل شده بود. برای نمونه با استفاده از عملیات منطقی `and` بر روی ماسک مثال قبل (`diff`) و تصویر ورودی (`frame`) می توانیم بخش هایی را که در آن حرکت رخ داده است را استخراج نماییم.



```
res = cv2.bitwise_and( frame, diff )
cv2.imshow('motion', diff)
cv2.imshow('frame', frame )
cv2.imshow('result', res )
```

توابع عملگر های منطقی به صورت زیر می باشند.

<code>bitwise_and(src۱ , src۲ [, dst [, mask]])</code>	<code>-> dst</code>	•
<code>bitwise_and(src۱ , src۲ [, dst [, mask]])</code>	<code>-> dst</code>	•
<code>bitwise_not(src۱ [, dst [, mask]])</code>	<code>-> dst</code>	•
<code>bitwise_xor(src۱ , src۲ [, dst [, mask]])</code>	<code>-> dst</code>	•

ورودی های این توابع عبارتند از:

- `src۱` : تصویری ورودی اول
- `src۲` : تصویر ورودی دوم
- `Dst` : تصویر خروجی

مثال :

```

import cv2
# Load two images
img1 = cv2.imread('messi.jpg')
img2 = cv2.imread('open_cv.png')
# I want to put logo on top-left corner, So I create a ROI
rows,cols,channels = img2.shape
roi = img1[0:rows, 0:cols ]
# Now create a mask of logo and create its inverse mask also
img2gray = cv2.cvtColor(img2,cv2.COLOR_BGR2GRAY)
ret, mask = cv2.threshold(img2gray, 10, 255, cv2.THRESH_BINARY)
mask_inv = cv2.bitwise_not(mask)

# Now black-out the area of logo in ROI
img1_bg = cv2.bitwise_and(roi,roi,mask = mask_inv)



# Take only region of logo from logo image.
img2_fg = cv2.bitwise_and(img2,img2,mask = mask)

# Put logo in ROI and modify the main image
dst = cv2.add(img1_bg,img2_fg)
img1[0:rows, 0:cols ] = dst

cv2.imshow('res',img1)
cv2.waitKey(0)
cv2.destroyAllWindows()

```

در مثال بالا میخواهیم یک لوگو را بر روی یک تصویر قرار دهیم. ابتدا تصویر اصلی و تصویر لوگوی خود را لود می‌کنیم. سپس یک برش از بخشی از تصویر که میخواهیم لوگو روی آن قرار گیرد می‌دهیم (roi). سپس تصویر لوگو را با تبدیل به فضای رنگی خاکستری و آستانه‌گذاری مناسب، به یک تصویر باینری تبدیل می‌کنیم (mask). در این تصویر لوگو سفید و بک‌گراند سیاه می‌باشد. سپس با اعمال یک عملگر not روی آن یک ماسک بر عکس ماسک قبلی ایجاد می‌کنیم (mask_inv). سپس mask را روی تصویر لوگو اعمال می‌کنیم تا بک‌گراند آن حذف و تنها لوگو باقی بماند (img1_fg). همچنین mask_inv را روی تصویر برش خورده اعمال می‌کنیم تا محل حذف (سیاه) شود. (img1_bg). سپس این دو تصویر را باهم جمع می‌کنیم (dst) و حاصل را روی تصویر اصلی قرار می‌دهیم. عملگرهای and در اینجا برای اعمال ماسک مورد استفاده قرار گرفته است.



تبدیل فضای رنگ تصاویر

فضاهای رنگی متفاوت دارای کاربردهای خاصی هستند. برای مثال فرض کنید می‌خواهید یک صورت را در تصویر شناسایی کنید. برای شناسایی یک صورت ما نیازی به تصویر رنگی نداریم چرا که هنگامی که شما به یک تصویر سیاه سفید از یک انسان نگاه کنید باز هم می‌توانید صورت فرد را شناسایی کنید یا مثلاً در فیلم آواتار شما برای شناسایی صورت‌ها قطعاً مشکلی نداشتید با اینکه رنگ صورت‌ها کاملاً آبی رنگ و متفاوت بود. بنابراین شما برای شناسایی یک صورت به فضای رنگی RGB یا HSV نیازی ندارید بنابراین با انجام پردازش بر روی تصویر خود در فضای رنگی خاکستری می‌توانید حجم پردازشی را تا حد زیادی بکاهید. یا حتی در مثال شناسایی حرکت که پیش از این داشتیم نیازی نبود تا ما بر روی تصاویر رنگی پردازش کنیم چرا که پردازش بر روی تصاویر خاکستری علاوه بر کافی بودن اطلاعات، پردازش ما را سبک تر و برنامه ما را آسان تر کرده است. یا برای مثال فرض کنید می‌خواهید در تصاویر هوایی که از یک پهپاد بدست می‌آید بخش‌های سرسبز را شناسایی کنید. احتمالاً فضای رنگی HSV انتخاب بهتری از RGB است چرا که با حذف کانال V می‌توانید تاثیر نور را بر روی رنگ در نظر نگیرید و برنامه شما بتواند در شرایط نوری متفاوت بهتر کار کند. مگر آنکه قصد داشته باشید برنامه‌ای بنویسید که تنها در روزهای افتابی کار کند. بنابراین تبدیل تصاویر به فضاهای رنگ متفاوت و مناسب برای پروژه شما برای شروع پردازش انتخاب مناسبی است.

برای تبدیل یک تصویر از یک فضای رنگی به یک فضای دیگر از تابع `cvtColor()` استفاده می‌کنیم. این تابع بصورت زیر است:

`cvtColor ( image , Code)`

- `image` : تصویر ورودی
- `Code` : پارامتری که فضای رنگی مبدا و مقصد را مشخص می‌کند که بیش از ۱۵۰ پرچم برای این پارامتر تعریف شده است. نظیر: `COLOR_BGR2HSV` `COLOR_BGR2GRAY` `COLOR_HSV2BGR` و...

در `hsv` محدوده رنگ یا `h` [۰,۱۷۹] محدوده اشباع رنگ یا `s` [۰,۲۵۵] و محدوده روشنی و تیرگی یا `v` [۰,۲۵۵] است

```
Cv2.cvtColor(img , cv2.COLOR_BGR2GRAY)
#convert from BGR to Gray
```

مثال: در

مثال زیر ما یک تصویر را از فضای رنگ BGR به Gray تبدیل می‌کنیم

نکته مهم: تابع `imshow` تصاویر را در فرمت BGR نمایش می‌دهد. بنابراین هنگامی که شما یک تصویر را به فضای رنگی دیگری مانند HSV می‌برید. در هنگام نمایش، رنگ‌های تصویر به هم ریخته خواهد بود. توجه داشته باشید که بهم ریختگی در رنگ تنها در نمایش تصویر در `opencv` است و تصویر شما در حقیقت همان رنگبندی اصلی را دارد اما در یک فضای رنگی دیگر

مثال : در مثال زیر ما قصد داریم تا یک شی سبز رنگ را در یک تصویر پیدا کنیم. در این مثال ما ابتدا تصویر را به فضای رنگ hsv می‌بریم تا نور تاثیر کمتری داشته باشد. سپس دو سطح رنگ سبز تعریف میکنیم. برای بدست آوردن مقادیر مناسب برای این رنگ ها میتوان از نرم افزار های طراحی نظیر فتوشاپ استفاده کرد. سپس از طریق تابع `inRange()` یک ماسک برای تصویر می‌سازیم. این تابع پیکسل هایی که بین سبز کمرنگ و پرنگ هستند را سفید و سایر پیکسل هارا سیاه می‌کند. سپس این ماسک را روی تصویر اعمال می‌کنیم.


- برای بدست آوردن مقادیر سبز در HSV علاوه بر استفاده از نرم افزار های مختلف، میتوان از خود تبدیل رنگ پایتون استفاده کرد و رنگ مورد نظر را از BGR به HSV تبدیل کرده و مقادیر آن را بدست آورد

```
import cv2
import numpy as np

cap = cv2.VideoCapture(0)
while(True):
    _, frame = cap.read()
    hsv = cv2.cvtColor(frame, cv2.COLOR_BGR2HSV)
    # define range of blue color in HSV
    lower_blue = np.array([80,50,50])
    upper_blue = np.array([100,255,255])
    # Threshold the HSV image to get only blue colors
    mask = cv2.inRange(hsv, lower_blue, upper_blue)
    # Bitwise-AND mask and original image
    res = cv2.bitwise_and(frame,frame, mask= mask)

    cv2.imshow('frame',frame)
    cv2.imshow('mask',mask)
    cv2.imshow('res',res)
    k = cv2.waitKey(5) & 0xFF
    if k == 27:
        break

cv2.destroyAllWindows()
```



تبدیل هندسی تصاویر

تبدیل هندسی در تصاویر به عملیاتی مانند چرخش، انتقال، زوم، تغییر پرسپکتیو و غیره گفته می‌شود. هر بار که در اینستاگرام می‌خواهید یک استوری بگذارید و تصویر خود را با چرخش و زوم به حالت ایده‌آل درمی‌آورید، در واقع یک تبدیل هندسی روی تصویر انجام می‌دهید.


همچنین احتمالاً با نرم‌افزارهای اسکنر گوشی‌های هوشمند آشنا هستید؛ هنگامی که از یک صفحه جزوه عکس می‌گیرید، این نرم‌افزارها علاوه بر اصلاح رنگ، پرسپکتیو تصویر را نیز به گونه‌ای تنظیم می‌کنند که تصویر بدون زاویه به نظر برسد، انگار کاملاً از رو به رو و به صورت تمام صفحه عکس‌برداری شده است..



در تبدیل هندسی هر پیکسل با مختصات (X,Y) به یک پیکسل با مختصات (u,v) تصویر می‌شود.

$$u = f_1(x, y)$$

$$v = f_2(x, y)$$



Affine Transform

نوعی انتقال هندسی است که در آن همبستگی تصویر حفظ می‌شود. برای مثال اگر پیکسل‌هایی از تصویر بر روی یک خط قرار داشته باشند، در تصویر خروجی نیز این پیکسل‌ها همچنان بر روی یک خط قرار خواهند داشت. این تبدیل هندسی، نسبت مسافت را نیز در تبدیل حفظ می‌نماید. برای مثال اگر یک پیکسل بر روی یک خط در $\frac{1}{4}$ آن قرار داشته باشد، پس از تبدیل باز هم در موقعیت $\frac{1}{4}$ آن خط قرار خواهد داشت. این تبدیل هندسی به طور کلی شامل عملیات‌های انتقال، چرخش، کوچک نمایی و بزرگ نمایی تصویر و برش یک عکس می‌شود. بنابراین در انجام این عملیات‌ها از این تبدیل هندسی استفاده می‌شود. این تابع تبدیل بر اساس یک ماتریس تبدیل با ابعاد 2×3 به صورت زیر کار می‌کند

$$\begin{bmatrix} x'_i \\ y'_i \end{bmatrix} = \text{map_matrix} \cdot \begin{bmatrix} x_i \\ y_i \\ 1 \end{bmatrix}$$

x_i, y_i مختصات‌های پیکسل ورودی می‌باشند که پس از ضرب در ماتریس تبدیل مختصات‌های جدید این پیکسل را پس از تبدیل بدست می‌آوریم. بیایید کمی موضوع را باز تر کنیم. فرض کنید ماتریس تبدیل ما به صورت زیر باشد.

$$\begin{bmatrix} c_{11} & c_{12} & c_{13} \\ c_{21} & c_{22} & c_{23} \end{bmatrix}$$

بر اساس رابطه بالا خواهیم داشت.

$$u = c_{11}x + c_{12}y + c_{13}$$

$$v = c_{21}x + c_{22}y + c_{23}$$

پارامترهای c_{13} و c_{23} پارامترهای انتقال هستند برای مثال فرض کنید ماتریس تبدیل ما به صورت زیر باشد

$$M = \begin{bmatrix} 1 & 0 & 10 \\ 0 & 1 & 20 \end{bmatrix}$$

آنگاه خواهیم داشت:

$$u = x + 10$$

$$v = y + 20$$

این یک ماتریس برای انتقال تصویر است. در این مختصات x به اندازه 10 و مختصات y هر پیکسل به اندازه 20 جابه جا می‌شوند.


این بار ماتریس تبدیل را به صورت زیر در نظر بگیرید

$$\begin{vmatrix} 1 & 0.2 & 0 \\ 1 & 0 & 0 \end{vmatrix}$$

بنابر این طبق تبدیل affine یک برش در محور x خواهیم داشت:

$$u = x + 0.2y$$

$$v = y$$




یا برای ماتریس تبدیل زیر چرخش خواهیم داشت

$$\begin{vmatrix} 1 & 0.2 & 0 \\ 0.3 & 1 & 0 \end{vmatrix}$$

$$u = x + 0.2y$$


$$v = -0.3x + y$$



برای ایجاد یک چرخش در تصویر به اندازه زاویه تتا بر اساس مثلثات روابط زیر بدست می‌آید

$$u = x \cos \theta + y \sin \theta$$

$$v = -x \sin \theta + y \cos \theta$$



بنابراین ماتریس انتقال بصورت مقابل خواهد

$$\begin{vmatrix} \cos \theta & \sin \theta & 0 \\ \sin \theta & \cos \theta & 0 \end{vmatrix}$$

بنابراین با تعیین صحیح ماتریس تبدیل می‌توان تبدیلات هندسی مختلف را پیاده سازی کرد. برای پیاده سازی تبدیل هندسی affine در opencv از تابع `wrapAffine()` استفاده می‌شود. در ادامه پیاده سازی چند نمونه تبدیل هندسی را در کتابخانه opencv آورده ایم. یک تبدیل هندسی خود می‌تواند شامل چند تبدیل هندسی باشد. برای مثال علاوه بر چرخش، انتقال نیز صورت بگیرد. نکته حائز اهمیت آن است که بر اساس ابعاد تصویر خروجی ممکن است برخی پیکسل‌های تصویر، در این دامنه قرار نگیرند و حذف شوند. از این رو انتخاب ابعاد مناسب برای تصویر خروجی می‌تواند حائز اهمیت باشد. برای محاسبه ابعاد تصویر خروجی می‌توانید مختصات نقاط چهار گوشه تصویر را با استفاده از تابع تبدیل محاسبه نمایید یا با تعیین عددس ابعاد تصویر خروجی و با آزمون و خطا به ابعاد مورد نظر خود برسید. شاید استفاده از آزمون و خطا روش مناسبی به نظر نرسد اما لازم به ذکر است که در بسیاری از بخش‌های پردازش تصویر، یکی از رایج‌ترین و مرسوم‌ترین روش‌های رسیدن به پارامترهای مطلوب، آزمون خطا می‌باشد.

انتقال

انتقال (Translation) یکی از ساده‌ترین تبدیلهای هندسی در تصاویر است که تصویر را در راستای محورهای x و y جابه‌جا می‌کند بدون اینکه شکل یا اندازه پیکسل‌ها تغییر کند. در عمل، برای هر پیکسل تصویر، موقعیت جدید آن با اضافه کردن مقادیر tx و ty به مختصات x و y تعیین می‌شود. برای اعمال انتقال در OpenCV، ابتدا ماتریس انتقال 3×2 ساخته می‌شود و سپس با تابع `warpAffine` روی تصویر اعمال می‌گردد.

`warpAffine( image , M , dsize)`

- `image` : تصویر ورودی
- `M` : ماتریس تبدیلی که می‌خواهیم روی تصویر اعمال کنیم این ماتریس یک ماتریس 2×3 است. برای انجام عمل جابه‌جایی باید ماتریس تبدیل را به صورت زیر تعریف کنیم که در آن tx و ty میزان جابه‌جایی برحسب پیکسل در جهت‌های x و y را نشان می‌دهند

$$M = \begin{bmatrix} 1 & 0 & t_x \\ 0 & 1 & t_y \end{bmatrix}$$


- `Dsize` : اندازه تصویر خروجی بر اساس عرض و ارتفاع می‌باشد که به صورت یک دوتایی به تابع داده می‌شود.

```
import cv2
import numpy as np

img=cv2.imread ("img.jpg")

rows,cols,_ = img.shape
M = np.float32([[1,0,100],[0,1,50]])
dst = cv2.warpAffine(img,M,(cols,rows))

cv2.imshow('img',dst)cv2.imshow ("original image",img)
```



چرخش

چرخش (Rotation) یکی از تبدیلات هندسی در تصاویر است که تصویر را حول یک نقطه مشخص می‌چرخاند. این چرخش می‌تواند در جهت عقربه‌های ساعت یا خلاف آن انجام شود و زاویه چرخش با درجه یا رادیان مشخص می‌گردد. هنگام چرخش، شکل و اندازه پیکسل‌ها حفظ می‌شوند، اما موقعیت آن‌ها تغییر می‌کند.

برای چرخاندن تصویر در OpenCV می‌توان از تابع `warpAffine()` استفاده کرد. برای این کار، ابتدا باید ماتریس تبدیل چرخش تعریف شود. این ماتریس می‌تواند به صورت دستی ساخته شود یا با استفاده از تابع آماده `getRotationMatrix2D()` در OpenCV ایجاد گردد.

`getRotationMatrix2D( center , angle , scale )`

- center : مرکز چرخش حول آن دوران میکند و مختصات آن به صورت یک دوتایی می‌دهیم
- Angle : زاویه دوران تصویر
- Scale : میزان بزرگ نمایی تصویر


مثال :

```
import cv2
import numpy as np

img=cv2.imread ("img.jpg")
cv2.imshow ("original image",img)
rows,cols,_ = img.shape

M=cv2.getRotationMatrix2D ( (rows/2 , cols/2) , 60 ,1)
rotImg=cv2.warpAffine ( img, M , (cols , rows))

cv2.imshow('Rotate img',rotImg)
```



محاسبه تابع تبدیل

در بسیاری از عملیات پردازش تصویر، ما ممکن است مستقیماً ماتریس تبدیل را نداشته باشیم، اما مختصات چند نقطه در تصویر مبدا و مختصات متناظر آن‌ها در تصویر مقصد را می‌دانیم. با استفاده از این نقاط، می‌توان روابط خطی یا آفاین بین موقعیت‌های مبدا و مقصد را برقرار کرد. سپس با حل این معادلات، ماتریس تبدیل بدست می‌آید و می‌توان آن را برای اعمال تبدیل روی تصویر استفاده کرد.

نرم‌افزارهای اسکنر گوشی‌های هوشمند هنگام عکس‌برداری از یک صفحه جزوه، سعی می‌کنند پرسپکتیو تصویر را اصلاح کنند. برای این کار، نرم‌افزار چهار گوشه صفحه را شناسایی می‌کند و می‌خواهد این چهار نقطه در تصویر نهایی به چهار گوشه یک مستطیل دقیق تبدیل شوند. با داشتن مختصات این چهار نقطه در تصویر اصلی و مختصات متناظر آن‌ها در تصویر مستطیل شده، نرم‌افزار می‌تواند ماتریس تبدیل هوموگرافی را محاسبه کرده و تصویر را اصلاح کند.

ماتریس تبدیل، از حل معادله زیر حاصل می‌شود

$$u = c_{11}x + c_{12}y + c_{13}$$

$$v = c_{21}x + c_{22}y + c_{23}$$

برای حل این معادله ما به سه نقطه از تصویر ورودی و مختصات تبدیل شده آن‌ها در تصویر خروجی نیاز داریم. در کتابخانه **opencv** تابع **getAffineTransform()** برای انجام این کار در نظر گرفته شده است. که بر اساس مختصات مبدا و مقصد نقاط مدنظر، ماتریس تبدیل را بدست می‌آورد. و سپس می‌توان با استفاده از تابع **warpAffine** از این ماتریس برای تبدیل هندسی تصویر بهره ببریم.

getAffineTransform(pts_۱ , pts_۲)

- **pts_۱**: آرایه‌ی سه مختصات مبدا نقاط انتخابی
- **pts_۲**: آرایه‌ی سه مختصات مقصد نقاط انتخابی

مثال :


```
import cv2
import numpy as np

img=cv2.imread ("img.jpg")
cv2.imshow ("original image",img)
rows,cols,_ = img.shape

pts1 = np.float32([[50,50],[200,50],[50,200]])
pts2 = np.float32([[10,200],[300,100],[100,250]])


M = cv2.getAffineTransform(pts1,pts2)
affine = cv2.warpAffine(img,M,(cols,rows))

cv2.imshow('Affine img',affine)
```



تبدیلات هندسی پیچیده تر

تبدیلات هندسی پیچیده‌تر را می‌توان با ترکیب چند تبدیل آفاین (Affine) به دست آورد. برای مثال، فرض کنید می‌خواهیم یک تصویر را ابتدا انتقال دهیم، سپس آن را به اندازه یک زاویه α چرخانده و در نهایت مقیاس (scale) تصویر را تغییر دهیم. برای انجام این کار، می‌توان این تبدیلات را به صورت دنباله‌ای روی تصویر اعمال کرد، به طوری که خروجی هر مرحله به عنوان ورودی مرحله بعدی استفاده شود.



اما در مقابل می‌توان بر اساس قواعد جبر خطی و ماتریس‌ها به این واقعیت دست یافت که با استفاده از ضرب ماتریس‌ها تبدیل در یک دیگر، می‌توان ماتریس تبدیلی تولید کرد که کلیه این تبدیلات را انجام دهد. اما از آنجا که ابعاد این ماتریس‌های تبدیل 2×3 می‌باشند، امکان ضرب این ماتریس‌ها در یک دیگر وجود ندارد. یک راهکار بسیار جالب تغییر شکل ماتریس تبدیل به یک ماتریس با ابعاد 3×3 می‌باشد. به گونه‌ای که معادلات تغییری نکند. این ماتریس تبدیل به صورت زیر خواهد بود

$$\begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} a & b & c \\ d & e & f \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix}$$

به سادگی با ضرب ماتریس‌های بالا، متوجه خواهید شد که معادلات همانند قبل خواهد با این تفاوت که ماتریس تبدیل ما اکنون یک ماتریس تبدیل 3×3 است.

$$U = ax + by + c \quad v = dx + ey + f \quad 1 = 0x + 0y + 1$$

با این تغییر اکنون قادر خواهیم بود تا ماتریس‌های تبدیل مختلف را در یک دیگر ضرب کرده و یک تبدیل هندسی پیچیده‌تر داشته باشیم

$$\text{ماتریس تبدیل انتقال} \times \text{ماتریس تبدیل چرخش} \times \text{ماتریس تغییر ابعاد} = \text{ماتریس تبدیل نهایی}$$

با تبدیل هندسی بر اساس ماتریس نهایی ما به خواسته خود در مثالی که در ابتدا گفتیم خواهیم رسید. اما با پردازش کمتر چرا که تنها با یکبار تبدیل هندسی به تصویر مطلوب خود دست پیدا می‌کنیم

بیایید بر اساس مطالب گفته شده، به یک ماتریس تبدیل جامع برای چرخش، بزرگ نمایی یا کوچک نمایی و انتقال دست پیدا کنیم. براساس آنچه پیش از این گفتیم ما سه ماتریس تبدیل برای عملیات های فوق به صورت زیر خواهیم داشت که به صورت ماتریس های 3×3 در آمده اند

$$\mathbf{T} = \begin{bmatrix} 1 & 0 & x_0 \\ 0 & 1 & y_0 \\ 0 & 0 & 1 \end{bmatrix} \quad \text{Translation by } (x_0, y_0)$$

$$\mathbf{T} = \begin{bmatrix} s_1 & 0 & 0 \\ 0 & s_2 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad \text{Scale by } s_1 \text{ and } s_2$$

$$\mathbf{T} = \begin{bmatrix} \cos \theta & \sin \theta & 0 \\ -\sin \theta & \cos \theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad \text{Rotate by } \theta$$

با ضرب سه ماتریس فوق و در نهایت استخراج ماتریس تبدیل 2×3 نهایی می توانیم به ماتریس تبدیلی دست پیدا کنیم که این سه تبدیل دنباله ای را در دل خود دارد. در شکل زیر مقدار این ماتریس تبدیل محاسبه شده است

$$H = RST = \begin{bmatrix} \cos \theta & \sin \theta & 0 \\ -\sin \theta & \cos \theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} s_0 & 0 & 0 \\ 0 & s_1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & x_0 \\ 0 & 1 & x_1 \\ 0 & 0 & 1 \end{bmatrix}$$

$$= \begin{bmatrix} s_0 \cos \theta & s_1 \sin \theta & s_0 x_0 \cos \theta + s_1 x_1 \sin \theta \\ -s_0 \sin \theta & s_1 \cos \theta & s_1 x_1 \cos \theta - s_0 x_0 \sin \theta \end{bmatrix}$$

بنابراین به راحتی می توانید با تبدیل ماتریس های تبدیل خود به فرم مربعی و ضرب آن ها در یک دیگر و در نهایت استخراج ماتریس تبدیل 2×3 تبدیلات پیچیده تر را پیاده سازی نمایید.

تبدیل پرسپکتیو

تبدیل پرسپکتیو (Perspective Transformation) به تغییر ظاهر تصویر اشاره دارد که شبیه تغییر زاویه یا موقعیت دوربین نسبت به صحنه است. به عنوان مثال، وقتی از یک صفحه جزوه از زاویه گرفته می شود، لبه های صفحه به صورت مایل دیده

می‌شوند. تبدیل پرسپکتیو می‌تواند تصویر را طوری اصلاح کند که این لبه‌ها مستقیم و مستطیلی به نظر برسند، گویی عکس از روبه‌رو و بدون زاویه گرفته شده است.

ماتریس تبدیل پرسپکتیو یک ماتریس 3×3 است که اجازه می‌دهد چرخش، انتقال و تغییر پرسپکتیو به صورت همزمان روی تصویر اعمال شود. برای اعمال این تبدیل در OpenCV از تابع `warpPerspective()` استفاده می‌کنیم. پارامترها و عملکرد این تابع شباهت زیادی به `warpAffine()` دارد، با این تفاوت که ماتریس ورودی آن 3×3 است و می‌تواند تغییرات پرسپکتیو را نیز اعمال کند.

برای محاسبه ماتریس تبدیل مناسب، از تابع `getPerspectiveTransform()` استفاده می‌شود. همانند `getAffineTransform()`، این تابع دو آرایه نقطه دریافت می‌کند:

- نقاط مبدا: مختصات چهار نقطه در تصویر اصلی
 - نقاط مقصد: مختصات متناظر این چهار نقطه در تصویر مقصد
- با داشتن این چهار نقطه، تابع می‌تواند ماتریس پرسپکتیو 3×3 را محاسبه کند و تصویر را مطابق پرسپکتیو جدید اصلاح نماید. این روش معمولاً در اصلاح تصاویر زاویه‌دار اسکن شده یا عکس‌های گرفته شده با دوربین از زاویه نامناسب استفاده می‌شود.

`warpPerspective( image , M , size)`

`getPerspectiveTransform( pts1, pts2)`

مثال :


```
import cv2
import numpy as np

img=cv2.imread ("img.jpg")
cv2.imshow ("orginal image",img)
rows,cols,_ = img.shape

pts1 = np.float32([[56,65],[368,52],[28,387],[389,390]])
pts2 = np.float32([[0,0],[300,0],[0,300],[300,300]])

M = cv2.getPerspectiveTransform(pts1,pts2)
prstc = cv2.warpPerspective(img,M,(300,300))

cv2.imshow('Perspective img',prstc)
```



تغییر مقیاس

Scale تصویر : یکی از تبدیلات هندسی که به آن اشاره شد بزرگ نمایی یا کوچک نمایی تصویر است. از آن جا که این تبدیل هندسی بسیار کاربردی است در کتابخانه **opencv** یک تابع جداگانه برای آن پیشبینی شده . تابع مذکور **resize()** می باشد.

Resize (img , dsize [, dst [, fx [, fy [, interpolation]]])

Img : تصویر ورودی

Dsize : ابعاد تصویر جدید بر اساس تعداد ستون و ردیف که به صورت یک دوتایی به تابع داده می شود.

Fx,fy : ضریب افزایشی-کاهشی طول تصویر جدید است که یک عدد اعشاری بوده و میتواند کوچکتر یا بزرگتر از ۱ باشد.

Interpolation : برای تغییر ابعاد تصویر، نیازمند درون یابی برای بدست آوردن مقدار پیکسل های جدید است . این پارمتر

مشخص کننده روش درون یابی است که یکی از مقادیر زیر می تواند باشد

۱- **INTER_LINEAR** : درون یابی برای مواقع زوم کردن یا کوچک کردن تصویر

۲- **INTER_CUBIC** : درون یابی برای زوم کردن

۳- **INTER_AREA** : دورن یابی برای کوچک کردن تصویر

از این تابع میتوان به دو صورت استفاده کرد. روش اول تعیین ابعاد خروجی به صورت مستقیم است. برای منظور ابعاد خروجی مطلوب را به عنوان پارامتر **Dsize** به توابع می دهیم. روش دیگر استفاده از ضرایب کاهشی **fx** و **fy** است که در این روش مقدار پارامتر **Dsize** را برابر **None** قرار داده و نسبت تبدیل مورد نظر برای محور **x** و **y** را به صورت جداگانه به پارامترهای **fx** و **fy** می دهیم. در مثال زیر هر دوی این روش ها نشان داده شده است.

`Cv2.resize(img, (۲*h, ۲/w)) = cv2.resize( img, None, fx=۲, fy = ۲ )`


مثال :

```
import cv2

img=cv2.imread ("img.jpg")

out1=cv2.resize(img ,None, fx=2, fy=0.5 , interpolation=cv2.INTER_CUBIC)
out2=cv2.resize(img ,(200,300), interpolation=cv2.INTER_CUBIC)

cv2.imshow ("out1 img" , out1)
cv2.imshow ("out2 img" , out2)
cv2.imshow ("original image",img)
```



اعمال threshold روی تصویر

ترشولد (Thresholding) یکی از پایه‌ای‌ترین و پرکاربردترین عملیات در پردازش تصویر است که معمولاً بر روی تصاویر خاکستری اعمال می‌شود. هدف اصلی آن، تبدیل تصویر خاکستری به تصویر باینری است، یعنی تصویری که هر پیکسل فقط دو مقدار ممکن دارد: روشن یا تاریک (معمولاً سفید یا مشکی).

مفهوم اصلی ترشولد به این صورت است که یک مقدار آستانه (threshold value) برای تصویر مشخص می‌کنیم. سپس بسته به نوع ترشولد:

- پیکسل‌هایی که مقدار روشنایی آن‌ها بیشتر از آستانه است، به یک مقدار ثابت (مثلاً سفید) تبدیل می‌شوند.
- پیکسل‌هایی که کمتر از آستانه هستند، به مقدار دیگر (مثلاً مشکی) تبدیل می‌شوند.

چرا ترشولد لازم است؟

ترشولد باعث ساده شدن تصویر و کاهش پیچیدگی آن می‌شود، به طوری که ویژگی‌های مهم تصویر (مانند اجسام یا اعداد) از پس‌زمینه متمایز می‌شوند. این مرحله برای بسیاری از پردازش‌های بعدی، مانند موارد زیر، ضروری است:

- تشخیص اجسام یا کانتورها (مفهوم کانتور را در آینده بررسی خواهیم کرد)

- شناسایی متن یا اعداد روی پلاک‌ها
- تفکیک اشیاء از پس‌زمینه

مثال کاربردی: فرض کنید می‌خواهیم اعداد روی یک پلاک خودرو را استخراج کنیم. در اینجا می‌توانیم با اعمال ترشولد مناسب: بخش‌های روشن پلاک (پس‌زمینه) را به رنگ مشکی بخش‌های تیره (اعداد) را به رنگ سفید در نتیجه، اعداد پلاک به صورت واضح از پس‌زمینه جدا می‌شوند و آماده انجام پردازش‌های بعدی مانند خواندن اعداد توسط الگوریتم‌های OCR می‌شوند.

در OpenCV، این عمل با تابع `threshold()` انجام می‌شود و پارامترهای آن شامل تصویر ورودی، مقدار آستانه، مقدار جایگزین برای پیکسل‌ها و نوع ترشولد است..

```
import cv2
import numpy as np

img = cv2.imread('pela.jpg',0 )
roi = img[ 220:350, 100:500]
_,thresh = cv2.threshold( roi, 100, 255, cv2.THRESH_BINARY_INV )

cv2.imshow('img', img )
cv2.imshow('thresh', thresh )
cv2.waitKey(0)
```




در ادامه به بررسی کامل تابع threshold می‌پردازیم.

Threshold (image , thresh , maxVal , type) ->retVal , dst

- Image : تصویر ورودی که عموماً در فضای رنگی Gray است.
- Thresh : مشخص کردن حد آستانه (مقدار است که پیکسل های بالاتر و پایین تر آن از هم جدا میشوند)
- maxVal : حداکثر مقدار عددی که میتوان به آن رسید. مثلاً در یک تصویر ۸ بیتی برای رسیدن به حداکثر مقدار مجاز، این مقدار ۲۵۵ خواهد بود.
- Type : این پارامتر مشخص میکند که threshold چه نوعی باشد که یکی از مقادیر زیر میتواند باشد
 - THRESH_BINARY : مقادیر بیشتر از حد آستانه برابر MaxVal و مقادیر کمتر صفر می‌شوند
 - THRESH_BINARY_INV : مقادیر بیشتر از حد آستانه برابر صفر و مقادیر کمتر برابر maxVal می‌شوند
 - THRESH_TRUNC : مقادیر بیشتر از حد آستانه برابر maxVal و مقادیر کمتر بدون تغییر باقی می‌مانند
 - THRESH_TOZERO : مقادیر کمتر از حد آستانه برابر صفر و مقادیر بیشتر بدون تغییر باقی می‌مانند
 - THRESH_TOZERO_INV : مقادیر بیشتر از حد آستانه برابر صفر و مقادیر کمتر بدون تغییر باقی می‌مانند

مثال :

```
ret,thresh1_img = cv2.threshold(img,127,255,cv2.THRESH_BINARY)
```



Adaptiv Threshold

در تابع `threshold` که تا کنون بررسی کردیم، ما یک حد آستانه عمومی برای کل تصویر در نظر می‌گیریم اما در مواردی، این حد آستانه عمومی، کارآمد نیست به‌خصوص در تصاویری که روشنایی در بخش‌های مختلف آن متفاوت است. در این تصاویر راهکار استفاده از حد آستانه محلی است، برای انجام این کار یک پنجره به صورت کشویی بر روی هر بخش تصویر قرار می‌دهیم. سپس مقدار آستانه برای هر پنجره برابر خواهد بود با میانگین مقدار پیکسل‌ها یا میانگین گاوسی آن‌ها به این صورت برای هر بخش از تصویر یک حد آستانه مناسب انتخاب می‌شود. در کتابخانه `opencv` تابع `adaptiveThreshold()` برای همین منظور ایجاد شده است.


`adaptiveThreshold( img , maxval , adaptiveMethod , thresholdType , blockSize , C)`

- `image` : تصویر ورودی
- `Maxval` : حداکثر مقداری که می‌توان به خروجی اختصاص داد
- `adaptiveMethod` : در این پارامتر مشخص می‌کنیم از چه متد و روشی برای ترشولد انطباقی، استفاده می‌کنیم.
برای اینکار دور روش زیر تعریف شده است.
 - `ADAPTIVE_THRESH_MEAN_C` : محاسبه حد آستانه یا روش میانگین
 - `ADAPTIVE_THRESH_GAUSSIAN_C` : محاسبه حد آستانه یا روش گاوسی
- `thresholdType` : نوع ترشولد را مشخص می‌کند که یکی از ۵ نوع `threshold` است که پیش از این به آن اشاره شده بود.
- `blockSize` : یک عدد صحیح بوده که مشخص می‌کند تا چه محدوده‌ای از پیکسل‌ها برای محاسبه حد آستانه استفاده گردد.
- `C` : یک مقدار ثابت که از میانگین و یا میانگین وزن دار محاسبه شده است.

مثال :

```
img=cv2.imread ("img.jpg",0)
th2=cv2.adaptiveThreshold(img,255,cv2.ADAPTIVE_THRESH_MEAN_C,cv2.THRESH_BINARY,11,10)
cv2.imshow('Perspective ',th2)
```

همانطور که در مثال زیر مشاهده می‌کنید تابع ترشولد عادی خروجی که تصویر جدول بالا سمت راست است خروجی مطلوبی نداشته اما در مقابل تابع `adaptiveThreshold` به خوبی تصویر را باینری کرده



بدست آوردن حد آستانه با OTSU

هنگام اعمال ترشولد (Threshold) روی یک تصویر با یک حد آستانه ثابت، معمولاً نیاز است تا یک مقدار مناسب برای کل تصویر پیدا کنیم. روش رایج این است که با آزمون و خطا، مقدار آستانه‌ای انتخاب شود که بهترین نتیجه را بدهد.

روش دیگری که دقیق‌تر است، استفاده از هیستوگرام تصویر است (هیستوگرام در فصل‌های بعدی آموزش داده می‌شود). در این روش، ابتدا هیستوگرام تصویر محاسبه می‌شود و سپس مقدار آستانه بین دو قله هیستوگرام انتخاب می‌شود تا پس‌زمینه و اجسام مورد نظر به خوبی از هم جدا شوند.

در OpenCV، برای انجام این کار از همان تابع `threshold` استفاده می‌کنیم، با این تفاوت که در پارامتر `type` علاوه بر نوع ترشولد، پرچم `THRESH_OTSU` را نیز به تابع می‌دهیم. در این حالت، تابع به صورت خودکار حد آستانه مناسب را برای تصویر محاسبه می‌کند.

تابع `threshold` دو خروجی دارد:


- تصویر ترشولد شده
- `retVal` که مقدار آستانه واقعی است

وقتی حد آستانه را خودمان مشخص می‌کنیم، `retVal` همان مقداری است که به تابع داده‌ایم. وقتی از پرچم `OTSU` استفاده می‌کنیم، `retVal` همان حد آستانه محاسبه شده توسط تابع است و مقدار ورودی آستانه را می‌توان به راحتی صفر قرار داد.

این روش باعث می‌شود نیاز به انتخاب دستی آستانه کاهش یابد و نتیجه دقیق‌تر شود، به خصوص در تصاویری که نور و روشنایی یکنواخت نیست.

مثال :

```
>>> img=cv2.imread ("img.jpg",0)
>>> ret2,th2 = cv2.threshold(img,0,255,cv2.THRESH_BINARY+cv2.THRESH_OTSU)
>>> ret2
112.0
>>> cv2.imshow('Perspective ',th2)
```



تمرین : با استفاده از ترشولد و تبدیل هندسی یک برنامه اسکریپت برای اسکن سیاه و سفید بنویسید.

راهنمایی : در ابتدا باید یک ترشولد مناسب بر روی تصویر اعمال کنید تا رنگ بندی تصویر اصلاح شود. سپس با انتخاب مختصات چهار گوشه برگه به عنوان نقاط ورودی و دادن مختصات های پیشفرض براساس نسبت ابعاد برگه، ماتریس تبدیل را بدست آورید و بر روی تصویر اعمال کنید.




اعمال فیلتر بر روی تصویر


فیلتر چیس

اعمال فیلتر بر روی تصاویری که از پایه ای ترین و مهم ترین عملیات های پردازش تصویر است و در مواردی نظیر یافته لبه ها، حذف نویز، تار کردن تصویر و... کاربرد دارد. هر فیلتر از یک هسته تشکیل شده است که این

هسته آرایه ای از اعداد است که این اعداد وزن نام دارند. همچنین هر هسته دارای یک نقطه لنگرگاه است که عموماً این نقطه، دارای مرکزی در یک هسته می‌باشد. برای مثال در یک هسته با ابعاد 3×3 نقطه لنگرگاه به صورت پیشفرض درایه $(2,2)$ می‌باشد. برای اعمال یک فیلتر بر روی یک تصویر کافی است که فیلتر را بر روی تصویر به صورت کشویی حرکت دهیم و در لحظه مقدار هر پیکسل تصویر در مقدار وزن نظیرش در هسته ضرب می‌شود. سپس مجموع این حاصل ضرب ها را حساب می‌کنیم و این حاصل به جای مقدار پیکسلی که لنگرگاه هسته روی آن قرار دارد، قرار می‌گیرد. برای درک بهتر به تصویر زیر نگاه نمایید.



این عملیات کانولوشن نیز نام دارد. همان گونه که از تصویر فوق مشخص است، ابعاد تصویر خروجی، از تصویر ورودی کوچک تر است. **Opencv** برای جلوگیری از این اتفاق، بصورت پیشفرض در حاشیه تصویر ورودی از پیکسل‌هایی با مقدار ایجاد می‌کند. به گونه‌ای که ابعاد تصویر ورودی و خروجی برابر باشند. این عملیات **padding** نام دارد



فیلتر BLURING

فیلتر **Blur** یک فیلتر پایین گذر (LPF) بوده برای نرم کردن تغییرات یک تصویر استفاده میشود. این فیلتر توسط تابع **blur()** اعمال میشود. این فیلتر با یکدست کردن تصویر، نویز های تصویر را حذف می‌کند. برای درک بهتر تصویر زیر را در نظر بگیرید.

تصویری بالایی، تصویر اصلی ما می‌باشد که دارای نویز بوده. در حقیقت در این تصویر پیکسل‌ها یک‌دست نیستند و دارای تغییرات زیادی می‌باشند یا به اصطلاح این تصویر دارای فرکانس بالایی است. زیرا با حرکت از یک نقطه به نقطه دیگر در آن، تغییرات شدت روشنایی در هر گام زیاد می‌باشد. اما با اعمال یک فیلتر پایین‌گذر مانند blur می‌توانید تاثیر آن را مشاهده نمایید که یک تصویر یک‌دست‌تر و ملایم‌تر برای ما فراهم می‌سازد. از این رو به این فیلتر یک فیلتر پایین‌گذر می‌گویند. زیرا تغییرات فرکانس بالا را حذف و یک تصویر فرکانس پایین به ما ارائه می‌دهد و این تصویر را برای انجام سایر عملیات‌های پردازشی که در این کتاب به آن می‌پردازیم مناسب می‌سازد. یکی از کاربردهای مهم این عملگر پیش‌پردازش تصویر برای تشخیص لبه است.



Blur(image , kernel size)

مثال: هسته این فیلتر به صورت زیر است:

$$K = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$


همانگونه که از هسته این فیلتر پیدا است، در این فیلتر مقدار هر پیکسل که مرکز هسته روی آن قرار دارد با میانگین n پیکسل اطراف خود جایگزین می‌شود که مقدار n به اندازه هسته بستگی دارد از این رو مقدار هر پیکسل‌ها به یک مقدار میانگین نزدیک می‌شوند و تصویر تقریباً یک‌دست می‌شود.

مثال:

```
import cv2
import numpy as np

img = cv2.imread('opencv_logo.png')

blur = cv2.blur(img,(5,5))
```



فیلتر Gaussian

فیلتر گاوسی مانند فیلتر blur یک فیلتر پایین گذر (LPF) بوده و از نظر بصری تصویر را تار می‌کند اما با این تفاوت که بر عکس فیلتر blur که وزن کلیه پیکسل‌های همسایه یکسان بود و با یک ضریب یکسان میانگین‌گیری میشد، در این فیلتر ضرایب بر اساس فاصله از مرکز و با عملگر گاوسی محاسبه میشوند. از این رو پیکسل‌های نزدیک‌تر به پیکسل مرکزی، وزن و تأثیری بیشتری در میانگین‌گیری دارند. تابع این فیلتر (GaussianBlur) بوده که در آن باید علاوه بر معرفی ابعاد هسته، باید سیگما در جهت X و Y را برای محاسبه ضرایب معرفی کرد. اگر فقط سیگما X مقدار دهی شود، سیگما Y برابر با آن در نظر گرفته میشود. اگر هر دو صفر در نظر گرفته شوند، مقدارشان بر اساس ابعاد هسته، محاسبه میشود. این فیلتر برای رفع نویزهای گاوسی بسیار مناسب است.

GaussianBlur(image, kernel size , sigma x , sigmay)

مثال هسته یک فیلتر gaussain

$$\frac{1}{16}$$


1	2	1
2	4	2
1	2	1

مثال :

```
blur = cv2.GaussianBlur(img,(5,5),0)
```



Original image




Gaussian Blur filter applied

فیلتر median

این فیلتر نیز یک فیلتر پایین گذر (LPF) می‌باشد. در این فیلتر median مقدار هر پیکسل با مقدار میانه پیکسل‌های اطرافش که در همسایگی معینی قرار دارند، جایگزین می‌شود. برای مثال فرض کنید پیکسل‌های همسایه یک پیکسل مشخص دارای مقادیر ۱۳۰، ۴۰، ۵۰، ۲۰۰، ۱۰۰ باشند. در این صورت مقدار پیکسل مدنظر برابر مقدار میانه این مقادیر یعنی ۱۳۰ خواهد شد. این فیلتر برای رفع نویز‌هایی نظیر نویز فلک - نمکی بسیار مناسب می‌باشد (نویز‌هایی که پیکسل‌های سفید و سیاه پراکنده روی تصویر به وجود می‌آورند). فرض کنید چنین تصاویری را بخواهیم با یک فیلتر blur فیلتر نماییم در این صورت خروجی مطلوبی نخواهیم داشت چراکه پیکسل‌هایی سفید یا مشکی در میانگین‌گیری تاثیر می‌گذارند اما با اعمال فیلتر median ما

مقدار میانه پیکسل های همسایه را انتخاب خواهیم کرد که این مقدار قطعا پیکسل های سفید یا مشکی نخواهند بود بلکه یک مقدار پیکسل از همسایگی است که مقدارش در میانه قرار دارد. به این صورت پیکسل های سفید و مشکی تاثیری در مقدار جدید پیکسل ما نخواهند داشت. این موضوع برای تصویر رنگی نیز صادق است چرا که هر تصویر رنگی خود از سه کانال رنگی تشکیل شده است که هر کانال مانند یک تصویر سیاه و سفید است. در تصویر زیر مقدار نتیجه برای پیکسل مرکزی به ازای هر دو فیلتر را مشاهده می‌نمایید. مشخصا نتیجه فیلتر median بسیار مطلوب تر است.




تابع این فیلتر در `opencv`، `medianBlur` می‌باشد.

`medianBlur( image , kernel size)`

مثال:

```
median = cv2.medianBlur(img,5)
```



فیلتر Bilateral

این فیلتر مانند فیلتر گاوسی عمل می‌کند با این تفاوت که با اعمال این فیلتر لبه‌های تصویر حفظ خواهند شد. در فیلتر گاوسی هنگام میانگین گرفتن بین پیکسل‌های همسایه، توجه نمی‌شود که آیا این پیکسل‌های همسایه متعلق به همان محدوده بوده و همان شدت را دارند یا خیر. از این رو پیکسل‌های مرزی شدتشان کاهش یافته و لبه‌ها محو می‌شوند. اما در فیلتر دوطرفه فوق، هنگام میانگین‌گیری، همواره برآورد میشود که پیکسل‌های همسایه که در میانگین‌گیری گاوسی مورد استفاده قرار می‌گیرند، متعلق به همان ناحیه باشند که پیکسل مرکزی در آن قرار دارد در غیر این صورت در میانگین‌گیری محاسبه نخواهند شد. از این رو با حفظ شدن لبه‌ها، فیلتر گاوسی روی تصویر اعمال می‌شود. تابع پیاده‌سازی این فیلتر `bilateralFilter()` می‌باشد


`bilateralFilter( img , d , sigma Color , sigma Space)`

img : تصویر ورودی

- D : این پارامتر قطر محدوده هر پیکسل که در هنگام فیلترینگ استفاده می‌شود را برحسب پیکسل مشخص می‌کند.
- Sigma Color : انحراف معیار در فضای رنگی
- Sigma Space : انحراف معیار در فضا (فاصله)

مثال :

```
blur = cv2.bilateralFilter(img,9,75,75)
```



همانگونه که در شکل مشخص است، با وجود تار شدن تصویر، لبه‌ها کاملاً حفظ شده‌اند

فیلتر با هسته دلخواه

در بعضی مواقع نیاز است تا ما یک فیلتر با یک هسته دلخواه روی تصویر اعمال کنیم. برای استفاده از این فیلتر ابتدا لازم است یک هسته تعریف نماییم. برای اینکار ابتدا ماژول `numpy` را به برنامه `import` میکنیم. سپس به کمک تابع `ones()` به صورت زیر یک هسته تعریف مینماییم. که یک هسته با درایه های ۱ میسازد. تابع `zeros` نیز یک هسته با درایه های صفر میسازد.

`Ones( ( rows number , column number) , kernel type)`

یا تولید یک با تابع زیر

`array( array values , kernel type)`

سپس با استفاده از تابع `filter2D()` این هسته را روی تصویر اعمال میکنیم.

`Filter2D( image , out type , kernel)`

نکته: در این فیلتر مقدار هر پیکسل با مقدار مجموع مقدار پیکسل های همسایه ضرب در وزنشان

نکته : این هسته در واقع از نوع ارایه کتابخانه `numpy` بوده و میتوان آن را مانند یک لیست مقدار دهی کرد

مثال: در برنامه زیر ما هسته زیر را تولید و روی تصویر اعمال میکنیم


$$K = \frac{1}{25} \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix}$$

```
import cv2
import numpy as np
from matplotlib import pyplot as plt

img = cv2.imread('opencv_logo.png')


kernel = np.ones((5,5),np.float32)/25
kernel2= np.array( [[0,1,0] , [1,-4,1] , [0,1,0]] , np.int8)

dst = cv2.filter2D(img,-1,kernel)
kernel[3,3]=2
```



تشخیص لبه

لبه‌های تصویر خطوطی در تصویر هستند که نواحی مختلف تصویر را از یکدیگر جدا می‌کنند. تشخیص لبه می‌تواند درک مناسب از اشکال موجود در تصویر برای ما ایجاد نماید. در گام‌های بعدی ما شناسایی کانتورها بر روی لبه‌های یک تصویر می‌توانیم. خصوصیات هندسی هر شی در تصویر نظیر مساحت، زاویه، فرم و... را استخراج نماییم الگوریتم‌های تشخیص لبه بر اساس تضاد رنگ نواحی مختلف در تصویر کار می‌کنند از این رو برای آنکه در تشخیص لبه نویزها و لبه‌های ناخواسته نداشته باشیم، اعمال یک فیلتر پایین گذر مانند blur پیش از تشخیص لبه می‌تواند گزینه مناسبی باشد.



فیلتر Laplacian

این فیلتر بر خلاف فیلتر های قبلی، یک فیلتر بالا گذر (HPF) بوده و از آن برای تشخیص لبه های یک تصویر میتوان استفاده نمود.. همچنین کنتراست یک تصویر را میتوان با تفریق لاپلاس یک تصویر از خودش، بالا برد . تابع این فیلتر `Laplacian()` میباشد

`Laplacian( img , out type , out image_dst , kernel size)`

مثال: هسته یک فیلتر لاپلاسین به صورت زیر میباشد:


$$\text{kernel} = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

با توجه به هسته فوق، مشخص است در این فیلتر مقدار هر پیکسل از اختلاف چهار برابر هر پیکسل از چهار همسایه اطراف خود بدست می آید که در لبه ها مقداری غیر صفر و در سایر بخش ها تقریبا صفر میباشد.

نکته : این فیلتر عموما برای تصاویری خاکستری کاربرد دارد

مثال:

```
img = cv2.imread('dave.jpg',0)
laplacian = cv2.Laplacian(img,cv2.CV_8U)
```



عملگر Sobel

عملگر سوبل (Sobel Operator) یک فیلتر بالاگذر (High-pass Filter) است که برای تشخیص لبه‌ها در تصاویر استفاده می‌شود. این عملگر نسبت به عملگر لاپلاس (Laplacian) دقت بیشتری در تشخیص لبه‌ها دارد و حساسیت آن به نویز کمتر است.

سوبل دارای دو هسته (Kernel) مجزا است:

- یکی برای تشخیص لبه‌ها در جهت x
- دیگری برای تشخیص لبه‌ها در جهت y

با استفاده از تابع `add()` می‌توان نتایج این دو هسته را با هم ترکیب کرد تا لبه‌های کامل تصویر به دست آید.

به طور کلی، عملگر سوبل برای استخراج جزئیات و مرزهای اشیاء در تصویر بسیار مفید است و نسبت به لاپلاس حساسیت کمتری به نویز دارد و بنابراین اغلب در کاربردهای واقعی ترجیح داده می‌شود.

`Sobel(image, out type, x_bool, y_bool, kernel size)`

مثال: هسته یک عملگر سوبل به صورت زیر است:

-1	0	+1
-2	0	+2
-1	0	+1

G_x

+1	+2	+1
0	0	0
-1	-2	-1

G_y

همان طول که از هسته‌های این عملگر مشخص است، اگر این هسته بر روی یک ناحیه یک دست مثلاً پیشانی یک فرد در عکس قرار گیرد، مقدار حاصل عددی کوچک خواهد شد زیرا مقدار پیکسل‌ها تقریباً یکسان بوده و با ضرب آن‌ها در وزن‌های بالا که مجموعشان برابر صفر است، حاصل و جمعشان با یک دیگر عددی کوچکی خواهد بود اما اگر در لبه قرار بگیرد مقدار این فیلتر محالف صفر می‌شود

-1	0	+1
-2	0	+2
-1	0	+1

G_x

برای مثال در تصویر بالا که فیلتر بر روی یک لبه قرار گرفته است، مقدار حاصل بصورت زیر خواهد بود (رنگ خاکستری عکس برابر ۱۰۰ می‌باشد)


$$(-1 \times 255 - 2 \times 255 - 1 \times 255) + (1 \times 100 + 2 \times 100 + 1 \times 100) = -620$$

اما اگر این فیلتر بر روی یک محیط کاملاً سفید یا کاملاً خاکستری بود حاصل برابر ۰ می‌شد. یا حتی اگر تصویر یک دست نباشد مقدار عددی کوچکی خواهد شد

```
img = cv2.imread('dave.jpg',0)

sobelx = cv2.Sobel(img,cv2.CV_8U,1,0)
sobely = cv2.Sobel(img,cv2.CV_8U,0,1)
sobxy=cv2.add(sobelx , sobely)
```

مثال: در زیر تصویری از عملگر سوبل و مقایسه آن با لاپلاسیان را مشاهده می‌نمایید



فیلتر Scharr

نوعی فیلتر یا عملگر لبه یاب دیگری است که هرگاه نیازمند تخمین دقیق‌تر در جهت گرادیان باشد استفاده می‌شود. این عملگر مانند عملگر سوبل، لبه‌ها را در دو جهت X و Y بدست می‌آورد. که میتوان با تابع add() آنها را باهم جمع نمود. تابع این عملگر Scharr() می‌باشد.

Scharr(img , output type , dx , dy)

هسته‌های این فیلتر به صورت زیر می‌باشند


$$\begin{bmatrix} +3 & 0 & -3 \\ +10 & 0 & -10 \\ +3 & 0 & -3 \end{bmatrix} \quad \begin{bmatrix} +3 & +10 & +3 \\ 0 & 0 & 0 \\ -3 & -10 & -3 \end{bmatrix}$$

Scharr-x **Scharr-y**

مثال :

```
img = cv2.imread('dave.jpg',0)

scharrx = cv2.Scharr(img,cv2.CV_8U,1,0)
scharry = cv2.Scharr(img,cv2.CV_8U,0,1)
scharrxy=cv2.add(scharrx , scharry)
```



تذکر مهم : هنگام استفاده از عملگرهای Sobel و Scharr، ما در واقع تغییرات شدت روشنایی پیکسل‌ها را محاسبه می‌کنیم. این تغییرات می‌توانند مثبت یا منفی باشند:

- مثبت: تغییر روشنایی از تیره به روشن (سیاه به سفید)
- منفی: تغییر روشنایی از روشن به تیره (سفید به سیاه)

اگر تصویر خروجی را با نوع داده CV_8U ذخیره کنیم، مقادیر منفی به صفر تبدیل می‌شوند. نتیجه این است که لبه‌هایی که در جهت منفی قرار دارند، از تصویر حذف می‌شوند و بخشی از جزئیات تصویر از دست می‌رود.

راهکار استاندارد برای حفظ تمام لبه‌ها این است که ابتدا از نوع داده‌ای با قابلیت ذخیره مقادیر منفی مانند CV_16S یا CV_64F استفاده کنیم. سپس با اعمال عملگر قدر مطلق (absolute)، تمام مقادیر منفی و مثبت به مقادیر مثبت تبدیل می‌شوند و در نهایت می‌توان تصویر را به CV_8U برگرداند تا قابل نمایش و پردازش باشد.

به عبارت ساده‌تر، این روش باعث می‌شود هیچ لبه‌ای از تصویر به دلیل منفی بودن از بین نرود و تصویر خروجی کامل‌تر و دقیق‌تر باشد.

مثال:


```
import cv2
import numpy as np

img = cv2.imread('image.jpg',0)

img=cv2.bilateralFilter(img , 10,50,50)
sobelx8u = cv2.Sobel(img,cv2.CV_8U,1,0,ksize=5)

#Output dtype = cv2.CV_64F. Then take its absolute and convert to cv2.CV_8U
sobelx16s = cv2.Sobel(img,cv2.CV_16S,1 ,0,ksize=5)
abs_sobel16s = np.absolute(sobelx16s)

sobel_8u = np.uint8(abs_sobel16s)
#improve image
_,sobel_8u=cv2.threshold (sobel_8u,120,255,cv2.THRESH_BINARY )
cv2.imshow ("out" , sobel_8u)
```



همانگونه که مشخص است در تصویری که نوع خروجی CV-8U انتخاب شده، با حرکت از چپ به راست، لبه اول که از سیاه به سفید است، تشخیص داده شده اما لبه دوم که از سفید به سیاه است، به خاطر مقدار منفی، حذف شده است.

البته در موارد تبدیل تصویر به CV_8U باعث خراب شدن تصویر لبه‌ها می‌شود و بهتر است ابتدا یک ترشولد روی تصویر نوع CV_16S اعمال کرد. و سپس آن را به نوع ۸ بیتی تبدیل کرد. یا حتی میتوان از همان تصویر با نوع CV_16S استفاده کرد برای درک بهتر به مثال زیر توجه فرمایید.

```
import cv2
import numpy as np

img = cv2.imread('min.jpg',0)

sobelx16s = cv2.Sobel(img,cv2.CV_16S,1,0,ksize=5)


abs_sobelx16s = np.absolute(sobelx16s)
abs_sobelx6u=np.int16 (abs_sobelx16s)
_,abs_sobelxth=cv2.threshold (abs_sobelx6u,800,65535,cv2.THRESH_BINARY )

sobel1_8u = np.uint8(sobelx16s)
sobel2_8u = np.uint8(abs_sobelxth)

cv2.imshow (" out1 img" , sobel1_8u )
cv2.imshow (" out2 img" , sobel2_8u )
cv2.imshow ("soble 16S", sobelx16s)
cv2.imshow ("soble th", abs_sobelxth)
```

مثال :

همانطور که مشخص است در تصاویر زیر خروجی اول که مستقیم با تبدیل ۱۶S به ۸U ساخته شده مناسب نیست. اما تصویر که از تبدیل تصویر ترشولد یافته ۱۶S به ۸U به وجود آمده قابل قبول است. همچنین خود تصویر ۱۶S نیز برای تشخیص لبه‌ها مناسب است



عملگر Canny

این عملگر برای تشخیص لبه‌ها مورد استفاده قرار می‌گیرد و محبوبیت بالایی دارد. این عملگر در مراحل زیر

- 1- حذف نویز با اعمال یک فیلتر گاوسی با یک هسته 5×5
- 2- یافتن لبه‌های تصویر فیلتر شده در دو جهت X و Y با عملگر سوبل
- 3- حذف پیکسل‌هایی که احتمالاً جزو لبه‌ها نیستند.
- 4- اعمال آستانه‌های بالا و پایین: این بخش به این صورت است که دو آستانه بالا و پایین روی تصویر لبه‌ها اعمال می‌شود. بخش‌هایی که زیر آستانه پایین قرار دارند مطمئناً جزو لبه‌ها نیستند و بخش‌هایی که بالاتر از آستانه بالا قرار دارند مطمئناً جزو لبه‌ها هستند. اما بخش‌هایی که بین سطح آستانه بالا و پایین قرار دارند بر اساس ارتباطشان با سایر لبه‌های قطعی یا جزو لبه‌ها انتخاب می‌شوند یا حذف می‌شوند.

این عملگر توسط تابع `Canny()` اعمال می‌شود.

`Canny( img , min threshold , max threshold)`

`Img` : تصویر ورودی

`Min thrshold` : سطح آستانه پایین

`Max threshold` : سطح آستانه بالا

```
import cv2
import numpy as np
img=cv2.imread("imag.jpg",0)
blurImg=cv2.blur (img , (3,3))
imgCanny=cv2.Canny(blurImg,100,150)
cv2.imshow("canny image", imgCanny)
cv2.imshow(" image", img)
```




ریخت شناسی یا Morphology

تصاویر باینری

تصاویری هستند که از تنها از پیکسل های سیاه و سفید تشکیل شده اند. این تصاویر اطلاعاتی خوبی از شکل **object** مورد نظر نمایش می دهند. این تصاویر معمولاً با توابع **threshold** و تشخیص لبه بدست می آیند. این تصاویر همچنین به عنوان ماسک کاربرد زیادی دارند. برای مثال اگر ما بخواهیم پردازش خود را به بخش خاصی از یک تصویر محدود نماییم میتوانیم یک ماسک را به گونه ای ایجاد کنیم که مقدار آن ناحیه مورد نظر ما سفید و سایر نواحی سیاه باشند. گاهی برای رسیدن به تصاویر باینری، تصویر ممکن است دچار نویز شود یا بخشی از اطلاعات از بین روند. در این مواقع ما به کمک ریخت شناسی تصویر را اصلاح مینماییم و تصاویر مطلوب خود را بدست می آوریم.



برای مثال در تصویر زیر هدف ما استخراج ماسک یک سکه موجود در تصویر است اما تصویر باینتری ما دارای نویز بسیار زیادی است (نقاط سفید منفرد موجود در عکس سمت چپ) . ما می‌توانیم با استفاده از عملیات ریخت شناسی این تصویر را اصلاح و به تصویر بدون نویز سمت راست دست یابیم



ریخت شناسی

ریخت شناسی مجموعه‌ای از الگوریتم‌هاست که برای اصلاح و بهبود تصویر که عموماً برای تصاویر باینری مورد استفاده قرار می‌گیرد. ریخت شناسی برپایه دو عمل Erosion (فرسایش) و Dilation (انحطاط) است و تعمیم این دو عمل، سایر الگوریتم‌ها و عملیات‌های ریخت‌شناسی نظیر opening , closing و... را تولید می‌کنند. ریخت شناسی شامل دو پارامتر زیر است:

۱- **تصویر:** یک تصویر باینری که عملیات ریخت‌شناسی روی آن اعمال می‌شود

۲- **هسته:** یک هسته در ریخت شناسی یک آرایه دو بعدی است که از درایه‌های صفر و یک تشکیل شده است و یک نقطه لنگر دارد. نقطه لنگر درایه‌ای از این ماتریس است که پیکسلی که تحت پوشش آن قرار می‌گیرد را تحت تاثیر قرار می‌دهد. درایه لنگر معمولاً در مرکز ماتریس قرار دارد

Figure 1 illustrates the layout of a 3x3 Box and a 5x5 Disc. The Box is a 3x3 grid with 1s in the center and 0s elsewhere. The Disc is a 5x5 grid with 1s in the center and 0s elsewhere. The Box is labeled 'Box' and the Disc is labeled 'Disc'. The Box is 3x3 and the Disc is 5x5. The Box is 3x3 and the Disc is 5x5. The Box is 3x3 and the Disc is 5x5.

عملیات های ریخت شناسی

Erosion

این الگوریتم موجب فرسایش تصویر پیش زمینه (هنگامی که پیش زمینه سفید و پس زمینه سیاه باشد) می شود. روش این الگوریتم به این صورت است که اگر تمام پیکسل هایی که تحت پوشش درایه های یک قرار دارند به رنگ سفید باشند، پیکسلی که تحت پوشش درایه لنگر است، سفید و در غیر این صورت سیاه می شود. از این رو با اعمال آن، پیکسل های مرکزی سفید می مانند و پیکسل های که در نزدیکی لبه ها قرار دارند سیاه می شوند. در نتیجه لبه های تصویر پس زمینه فرسایش یافته و پس زمینه کوچک تر می شود. این عملگر برای حذف نویز از تصویر بسیار کاربرد دارد و نقاط مفرد در تصویر را حذف می مند



تابع این عملگر `erdode()` می‌باشد و به صورت زیر است:

```
erode( image , Kernel , anchor , iteration)
```

- image : تصویر ورودی
- Kernal : ماتریس هسته
- Anchor : شماره درایه‌ی نقطه لنگری

Iteration : تعداد تکرار الگوریتم را مشخص میکند. مشخصا هرچه تعداد تکرار بیشتر باشد فرسایش نیز بیشتر خواهد بود.

مثال:

```
import cv2
import numpy as np

#step_1 convert image
img=cv2.imread("imag.JPG",0)

kernel = np.ones((5,5),np.uint8)
erosin=cv2.erode(img , kernel , iterations=1) # nitration write for inter face
cv2.imshow("erod" , erosin)
```

Dilation

این عملگر بر عکس عملگر erode بوده و نحوه کار این عملگر به اینصورت است که اگر حداقل یک پیکسل تحت پوشش درایه های یک، سفید باشد، پیکسل تحت پوشش درایه لنگر سفید می شود و اگر همه پیکسل های تحت پوشش درایه های یک، سیاه باشند، پیکسل تحت پوشش درایه لنگری سیاه می شود. از این رو پیکسل های سیاه پس زمینه که در مجاورت پیکسل های سفید هستند، سفید می شوند و سایر پیکسل ها بدون تغییر باقی می ماندند. در نتیجه تصویر پیش زمینه گسترش می یابد. این فیلتر در ترکیب با erode عملگر های پر کاربرد opening و closing را ایجاد می کنند.



تابع این عملگر dilate() است که پارامتر های آن مانند تابع erode است.

```
erosin=cv2.dilate(img , kernel , iteration=1)
```

عملگر opening :

این عملگر از اعمالی متوالی dilate و erode تشکیل شده است. در ابتدا با اعمال یک erode تصویر دچار فرسایش شده و نویز های تصویر (پیکسل ها و لکه های سفید) حذف می شوند. سپس با اعمال یک dilate تصویر اصلی که لبه هایش فرسایش یافته تا حد زیادی ترمیم می شود در نتیجه با اعمال opening تنها لکه های سفید از تصویر حذف می شوند. این عملگر با تابع morphologyEX به این صورت که در پارامتر دوم نوع عملگر که در اینجا opening است، پیاده سازی می شود.

morphologyEX(img , opration , kernel)

operation : نوع عملگر که در اینجا MORPH_OPEN می باشد.

مثال :

```
Op=cv2.morphplogyEX( img ,cv2.MORPH_OPRN ,kernel)
```



عملگر Closing :

این عملگر مانند عملگر opening است با این تفاوت که ابتدا عملگر dilate و سپس erode روی تصویر اعمال می شود. این عملگر برای تصاویری که بخشی هایی از اطلاعات آن حذف شده اند بسیار کاربردی است. در ابتدا با اعمال dilate روی تصویر، ضمن گسترش پیش زمینه، نواحی سیاه درون پیش زمینه را که سیاه هستند، سفید می کند تا تصویر پیش زمینه کاملاً پر شود و بخش های حذف شده جبران گردند. سپس با اعمال عملگر erode تصویر پیش زمینه که گسترش یافته دچار فرسایش می شود تا به حالت نرمال خود باز گردد. این عملگر نیز با تابع morphologyEX() پیاده سازی می شود

morphologyEX(img , opration , kernel)

```
C1=cv2.morphplogyEX( img ,cv2.MORPH_CLOSE ,kernel)
```

operation : نوع عملگر که در اینجا MORPH_CLOSE می باشد.



در ادامه تنها به معرفی برخی دیگر از عملگرهای ریخت شناسی می پردازیم و توضیح درباره آن ها خارج از محدوده این کتاب است

عملگر Morphological Gradient

این عملگر تصویر را به حالت outline در می آورد. این عملگر در حقیقت از اختلاف dilate و erode تصویر بدست می آید این عملگر نیز با تابع morphologyEX() پیاده سازی می شود.

morphologyEX(img , opration , kernel)

operation : نوع عملگر که در اینجا MORPH_GRADIENT می باشد.

```
Gr=cv2.morphologyEX( img ,cv2.MORPH_GRADIENT ,kernel)
```



عملگر Top Hat

این عملگر نتیجه ای به صورت زیر دارد و توسط تابع morphologyEX پیاده سازی می شود.

morphologyEX(img , opration , kernel)

operation : نوع عملگر که در اینجا MORPH_TOPHAT می باشد.

```
th=cv2.morphologyEX( img ,cv2.MORPH_TOPHAT ,kernel)
```



عملگر Black Hat

این عملگر نتیجه‌ای به صورت زیر دارد و توسط تابع morphologyEX پیاده سازی می‌شود.

morphologyEX(img , opration , kernel)

operation : نوع عملگر که در اینجا MORPH_BLACKHAT می‌باشد.

```
th=cv2.morphologyEX( img ,cv2.MORPH_BLACKHAT ,kernel)
```



ساخت یک Kernel متفاوت

گاهی لازم است ما یک kernel با شکلی خاص، مثلاً دایره ایجاد کنیم یک روش ساخت یک آرایه و مقدار دهی درایه به درایه آن است اما این روش کمی زمان بر است. اما روش دیگر که ساده تر است، بهره بردن از تابع getStructuringElement() است که تنها دو پارامتر برای ساخت kernel دریافت می‌کند.

getStructuringElement(kernel shape , size)

- kernel shape : شکل هسته را مشخص می‌کند که برای اینکار از keyword های پیشقرض نظیر MORPH_RECT
- size : ابعاد هسته را به صورت یک دوتایی مشخص می‌کند.


```
>>> cv2.getStructuringElement(cv2.MORPH_RECT,(5,5))
array([[1, 1, 1, 1, 1],
       [1, 1, 1, 1, 1],
       [1, 1, 1, 1, 1],
       [1, 1, 1, 1, 1],
       [1, 1, 1, 1, 1]], dtype=uint8)

# Elliptical Kernel
>>> cv2.getStructuringElement(cv2.MORPH_ELLIPSE,(5,5))
array([[0, 0, 1, 0, 0],
       [1, 1, 1, 1, 1],
       [1, 1, 1, 1, 1],
       [1, 1, 1, 1, 1],
       [0, 0, 1, 0, 0]], dtype=uint8)

# Cross-shaped Kernel
>>> cv2.getStructuringElement(cv2.MORPH_CROSS,(5,5))
array([[0, 0, 1, 0, 0],
       [0, 0, 1, 0, 0],
       [1, 1, 1, 1, 1],
       [0, 0, 1, 0, 0],
       [0, 0, 1, 0, 0]], dtype=uint8)
```

مثال :

نکته : این عملگرها برای شناسی در تصاویر نیز کاربرد دارند برای مثال در شکل زیر اگر یک هسته دایره ای شکل با اندازه دایره های تصویر را روی تصویر با عملگر **open** اعمال میکنیم و خطوط مانند نویز حذف می شوند. زیر تنها دوایر در این هسته مطابقت دارند و باقی می ماند و سایر اشکل حذف می شوند. توجه داشته باشید که ابعاد فیلتر تاثیر مهمی در این عملیات دارند. برای مثال اگر فیلتر ما از ذخامت خط ها کوچکتر باشد، خط ها به خوبی حذف نمی شوند.



کانتورها

کانتور چیست

کانتور (Contour) منحنی‌هایی هستند که از اتصال مجموعه‌ای از نقاط با ویژگی‌های مشابه شکل می‌گیرند و اغلب دور لبه‌های اشیاء در تصویر رسم می‌شوند. به عبارت ساده‌تر، کانتور مرز یا خطوطی است که شکل یک شیء را در تصویر مشخص می‌کند.


کانتورها کاربردهای زیادی دارند، از جمله:

- شناسایی و جداسازی اشیاء در تصویر
- محاسبه خصوصیات هندسی مانند مساحت، محیط و مرکز اشیاء
- ردیابی و تشخیص حرکت در تصاویر متوالی
- تشخیص شکل و اندازه اشیاء برای پردازش‌های بعدی

کانتورها معمولاً پس از اعمال فیلترهای لبه یا باینری کردن تصویر استخراج می‌شوند و کمک می‌کنند تا ساختار و شکل دقیق اشیاء به صورت عددی و تصویری تحلیل شود. در کانتورها ما دو بخش داریم:

- **Hole : Hole** یا همان چاله، پیرامون یک فضای خالی (فضای بین اشیا) را نشان می‌دهد. در تصاویر باینری چاله‌ها همان بخش‌های سیاه تصویر هستند. چاله‌ها در واقع مرزی داخلی اشیا هستند.
- **Curve : Curve** یا همان منحنی پیرامون یک شیء را توصیف می‌کنند. در تصاویر باینری، شیء‌ها همان بخش‌های سفید تصویر هستند.

در تصویر زیر منحنی‌ها با حرف **c** و چاله‌ها با حرف **h** مشخص شده‌اند.



استخراج کانتورها

برای یافتن کانتورها لازم است تا از تصاویر باینری استفاده شود از این رو لازم است ابتدا یک **threshod** و یا یک عملگر تشخیص لبه مانند **Canny** روی تصویر اعمال کرد. باید دقت کرد که در تصویر باینری، شی مورد نظر باید سفید و پس زمینه آن سیاه باشد. برای یافتن کانتور های یک تصویر از تابع **findContours()** استفاده می شود.

تذکر: در نسخه های جدید **opencv**، این تابع دارای تغییراتی بوده است.

`findContours ( img , mode , method ) ->img2 , contours , hierarchy`

- **img** : تصویر ورودی
- **Mode** : این پارامتر مشخص میکند که تابع چه کانتورهایی را یافته و به چه صورت آنها را ذخیره نماید. این پارامتر یکی از چهار حالت زیر است (در بخش آخر این فصل این موارد و عملکرد آن ها بیشتر پرداخته می شود).
 - **CV_RETR_EXTERNAL** : در این حالت تابع تنها بیرونی ترین کانتور ها را پیدا می کند
 - **CV_RETR_LIST** : همه کانتور هارا یافته و آن ها را در یک لیست قرار می دهد. در تصویر مثال قبل در این حالت
 - **CV_RETR_CCComp** : در این حالت تابع همه منحنی هارا به همراه مرز داخلی شان (حفره های درونشان) در یک سلسه مراتب دوسطحی نشان می دهد.

○ CV_RERT_TREE : در این حالت تابع همه منحنی‌ها را به صورت سلسله مراتبی، در یک ساختار درختی نشان می‌دهد.

ی

• Method : این پارامتر چگونگی ذخیره کانتور را معرفی می‌کند و می‌تواند یکی از گزینه‌های زیر باشد.

○ CHAIN_APPROX_NONE : در این حالت تابع مختصات تمام نقاط مرزی (تشکیل دهنده کانتور) را

ذخیره می‌کند. این کار حافظه زیادی اشغال می‌کند که معمولاً در بسیار از موارد نیازی به این کار نیست.

○ CHAIN_APPROX_SIMPLE : در این حالت تابع تنها نقاط ابتدایی و انتهایی یک خط را ذخیره می‌کند و

در واقع نقاط اضافی را حذف و کانتور را با تعدادی خط توصیف می‌کند از این‌رو در حافظه صرفه‌جویی می‌نماید.

○ CHAIN_APPROX_CODE : کانتور را به صورت کد زنجیری فریم توصیف می‌کند




Figure 8-4. Panel a, Freeman chain moves are numbered 0-7; panel b, contour converted to a Freeman chain-code representation starting from the back bumper

در کد فریم هر عدد نشان دهنده یک جهت بردار است و کانتور با این بردارها توصیف می‌شود و خروجی آن دنباله‌ای از اعداد است که شکل شی را توصیف می‌کنند

خروجی‌های این تابع نیز عبارتند از :


○ img2 : تصویر باینری که جست‌وجوی کانتورها روی آن انجام گرفته و در مواقعی که تصویر ورودی باینری نشده باشد،

کاربرد دارد. (همواره برای رسیدن به نتیجه مطلوب، تصویر ورودی تابع بهتر است باینری باشد)

○ Contours : کانتورهای پیدا شده که ممکن است به صورت مجموعه از نقاط تشکیل دهنده کانتور یا مجموعه از

خطوط تشکیل دهنده کانتور (مختصات نقاط ابتدا و انتهای خطوط را باز می‌گرداند) و یا کد فریم باشد

○ Hierarchy : سلسله مراتب (توضیحات بیشتر در بخش‌های بعدی)



مثال :

```
import numpy as np
import cv2 as cv

im = cv.imread('test.jpg')
imgray = cv.cvtColor(im, cv.COLOR_BGR2GRAY)
ret, thresh = cv.threshold(imgray, 127, 255, 0)

im2, contours, hierarchy =
cv.findContours(thresh, cv.RETR_TREE, cv.CHAIN_APPROX_SIMPLE)
```

رسم کانتورها

برای رسم کانتورها از تابع `drawContours()` استفاده می‌شود. در واقع از این تابع میتوان برای رسم هر شکلی که مختصات نقاط مرزی آن را داریم بهره ببریم.

`drawContours( img , contours , ContourIdx , color , thickness)`

`img` : تصویر ورودی که می‌خواهیم کانتورها روی آن رسم شوند

`Contours` : لیست کانتورها که از تابع `findContours()` بدست آوردیم و می‌خواهیم آن را رسم کنیم.

ContourIdx: پارامتر دوم یا **Contours** در واقع لیستی از چند منحنی است و هر درایه آن ، نشان دهنده یک منحنی می باشد. در این پارامتر با دادن شماره درایه، مشخص میکنیم کدام منحنی را تابع رسم کند. اگر این پارامتر ۱- داده شود، تابع کلیه کانتورها را رسم می کند

Color: رنگ کانتور را به صورت BGR مشخص می کند

Thickness: ضخامت کانتور را موقع رسم مشخص میکند. اگر این پارامتر ۱- داده شود، تابع کانتور را به صورت تو پر رسم می کند.

مثال :

```
#draw all contours
cv2.drawContours(img, contours, -1, (0,255,0), 3)

#draw 3th contour
cv2.drawContours(img, contours, 2, (0,255,0), 3)

#draw 3th contour
cnt=countours[2]
cv2.drawContours(img, [cnt], 0, (0,255,0), 3)
```

در مثال بالا دو روش برای رسم یک منحنی خاص که در این مثال منحنی سوم است، ارایه شده، خروجی هردوی این روش ها یکسان است اما در ادامه خواهیم فهمید روش دوم کارآمد تر است


```
import numpy as np
import cv2

img = cv2.imread('images.jpg')
img2=img.copy ()

#Convert to gray ang thresh
imgry=cv2.cvtColor (img ,cv2.COLOR_BGR2GRAY )
ret,thresh = cv2.threshold (imgry,0,255,cv2.THRESH_BINARY_INV + cv2.THRESH_OTSU)

#find and draw contours
im2, contours, hierarchy = cv2.findContours(thresh,cv2.RETR_CCOMP
,cv2.CHAIN_APPROX_SIMPLE)
cv2.drawContours (img2 , contours ,-1, (255,0,0) , thickness=5)

cv2.imshow ("out image", img2 )
cv2.imshow ("in image", img )
```



توابع کانتور

مساحت کانتور

برای بدست آوردن مساحت یک منحنی یا کانتور، از تابع `contourArea()` استفاده میکنیم که مساحت کانتور را بر اساس پیکسل محاسبه میکند.

`contourArea( contour ) -> Area`

تذکر : دقت شود که خروجی تابع `findContour()` لیستی از کانتور ها است و نه یک کانتور

مثال :

```
cnt=contours[0]  
area=cv2.contourArea (cnt)
```

طول کانتور

برای محاسبه طول یک کانتور یا منحنی از تابع `arcLength()` استفاده می‌شود. خروجی تابع برحسب پیکسل است

`arcLength( countour , closed ) -> length`

تابع closed

این پارامتر یک مشخص میکند که آیا منحنی بسته است یا خیر. اگر منحنی بسته باشد مقدار True در غیر این صورت مقدار False به تابع ارسال می شود

مثال :

```
cnt=contours[0]  
perimeter=cv2.arcLength (cnt ,True)
```

Approximates Contour


به معنی تقریب یک کانتور بوده که شکل کانتور را ساده تر می کند و از خطوط کمتری استفاده میکند. برای مثال فرض کنید شی مورد نظر شما یک مستطیل است اما به دلیل نویز، کانتور آن دقیقاً شکل یک مستطیل نیست و دارای ناهنجاری است. در اینجا تقریب کانتور بسیار مفید خواهد بود. برای اینکار از تابع `approxPolyDP()` استفاده می شود

-> `approx.curve approxPolyDP( curves , epsilon , closed )`

- `curves` : منحنی یا کانتور مورد نظر
- `Epsilon` : حداکثر اختلاف کانتور اصلی با کانتور تقریبی را بر اساس پیکسل مشخص می کند. در واقع این پارامتر دقت تخمین را مشخص میکند
- `Closed` : این پارامتر یک پارامتر Boolean بوده مشخص میکند که آیا منحنی بسته است یا خیر

مثال :

```
cntlen=cv2.arcLength (cnt ,True)  
approxCnt=cv2.approxPolyDP(cnt , cntlen*0.01 , True)  
  
cv2.drawContours (img2 , [approxCnt] ,0, (0,0,255) , thickness=5)
```



در تصویر مربع های زیر کانتور سمت راست با اپسیلون $\text{lenCnt} * 0.1$ تخمین زده شده که نتیجه مطلوب ما را ندارد اما منحنی وسطی با اپسیلون $\text{lenCnt} * 0.1$ تخمین زده شده و کانتور تقریبی به شکل مستطیل درآمد و ما را به هدفمان رسانده است



Hull Contour

حال در واقع یک منحنی محدب است که تقریبی از کانتور بوده و آنرا محاط میکند. Hull و approx متفاوتند اما ممکن است در برخی سوژه ها Hull یک کانتور شبیه approx آن باشد. برای بدست آوردن hull از تابع `convexHull()` استفاده می شود

→ `hull convexHull ( points [, hull [, clock wise , return point )`

points: نقاط تشکیل دهنده منحنی که میخواهیم hull آن را رسم کنیم که در اینجا همان کانتور مد نظر می باشد


Hull: منحنی خروجی که معمولا به جای استفاده از این پارامتر از مقدار بازگشتی تابع استفاده می کنیم

Clock wise: اگر این پارامتر True باشد، منحنی hull در جهت عقربه های ساعت و اگر false باشد منحنی در جهت خلاف عقربه های ساعت رسم می شود.

Return Points: این پارامتر یک مقدار، True و False است. اگر این پارامتر True باشد (حالت پیشفرض) تابع مختصات نقاط hull را باز میگرداند. اما اگر این پارامتر false باشد، شاخصه (شماره درایه) نقاط hull در کانتور را باز میگرداند. برای مثال برای یک hull مستطیلی در حالت true خروجی تابع به صورت `[(120,60), (140,70), (100,90), (130,40)]` است که مختصات چهار نقطه HULL را نشان می دهد. اما اگر false باشد، خروجی شاخصه نقاط بالا در کانتور مرجع است و مثلا به صورت `[ 120, 210, 350, 360 ]` است که هر کدام از این اعداد شاخصه یکی از نقاط هستند و مثلا `cnt[127]` همان نقطه `(120,60)` است پس `cnt[127] = (120,60)` کاربرد حالت دوم در بدست آوردن **convexity defects** یا نقص تخلخل ها کاربرد دارد که در تصویر دست زیر با فلش مشخص شده اند.

مثال: در تصویر زیر منحنی آبی کانتور ورودی و منحنی قرمز رنگ hull آن است

```
hull=cv2.convexHull (cnt)
cv2.drawContours (img2 , [hull] ,0, (0,0,255) , thickness=5)
cv2.imshow ("out image", img2 )
```



برای چک کردن این موضوع که یک کانتور محدب است یا خیر، از تابع `isContourConvex()` استفاده می‌شود که خروجی آن یک مقدار `True` یا `false` است.

```
k = cv2.isContourConvex(cnt)
```

مستطیل محاطی

مستطیلی است که یک کانتور را محاط می‌کند. در `opencv` دو نوع مستطیل محاطی برای کانتور ها تعریف شده است. مستطیل نوع `straight` نام دارد که مستطیل افقی و بدون زاویه است که چرخش شی را در نظر نمی‌گیرد و مساحت آن حداقل مساحت ممکن نیست. برای پیاده سازی این مستطیل محاطی از تابع `boundingRect()` استفاده می‌شود.

`boundingRect ( contour ) -> x,y,w,h`

مثال :

```
cnt=contour[0]
x,y,w,h = cv2.boundingRect(cnt)
cv2.rectangle(img,(x,y),(x+w,y+h),(0,255,0),2)
```


مستطیل محاطی دیگر `rotated` نام دارد که با حداقل مساحت رسم می‌شود از این رو زاویه دار بود و چرخش شی را در نظر می‌گیرد. برای بدست آوردن این مستطیل از تابع `minAreaRect()` استفاده می‌شود

`minAreaRect ( cnt ) -> center(x,y) , (w,h) , angle of Rotation`

تذکر : برای رسم یک مستطیل ما نیاز به مختصات چهار گوشه آن داریم اما خروجی این تابع به این صورت نیست از این رو از تابع `boxPoints()` استفاده می‌کنیم. برای یادگیری روش رسم این مربع به مثال زیر توجه فرمایید

مثال :

```
rect = cv2.minAreaRect(cnt)
box = cv2.boxPoints(rect)
box = np.int0(box)
cv2.drawContours(img,[box],0,(0,0,255),2)
```




در تصویر بالا مستطیل سبز رنگ straight و مستطیل قرمز رنگ rotated است که حداقل مساحت ممکن را دارد.

دایره محاطی : برای بدست آوردن کوچکترین دایره محاطی از تابع `minEncloseingCircle()` استفاده می کنیم.

`minEncloseingCircle( contour Or points ) -> center(x,y) , radius`

مثال

```
(x,y),radius = cv2.minEnclosingCircle(cnt)
center = (int(x),int(y))
radius = int(radius)
cv2.circle(img,center,radius,(0,255,0),2)
```




Fit Ellipse

تابع مربوطه یک بیضی تقریبی از کانتور ایجاد میکند. تابع این عملیات `fitEllipse()` می باشد.

`fitEllipse ( contour ) -> center(x,y) , axel( a,b ) , angle`

مثال :

```
ellipse = cv2.fitEllipse(cnt)
cv2.ellipse(img, ellipse, (0,255,0), 2)
```



Moment : Moment یک تصویر یا منحنی، خصوصیات مهمی از آنرا ارائه میدهد. خصوصیات نظیر مرکز جرم ، مرکز و... تابع بدست آوردن آن `memnt()` است

Moment (array) -> moment

• **Array** : آرایه ورودی که در اینجا کانتور ما است.

خروجی این تابع یک دیکشنری است که ویژگی های مختلف تصویر را از آن استخراج میکنیم در مثال زیر ما مختصات مرکز جرم کانتور را بر اساس **moment** محاسبه میکنیم. فرمول استفاده شده در این مثال ثابت بوده و بسیار کاربردی است

```
import cv2
import numpy as np

img = cv2.imread('star.jpg',0)
ret,thresh = cv2.threshold(img,127,255,0)
contours,hierarchy = cv2.findContours(thresh, 1, 2)
cnt = contours[0]
M = cv2.moments(cnt)
print M
#####
cx = int(M['m10']/M['m00'])
cy = int(M['m01']/M['m00'])
#####
```

مثال :

```
===== RESTART: C:/Users/Amir_PC/Desktop/contour.py =====
{'m00': 202458.5, 'm10': 83242258.33333333, 'm01': 87696183.66666666, 'm20': 366
45025510.916664, 'm11': 36044150715.95833, 'm02': 45739380900.25, 'm30': 1695556
7422548.8, 'm21': 15727765277362.117, 'm12': 18990730401792.35, 'm03': 266035372
72980.6, 'mu20': 2419376439.9544563, 'mu11': -12761567.932510376, 'mu02': 775322
2602.634773, 'mu30': -100784360418.34375, 'mu21': -134765978208.18762, 'mu12': 1
95712759684.0923, 'mu03': 74519153383.89453, 'nu20': 0.0590243777601933, 'nu11':
-0.00031133791088543497, 'nu02': 0.18915168892253847, 'nu30': -0.00546453367878
758, 'nu21': -0.007307018902700266, 'nu12': 0.010611556815193388, 'nu03': 0.0040
4043267914525}
>>> cy
433
>>> cx
411
>>> |
```

خصوصیات هندسی یک کانتور

Aspect Ratio

این پارامتر یا همان نسبت ابعاد، برابر است با نسبت $\frac{w}{h}$ مستطیل محاطی

```
x,y,w,h = cv2.boundingRect(cnt)
aspect_ratio = float(w)/h
```

Extent

این پارامتر برابر است با نسبت مساحت منحنی (کانتور) بر مساحت مستطیل محاطی. مساحت یک کانتور یا منحنی با تابع

$extent = \frac{contour\ area}{rect\ area}$ contourArea() محاسبه می‌شود.

```
x,y,w,h = cv2.boundingRect(cnt)
rect_area=w*h
area=cv2.contourArea( cnt)
extent=float (area) rect_area
```

Solidity

این پارامتر برابر است با نسب مساحت یک کانتور بر مساحت کانتور hull آن، تابع به دست آوردن hull یک منحنی convexHull() است. که ورودی آن منحنی مورد نظر و خروجی آن چندضلعی hull است. برای به دست آوردن مساحت یک

hull از همان تابع contourArea() استفاده می‌شود. $solidity = \frac{contour\ area}{hull\ area}$

```
Hull =cv2.convexHull(cnt)

area=cv2.contourArea( cnt)
hull_area=cv2.contourArea( hull)

solidity=float (area) rect_area
```

Equivalent Diameter

این پارامتر معادل است با قطر دایره‌ای که مساحتش با مساحت کانتور مورد نظر برابر باشد و مقدارش از فرمول ساده‌ی زیر بدست

$$\text{equivalent Diameter} = 2 \times \sqrt{\frac{\text{area}}{\pi}}$$


می‌آید

```
area=cv2.contourArea( cnt)
equi_diameter = 2*np.sqrt(area/np.pi)
```

Orientation

این پارامتر جهت گیری کانتور را بررسی می‌کند. که میتوان آنرا از تابع `fitEllipse()` برآورد کرد.

```
(x,y),(MA,ma),angle = cv2.fitEllipse(cnt)
ellipse = cv.fitEllipse(cnt)
cv.ellipse(img,ellipse,(0,255,0),2)
```



سایر توابع کانتور

```
(x,y),(MA,ma),angle = cv2.fitEllipse(cnt)
ellipse = cv.fitEllipse(cnt)
cv.ellipse(img,ellipse,(0,255,0),2)
```

Mask کانتور

گاهی نیاز است تا ما از کانتور یک ماسک ایجاد کنیم. به این صورت که پیکسل های تشکیل دهنده کانتور در ماسک سفید و سایر بخش ها سیاه شوند. برای ساخت یک ماسک از کانتور کافی است ابتدا یک آرایه با ابعاد تصویر با درایه های صفر به عنوان ماسک ایجاد کنیم سپس با تابع `drawContour()` تصویر کانتور را روی این آرایه، با رنگ سفید رسم میکنیم. همچنین برای بدست آوردن مختصات پیکسل های کانتور از تابع `findNoneZero()` استفاده میکنیم. ورودی این تابع تصویر مورد نظر که در اینجا ماسک ما است و خروجی آن لیستی از مختصات پیکسل های غیر صفر می باشد. برای درک بهتر به مثال زیر توجه نمایید.

مثال : در کد زیر ، در کامنت خط آخر روش دیگر برای بدست آوردن مختصات پیکسل های سفید ماسک داده شده است

```
mask = np.zeros(imgray.shape,np.uint8)
cv2.drawContours(mask,[cnt],0,255,-1)
pixelpoints = cv2.findNonZero(mask)
#pixelpoints = np.transpose(np.nonzero(mask))
```

Max min Value & Location

ما به استفاده از ماسکی که در قسمت قبل بدست آوردیم میتوانیم مختصات پیکسل هایی که متعلق به آن شی هستند و مقدارشان ماکزیمم و مینیمم است را مکان و مقدارشان را بدست آوریم. این کار با تابع `minMaxLoc()` انجام میگردد. ورودی این تابع تصویر اصلی به همراه ماسک مذکور می باشد و خروجی آن مختصات پیکسل های مذکور است

```
min_val, max_val, min_loc, max_loc = cv2.minMaxLoc(imgray,mask = mask)
```

Mean Color


توسط ماسک بخش قبل و با کمک تابع `mean()` میتوان شدت رنگ متوسط شی مورد نظر را بدست آورد. تصویر اصلی و ماسک مذکور به عنوان پارامتر به تابع ارسال می شوند و تابع، شدت متوسط رنگ شی را بر میگردداند.

```
min_val, max_val, min_loc, max_loc = cv2.minMaxLoc(imgray,mask = mask)
```

Extreme Point

با روش زیر میتوان مختصات نقاطی را که در بالاتر ، پایین ترین، راستی ترین و چپ ترین بخش شی قرار دارند را بدست آورد

```
leftmost = tuple(cnt[cnt[:, :, 0].argmin()][0])
rightmost = tuple(cnt[cnt[:, :, 0].argmax()][0])
topmost = tuple(cnt[cnt[:, :, 1].argmin()][0])
bottommost = tuple(cnt[cnt[:, :, 1].argmax()][0])
```



convexity defect

برای یافتن convexity defects از تابع `convexityDefects()` استفاده میکنیم

`convexityDefects ( contour , convex hull ) -> convexityDefects`

- `contour` : کانتور شی مورد نظر
- `Hull` : hull کانتور

خروجی این تابع یک آرایه است که هر سطر آن یک به صورت [نقطه شروع یک خط `hull`, نقطه پایان یک خط `hull`, دورترین نقطه از کانتور نسبت به آن خط , فاصله دورترین نقطه کانتور تا آن خط]


مثال : در مثال زیر ما بین دو نقطه شروع و پایان یک خط با رنگ آبی و مرکزیت دورترین نقطه از خط یک دایره سبز رسم میکنیم. دقت داشته باشید که مقدار سه پارامتر اول، شاخص های آن نقاط در کانتور هستند و نه خود نقاط (منحنی `hull` در تصویر با رنگ قرمز مشخص شده است)

```
_, cnts, _=cv2.findContours( thresh ,cv2.RETR_CCOMP , cv2.CHAIN_APPROX_SIMPLE )

hullA = cv2.convexHull(cnt )
hullB = cv2.convexHull(cnts[0],returnPoints = False)
cv2.drawContours (img , [hullA] ,0, (0,0,255) , thickness=8)

convexDFS=cv2.convexityDefects (cnts[0] , hullB)

cnt=cnts[0]
for i in range(convexDFS.shape[0]) :
    s,e,f,d=convexDFS[i,0]
    start=tuple(cnt[s,0])
    end=tuple(cnt[e,0])
    far=tuple (cnt[f,0])
    cv2.line (img , start , end ,(255,0,0),2)
    cv2.circle (img , far , 5, (0,255,0), -1)
cv2.imshow ("out image", img )
```



وضعیت یک نقطه نسبت به کانتور

تابع `pointPolygonTest()` کوتاه ترین فاصله یک نقطه دلخواه نسبت به یک کانتور را بدست می آورد. و اگر فاصله مثبت باشد، نقطه درون کانتور و اگر منفی باشد، نقطه خارج از کانتور قرار دارد، فاصله صفر یعنی نقطه روی کانتور قرار دارد.

`PointPolygonTest ( contour , point , measure Dist) -> distance`

Contour : کانتوری که می خواهیم وضعیت نقطه را نسبت به آن بررسی کنیم

Point : مختصات نقطه مورد نظر

Measure Dist: اگر این پارامتر `True` باشد، تابع کمترین فاصله نقطه از کانتور را باز میگرداند، اما اگر این پارامتر `False` باشد، تابع تنها با مقادیر `( outside ) -1` , `( on ) 0` , `( inside ) 1` وضعیت نقطه نیست به کانتور را مشخص میکند

مثال :

```
dist = cv2.pointPolygonTest(cnt,(50,50),True)
```

تشخیص شباهت دو کانتور

در بسیاری از کاربردهای پردازش تصویر، ممکن است بخواهیم تشابه شکل دو شیء را بررسی کنیم، بدون توجه به اندازه، موقعیت یا چرخش آن‌ها. یکی از روش‌های مؤثر برای انجام این کار، استفاده از کانتورها (Contours) است، زیرا کانتورها مرز و شکل دقیق اشیاء را نمایش می‌دهند.

با استخراج کانتورها از دو شیء، می‌توان شکل آن‌ها را به صورت عددی و قابل مقایسه نمایش داد. برای این منظور، OpenCV تابع `matchShapes()` را فراهم کرده است که شباهت دو شیء را بر اساس کانتورهایشان اندازه‌گیری می‌کند. این تابع در واقع بر پایه محاسبه Hu Moments است و معیارهای خاصی را برای مقایسه هندسی اشیاء استفاده می‌کند، به طوری که حتی اگر اشیاء چرخیده، مقیاس شده یا جابه‌جا شده باشند، می‌توان میزان شباهت آن‌ها را تعیین کرد.

`matchShapes ( contour۱ , contour۲ , method , parameter)`

- `contour۱ / contour۲` : کانتور هایی که می‌خواهیم باهم مقایسه کنیم.
- `Method` : این پارامتر روش مقایسه دو کانتور را معین میکند که یکی از سه حالت زیر است
 - `CV_CONTOURS_MATCH_۱۱`
 - `CV_CONTOURS_MATCH_۱۲`
 - `CV_CONTOURS_MATCH_۱۳`
- `Parameter` : پارامتر روش خاص (فعلاً ساپورت نمیکند ، ۰ داده شود)

تذکر : هرچه مقدار خروجی تابع کمتر باشد، شباهت دو کانتور بیشتر است.

مثال :

```

import cv2
import numpy as np

img1 = cv2.imread('star.jpg',0)
img2 = cv2.imread('star2.jpg',0)

ret, thresh = cv2.threshold(img1, 127, 255,0)
ret, thresh2 = cv2.threshold(img2, 127, 255,0)

contours,hierarchy = cv2.findContours(thresh,2,1)
cnt1 = contours[0]
contours,hierarchy = cv2.findContours(thresh2,2,1)
cnt2 = contours[0]

ret = cv2.matchShapes(cnt1,cnt2,1,0.0)
print ret

```

$$I_1(A, B) = \sum_{i=1..7} \left| \frac{1}{m_i^A} - \frac{1}{m_i^B} \right|$$


$$I_2(A, B) = \sum_{i=1..7} |m_i^A - m_i^B|$$

$$I_3(A, B) = \max_{i=1..7} \frac{|m_i^A - m_i^B|}{|m_i^A|}$$

$$m_i^A = \text{sign}(h_i^A) \cdot \log h_i^A$$

$$m_i^B = \text{sign}(h_i^B) \cdot \log h_i^B$$

مثال: در مقایسه ای که میان سه تصویر زیر صورت گرفت است، نتایج به صورت زیر است.



تطابق A با خودش = ۰.۰

تطابق A با B = ۰.۰۰۱۹۴۶


تطابق A با C = ۰.۳۲۶۹۱۱

همانطور که مشخص است اگر رزولوشن، ابعاد و زاویه دو تصویر یکسان نباشد، تاثیری در مقایسه کانتورها ندارد. زیرا این عملگر مقایسه شکل را مستقل از این پارامترها محاسبه می‌نماید.

سلسله مراتب یا hierarchy

در مباحث قبلی با تابع `findContours()` آشنا شدید. همانطور که مشاهده کردید این تابع سه خروجی داشت که شامل تصویر، کانتورها و سلسله مراتب می‌شد. اما سلسله مراتب واقعا به چه معنایی است. همچنین تاثیر پارامتر دوم یعنی `mode` به چه صورت است. ما از کانتورها برای تشخیص اشیا در تصویر استفاده می‌کنیم. اما در برخی تصاویر، اشیا سلسله مراتبی هستند و یک شی ممکن است در داخل شی دیگری باشد. برای مثال صورت انسان که خود شامل اشیایی دیگر نظیر چشم‌ها است. ما به کمک خروجی سوم یعنی `hierarchy` ارتباط کانتورها با یکدیگر را در میابیم. اینکه یک کانتور یک پدر برای کانتوری دیگر باشد و یا برعکس یک کانتور، زیرمجموعه یا فرزندی از یک کارتون دیگر باشد. هر کانتور شامل چهار پارامتر به صورت مقابل است که این ارتباطات را توصیف میکند [کانتور بعدی، کانتور قبلی، فرزند اول، پدر] که این مقادیر در `hierarchy` ذخیره میشوند.

[next , previous , First child , parent]



در تصویر بالا ما ۵ شی داریم، که از ۰ تا ۵ نام گذاری شده اند، کانتور ۲ و ۲a به ترتیب به مرز خارجی و داخلی یک شی تعلق دارند. کانتورهای ۰، ۱، ۲ هم سطح هستند و در بیرونی تری سطح قرار دارند که آنرا سطح صفر می‌نامیم. بعد از کانتور ۲a است که فرزند کانتور ۲ است (کانتور ۲ نیز پدر کانتور ۲a است) و در سطح یک قرار دارد. کانتور ۳ فرزند کانتور ۲a است. و به همین

صورت تا آخرین سطح که کانتور ۴ و ۵ در آن قرار دارند. این کانتور ها هردو فرزند کانتور ۳a هستند و کانتور ۴ اولین فرزند کانتور ۳a است (ممکن است کانتور ۵ فرزند اول باشد) این ها سطح بندی و سلسه مراتب کانتور ها هستند حال به پارامتر های hierarchy میپردازیم.

کانتور بعدی : کانتوریست هم سطح با کانتور مورد نظر که بعد از آن است. برای مثال در تصویر بالا کانتور ۰ را در نظر بگیرید، کانتور هم سطح بعدی این کانتور کانتور ۱ است. پس مقدار next برای کانتور ۰ برابر ۱ است. همچنین برای کانتور ۱ برابر ۲ می باشد. اما برای کانتور ۲، چون هیچ کانتور هم سطح دیگری پس از آن وجود ندارد، مقدار پارامتر next = -۱ است.

کانتور قبلی : کانتوریست در همان سلسله مرتبه که قبل از کانتور مورد نظر قرار دارد. برای مثال برای کانتور ۲، کانتور هم سطح قبلی، کانتور ۱ است، در نتیجه برای کانتور ۲ مقدار پارامتر previous برابر ۱ است و برای کانتور ۱، previous = ۰ می باشد. اما برای کانتور ۰ چون کانتور هم سطحی قبل از آن قرار ندارد این مقدار -۱ است.

اولین فرزند : همانگونه که از نامش مشخص است، اولین فرزند کانتور مورد نظر را تعیین میکند. برای مثال اولین فرزند کانتور ۲، کانتور ۲a است که تنها فرزند آن می باشد. همچنین برای کانتور ۳a اولین فرزند کانتور ۴ است. مشخصا اگر کانتور فرزندی نباشد مقدار این پارامتر ۱- خواهد بود

پدر : کانتور پدر کانتور فعلی را مشخص می کند. برای کانتور های ۴ و ۵، کانتور پدر کانتور ۳a است و برای کانتور ۳a مقدار parent برابر ۳ است و همین طور الی آخر. اگر کانتوری پدر نداشته باشد، مقدار این پارامتر ۱- است.

حالا که با سلسه مراتب کانتور ها آشنا شده ایم به سراغ پارامتر mode در تابع findContour() می رویم تا بررسی کنیم که پرچم های RETR_LIST, RETR_CCOMP و غیر واقعا به چه مفهومی هستند

پرچم های کانتور ها

۱- پرچم RETR_LIST

این پرچم ساده ترین حالت است که در آن تابع کلیه کانتور ها را بدون در نظر گرفتن سلسه مرتبه ذخیره میکند. از این رو پارامتر های First-Child و Parent در این حالت برای هر کانتور برابر ۱- است. اما کانتور های قبلی و بعدی در این حالت مشخص هستند. در زیر ما hierarchy یک تصویر را نشان دادیم، سطر اول این آرایه مربوط به کانتور ۰ و سطر دوم مربوط به کانتور یک و الی آخر. برای مثال برای کانتور ۰ ام، طبق hierarchy کانتور بعدی کانتور ۱ (پارامتر اول) است و کانتور قبلی آن ۱- (پارامتر دوم) است که یعنی کانتوری قبل از آن وجود ندارد

```
>>> hierarchy
array([[ 1, -1, -1, -1],
       [ 2,  0, -1, -1],
       [ 3,  1, -1, -1],
       [ 4,  2, -1, -1],
       [ 5,  3, -1, -1],
       [ 6,  4, -1, -1],
       [ 7,  5, -1, -1],
       [-1,  6, -1, -1]])
```


```
>>> hierarchy
array([[ 1, -1, -1, -1],      #contour 0
       [ 2,  0, -1, -1],      #contour 1
       [-1,  1, -1, -1]])      #contour 2
```

پرچم RETR_EXTERNAL

با استفاده از این پرچم، تابع تنها کانتور هایی را که در بالاترین سطح قرار دارند پیدا می کند. در واقع در این حالت، تنها کانتور هایی که در سطح صفر هستند بررسی می شوند و سایر کانتور ها از دید تابع حذف می شوند. برای تصویر بالا نتیجه به صورت زیر است و تنها کانتور های ۰، ۱، ۲ در خروجی دیده می شوند.

پرچم RETR_CCOMP

در این حالت تابع کلیه کانتور ها را استخراج میکند و آنها را در دو سطح، سطح بندی میکند، به این صورت که کانتور های متعلق به اشیاء (کانتورهای مرز خارجی) را در سطح ۱ و کانتور های متعلق به حفره ها (کانتور مرز داخلی) را در سطح ۲ قرار می دهد البته در اصل کانتور حفره ها بستگی به کانتوری که در آن قرار دارند سطح بندی می شوند. برای درک بهتر به تصویر زیر توجه فرمایید



در تصویر بالا اعداد نارنجی رنگ شماره کانتور و اعداد سبز نشان دهنده سطح آن کانتور می‌باشند.

در تصویر بالا کانتور ۰ را در نظر بگیرید. در این کانتور کانتور قبلی وجود ندارد. کانتور بعدی آن که هم سطح آن باشد (سطح ۱) کانتور ۳ است. از طرفی این کانتور چون در سطح ۱ قرار دارد هیچ پدری ندارد و فرزند اول آن کانتور ۱ است. بنابراین آرایه سلسه مرتبه این کانتور به صورت مقابل است : $[-1, 1, -1, 3]$

همچنین برای کانتور ۱، کانتور بعدی آن در همان سطح، کانتور ۲ است و کانتور قبل از آن وجود ندارد. همچنین این کانتور چون در سطح ۲ است، هیچ فرزندی ندارد و پدر آن کانتور ۰ می‌باشد. پس آرایه سلسه مرتبه آن برابر است با $[0, -1, -1, 2]$

برای کانتور ۲ نیز، کانتور بعدی هم سطحش باشد وجود ندارد و کانتور قبلی آن کانتور ۱، مشابه این کانتور فرزندی ندارد و کانتور پدر آن کانتور ۰ است $[0, -1, 1, -1]$


برای کانتور ۳ نیز کانتور بعد اش ۵، کانتور قبلی کانتور ۰، کانتور فرزند آن کانتور ۴ و کانتور پدر ندارد $[-1, 4, 0, 5]$

همچنین برای کانتور ۴، کانتور بعدی و قبلی در همان سطح و مشخصا فرزندی ندارد همچنین کانتور پدر آن کانتور ۳ است

```
>>> hierarchy
array([[[ 3, -1,  1, -1],
        [ 2, -1, -1,  0],
        [-1,  1, -1,  0],
        [ 5,  0,  4, -1],
        [-1, -1, -1,  3],
        [ 7,  3,  6, -1],
        [-1, -1, -1,  5],
        [ 8,  5, -1, -1],
        [-1,  7, -1, -1]]])
```

پرچم RETR_TREE

در این حالت پرچم کلیه کانتور ها را یافته و یک سلسله مراتب کامل برای آن ایجاد میکند به طوری که در آن کانتور پدر، فرزند، نوه و... قابل تشخیص می‌باشد. برای درک بهتر این موضوع تصویر زیر را در نظر بگیرید.



در تصویر بالا اعداد نارنجی رنگ شماره کانتور و اعداد سبز سطح آنان است

برای مثال برای کانتور ۰، کانتوری قبل از آن در همان سطح وجود ندارد اما کانتور بعدی آن کانتور ۷ است، فرزند این کانتور کانتور ۱ است و هیچ پدری ندارد در نتیجه آرایه سلسله مرتبه آن به صورت $[-1, 1, -1, 7]$ است

همچنین برای کانتور ۲، هیچ کانتور همسطحی در قبل و بعد آن نیست. کانتور پدر آن ۱ است و فرزند اول آن کانتور ۳ است پس آرایه آن به صورت مقابل خواهد بود $[1, 3, -1, -1]$


کانتور ۳ نیز هیچ کانتور همسطحی ندارد، کانتور پدر آن ۲ و فرزند اول آن کانتور ۴ است. $[2, 4, -1, -1]$

```
>>> hierarchy
array([[[ 7, -1, 1, -1],
        [-1, -1, 2, 0],
        [-1, -1, 3, 1],
        [-1, -1, 4, 2],
        [-1, -1, 5, 3],
        [ 6, -1, -1, 4],
        [-1, 5, -1, 4],
        [ 8, 0, -1, -1],
        [-1, 7, -1, -1]]])
```

هیستوگرام

هیستوگرام چیست

هیستوگرام در واقع یک نمودار میله ای است که محور افقی آن شامل داده ها و محور عمودی فراوانی داده ها در یک مجموعه را نشان می دهد. پس هیستوگرام یک تصویر، فراوانی (تعداد) پیکسل های بازه های رنگی مختلف را نشان می دهد. مثلاً در یک تصویر خاکستری می تواند نشان دهد چه تعداد پیکسل ها در بازه (۰،۱۰) و (۱۰،۲۰) و... را نشان دهد. در تصویر زیر هیستوگرام کانال های سبز، قرمز و آبی را مشاهده می کنند. هر بخش از این نمودار ها نشان می دهد که از چه شدت پیکسلی چه میزان استفاده شده برای مثال در هیستوگرام کانال آبی مشخص است که تعداد بیشتر پیکسل ها دارای شدت آبی بین ۰ تا ۵۰ هستند.



هیستوگرام کاربردهای زیادی در پردازش تصویر دارد و اطلاعات مهمی از تصویر را در خود ذخیره کرده. نظیر ماهیت تصویر، تیرگی یا روشنی تصویر و...

محاسبه هیستوگرام تصویر

هیستوگرام یک تصویر را میتوان با تابع `calcHist()` بدست آورد

- `calcHist( img , channels num , mask , hist Size , ranges )`
- `img` : تصویری که می خواهیم هیستوگرامش را بدست آوریم.
- `Channels num` : شماره کانال هایی از فضای رنگ تصویر که می خواهیم هیستوگرامشان را در تصویر را بدست آوریم.

- **Mask**: در صورتی که میخواهیم هیستوگرام بخشی از تصویر را بدست آوریم، ماسک مورد نظر را در این آرگومان وارد میکنیم در غیر این صورت، برای کل عکس، عبارت **None** را وارد می‌کنیم.
- **Hist Size**: تعداد کل ستون های هیستوگرام (میله های نمودار میله) را مشخص میکند مشخصاً هرچه تعداد ستون ها بیشتر باشد، پردازش سنگین تر خواهد بود.
- **Ranges**: بازه محور افقی هیستوگرام را مشخص میکند مثلاً برای بررسی پیکسل های روشن در یک تصویر خاکستری بازه ۱۰۰ تا ۲۵۵ را انتخاب میکنیم. مشخصاً برای بررسی کل بازه محور در یک تصویر ۸ بیتی این بازه ۰ تا ۲۵۵ خواهد بود

نکته: مقادیر **img**, **channels num**, **Hist size**, **Ranges** به صورت لیست باید وارد شوند

مثال: در این مثال هیستوگرام کانال سبز تصویر **img** را در بازه ۰ تا ۲۵۵ (مقادیر پیکسلی) با ۲۵۶ ستون بدست آوردیم.

```
import cv2
img = cv2.imread('opencv_logo.png')

hist = cv2.calcHist([img], [0], None, [256], [0,255])
```


برای تعریف یک ماسک کافی است، با کتابخانه **numpy** و از طریق توابع مربوطه (**array()** یا **zeros()** و...) یک آرایه با ابعاد تصویر ایجاد نماییم و پیکسل هایی که میخواهیم ماسک (محافظت) شوند، درایه نظیرشان در آرایه را ۰ (سیاه) و پیکسل مورد هدف را درایه نظیرشان را ۲۵۵ (سفید) مقدار می‌دهیم و نهایت در تابع **calcHist** آن را وارد می‌کنیم.

مثال: در مثال زیر ما میخواهیم تنها هیستوگرام یک بخش مربعی از تصویر را محاسبه کنیم.

```
import cv2
img = cv2.imread('home.png')

# crat mask
mask= np.zeros(img.shap[:2], np.uint8)
mask[100:300, 100:400]=255
masked_img=cv2.bitwise_and(img, img, mask=mask)

#calc Hist
Hist_full = cv2.calcHist([img], [0], None, [256], [0,255])
Hist_mask = cv2.calcHist([img], [0], mask, [256], [0,255])
```



برای نمایش هیستوگرام تصویر می‌توان از کتابخانه `matplotlib` و ماژول `pyplot` استفاده کرد. با اد کردن این ماژول به برنامه، با استفاده از تابع `plot()` و `show()` هیستوگرام را نمایش داد.

Plot (hist)


Show()

مثال :

```
import cv2
import matplotlib.pyplot as plt

img = cv2.imread('home.png')

#calc Hist
Hist = cv2.calcHist([img] , [0] , None , [256] , [0,255])
#show hist
Plt.plot(hist)
Plt.show()
```




بهبود کنتراست با Equalization Histogram

یکی از روش‌های بهبود کنتراست تصویر، یکنواخت‌سازی هیستوگرام (Histogram Equalization) است.

با این روش، به جای اینکه تصویر تنها از بازه محدودی از مقادیر رنگی استفاده کند، پیکسل‌ها از کل بازه مقادیر ممکن بهره می‌برند.

به عنوان مثال، در تصویر سمت چپ، هیستوگرام نشان می‌دهد که پیکسل‌ها تنها در یک بازه محدود از شدت‌ها قرار دارند، در حالی که تصویر با کنتراست مناسب، پیکسل‌های آن در تمام بازه شدت‌ها پخش شده‌اند، مشابه هیستوگرام سمت راست.

در واقع، فرآیند یکنواخت‌سازی هیستوگرام باعث می‌شود که هیستوگرام در محور X کشیده شود و تمامی شدت‌ها به طور یکنواخت در تصویر توزیع شوند، که نتیجه آن افزایش وضوح و کنتراست تصویر است.



با یکنواخت‌سازی هیستوگرام ما میتوانیم تصاویر با شرایط نوری متفاوت را باهم مقایسه کنیم و مثلاً در تشخیص چهره بسیار کاربردی خواهد بود. برای یکنواخت‌سازی هیستوگرام از تابع `equalizeHist()` استفاده می‌کنیم

`equalizeHist( one channel img) ->img`

تذکر: همانطور که مشخص است، ورودی این تابع باید یک تصویر تک کاناله باشد. مانند یک تصویر خاکستری.

تذکر: برای تصاویر رنگی لازم است ابتدا به کمک تابع `split()` کانال های تصویر را جدا کرده و هر کانال را به صورت جداگانه `equalize` کرده و سپس تصاویر بدست آمده را با تابع `merge()` ادغام مینماییم

```
import cv2
import matplotlib.pyplot as plt
img = cv2.imread('wiki.jpg', 0)
eqH = cv2.equalizeHist(img)
#show
cv2.imshow(" eq hist", eqH)
cv2.imshow(" org", img)
```



در مثال قبل ما با استفاده از یکنواخت سازی هیستوگرام کنتراست تصویر را بهبود بخشیدیم. در تابع `equalizeHist()` ما کنتراست کل تصویر را به صورت کلی و یکجا یکسان سازی کردیم. اما این کار ممکن است در بعضی موارد نتیجه خوبی نداشته باشد



در تصاویر بالا تصویر سمت راست هیستوگرامش یکنواخت شده است. با وجود آنکه کنتراست کتابخانه بهتر شده است اما صورت مجسمه مطلوب نیست و اطلاعات زیادی از دست رفته. علت به این خاطر است که هیستوگرام این تصویر به محدوده خاصی از مقادیر، محدود نبوده. برای بهبود کنتراست این تصویر، ابتدا باید تصویر به بلوک های کوچکی مثلاً 8×8 ، تقسیم شود که این بلوک ها را کاشی می نامیم سپس هیستوگرام این کاشی ها را یکی یکی یکنواخت می کنیم. اما اگر تصویر دچار نویز باشد، نویز آن

تقویت خواهد شد، برای حل این موضوع، یک حد مجاز برای bin یا میله هیستوگرام در نظر گرفته می‌شود و اگر طول bin از این حد مجاز بیشتر شود، پیکسل‌های متعلق به آن مقدار همگی حذف و بین سایر مقادیر تقسیم می‌شوند سپس عمل یکنواخت سازی هیستوگرام انجام می‌پذیرد.

برای پیاده سازی در openCV باید یک CLAHE ایجاد کرد و آن را به کمک تابع `apply()` روی تصویر پیاده سازی کرد. تابع ایجاد CLAHE ، `createCLAHE()` می‌باشد


`createCLAHE ( [ , clipLimit [ , tileGrid Size)`

- `clipLimit` : حد مجاز برای طول bin ها
- `tileGrid Size` : اندازه کاشی ها برای تقسیم بندی عکس

```
import numpy as np
import cv2

img = cv2.imread('tsukuba_1.png',0)

# create a CLAHE object (Arguments are optional).
clahe = cv2.createCLAHE(clipLimit=2.0, tileGridSize=(8,8))
c11 = clahe.apply(img)
cv2.imwrite('clahe_2.jpg',c11)
```



هستوگرام دو بعدی

در بخش قبل ما هیستوگرام یک کانال را بدست آوردیم . این هیستوگرام یک بعدی بود و تنها شدت رنگ یک کانال را یا تصویر خاکستری را بررسی می‌کرد. اما هیستوگرام دو بعدی هیستوگرامی است که ویژگی رنگ و میزان اشباع را به تصویر بکشد و کاربرد اصلی آن برای تصاویر رنگی است. برای بدست آوردن هیستوگرام دو بعدی از همان تابع `calHist()` استفاده می‌کنیم اما پیش از آن باید تصویر را به فضای رنگی HSV ببریم. مشخصات این هیستوگرام به صورت زیر است

Channels : به صورت [0,1] است زیر می‌خواهیم هیستوگرام کانال های s , h را بدست آوریم.

Bins : به صورت [۲۵۶ , ۱۸۰] است . مقدار ۱۸۰ برای کانال h و مقدار ۲۵۶ برای s

Ranges : به صورت [۰,۲۵۶ , ۰,۱۸۰] می باشد.

مثال :


```
import cv2
import numpy as np
img = cv2.imread('home.jpg')
hsv = cv2.cvtColor(img,cv2.COLOR_BGR2HSV)
hist = cv2.calcHist([hsv], [0, 1], None, [180, 256], [0, 180, 0, 256])
```

برای نمایش هیستوگرام دوبعدی دو راه وجود دارد. راه اول استفاده از تابع `imshow()` است. زیر هیستوگرام ما دو بعدی بوده و میتوان آنرا به عنوان یک تصویر نشان داد. اما تصویر خروجی تصویری خاکستری بوده و درکی از رنگ ها در آن وجود ندارد. راه دیگر استفاده از توابع کتابخانه `matplotlib` است که درک بهتری از تراکم پیکسلی برای ما فراهم میکند. اما شاید باز هم مانند بالا رنگ ها مشکل باشد مگر با دانستن مقادیر H به ازای رنگ های مختلف.

تذکر : هنگام استفاده از تابع `imshow` در کتابخانه `matplotlib` مقدار پارامتر `interpolation` را برابر 'nearest' قرار دهید.

مثال : در هیستوگرام تصویر زیر ، محور افقی مربوط به پارامتر H و محور عمودی پارامتر S را نشان می دهد

```
hist = cv2.calcHist( [hsv], [0, 1], None, [180, 256], [0, 180, 0, 256] )
plt.imshow(hist,interpolation = 'nearest')
plt.show()
```



در هیستوگرام بالا یک در $h=100$ و $s=200$ یک تراکم پیکسلی مشاهده می شود که متعلق به آبی آسمان است. همچنین در $H=25$ و $S=100$ نیز تراکم پیکسل دیگری به چشم می خورد که متعلق به رنگ زرد قصر است.

تشخیص محتوای خاصی از تصویر

گاهی در پردازش تصویر نیاز داریم تا یک محتوای خاص را در تصویر جست‌وجو کنیم و برای هر پیکسل، احتمال تعلق آن به آن محتوا را مشخص نماییم.

به عنوان مثال، فرض کنید می‌خواهیم در یک تصویر، احتمال تعلق هر پیکسل به پوست بدن را بدست آوریم.

برای این کار می‌توان از پس‌افکنش هیستوگرام (Histogram Backprojection) استفاده کرد. روش کار به این صورت است که ابتدا هیستوگرام نمونه‌ای از محتوای مورد نظر (مثلاً یک بخش از پوست) محاسبه می‌شود. سپس این هیستوگرام را به عنوان یک تابع احتمال در نظر می‌گیریم، به طوری که برای هر پیکسل تصویر، احتمال تعلق آن به محتوا مشخص شود.

خروجی پس‌افکنش هیستوگرام، یک تصویر خاکستری از احتمال‌ها است:

- پیکسل‌های سفید (مقدار ۲۵۵) نشان‌دهنده احتمال ۱۰۰ درصد تعلق به محتوا هستند.
- پیکسل‌های مشکی (مقدار ۰) نشان‌دهنده احتمال ۰ درصد تعلق هستند.

به این ترتیب می‌توان مناطق تصویر که بیشترین شباهت به نمونه دارند را تشخیص داد و برای پردازش‌های بعدی مانند شناسایی، جداسازی یا فیلتر کردن آن محتوا استفاده کرد.



تصویر پس‌افکنش هیستوگرام پوست انسان را روی یک عکس

برای پس‌افکنش یک هیستوگرام از تابع `calcBackProject()` استفاده می‌کنیم.

`calcBackProject( [ imag ] , [ channel numbers ] , hist , [ ranges ] , scale )`

- `imag` : تصویری که می‌خواهیم بررسی کنیم
- `Channel number` : شماره کانالی مورد نظر از تصویر برای پس‌افکنش. ۰ (آبی یا خاکستری یا hue) ، ۱ (سبز یا saturation) ، ۲ (قرمز یا vale) برای فضاهای رنگی RGB ، gray و HSV باشد.


- **Hist** : هیستوگرامی که می‌خواهیم بر اساس آن پس افکنش کنیم به عبارت دیگر، هیستوگرامی ناحیه ای که می‌خواهیم در تصویر جست و جو کنیم و احتمال تعلق هر پیکسل به آن را بدست آوریم.
- **Ranges** : بازه ی پیکسل هایی که می‌خواهیم بررسی کنیم
- **Scale** : یک عدد است که به عنوان ضریب در تصویر خروجی ضرب میشود تا در مواردی تصویر بصری بهتری تولید شود.

نکته: توصیه می‌شود تصویر نمونه که هیستوگرام آن محاسبه می‌شود و تصویر مورد بررسی که پس افکنش می‌شود؛ در فضای رنگی HSV مورد استفاده قرار گیرند تا با حذف پارامتر V ، تاثیرات روشنایی روی رنگ ها از بین برود.
پیدا کردن یک محتوا در یک تصویر:

- ۱- تبدیل عکس محتوا و عکس مورد بررسی به HSV
 - ۲- بدست آوردن هیستوگرام یک نمونه از محتوا
 - ۳- بهتر است در این مرحله هیستوگرام را توسط تابع `normalize()` نرمال کنیم (مراجعه به مثال بعد)
- `normalize(input, output, min, max, thresh type)`
- ۴- فراکنش هیستوگرام روی تصویر و به دست آوردن تصویر احتمال

***مراحل ۵ به بعد اضافی می‌باشد و برای نتیجه بهتر ارائه شده‌اند.**

- ۵- ترشولد کردن تصویر احتمال برای بدست آوردن تصویر بصری بهتر. با استفاده از تابع `Threshold()`
- `Threshold(imag, tresh, max, thresh type)`
- Imag** : تصویر ورودی
- Thresh**: مقداری که اعداد بیشتر آن به بالا و اعداد کمتر به پایین منتقل می‌شوند.
- Max**: ماکزیمم مقداری عددی برای `thresh` شدن.
- Thresh thpy** : روش مورد نظر برای ترش کردن که در شکل زیر آورده شده‌اند.



یک نمونه threshold

۶- ساخت یک تصویر سه بعدی (آرایه سه بعدی) و and کردن آن با تصویر اصلی برای حذف بخش های سیاه. با استفاده از تابع `bitwise_and()`

در مثال زیر ما هیستوگرام یک عکس نمونه از پوست را بدست آورده و تصویر احتمال صورت را بدست می آوریم.

```

import cv2
import numpy as np

face=cv2.imread ("face.jpg")
skin = cv2.imread ("skin.png")
skinhsv=cv2.cvtColor (skin,cv2.COLOR_BGR2HSV )
facehsv=cv2.cvtColor (face,cv2.COLOR_BGR2HSV )

hist=cv2.calcHist ([skinhsv],[0,1], None , [180,256],[0,180,0,256])
cv2.normalize (hist,hist,0,255 ,cv2.NORM_MINMAX )
bp=cv2.calcBackProject ([facehsv],[0,1], hist,[0,180,0,255],1)

cv2.imshow("face", face)
cv2.imshow("skin", skin)
cv2.imshow("back prj", bp)


_,tr=cv2.threshold(bp, 10,255,cv2.THRESH_BINARY )
cv2.imshow("thresh", tr)

kernel1=np.ones((7,7), np.uint8 )
kernel2=np.ones((3,3), np.uint8 )
tr1=cv2.morphologyEx (tr,cv2.MORPH_OPEN, kernel2 , iterations=1)
tr1=cv2.morphologyEx (tr,cv2.MORPH_CLOSE, kernel1 , iterations=3)
cv2.imshow("tr1", tr1)

tr1=cv2.merge ( (tr1,tr1,tr1))
out=cv2.bitwise_and (face , tr1)

cv2.imshow("out", out)

```



مقایسه محتوای دو تصویر با هیستوگرام

برای مقایسه محتوای دو تصویر، می توان از مقایسه هیستوگرام آن دو تصویر بهره بود. هرچه هیستوگرام دو تصویر به هم نزدیک تر باشند. مثلاً هیستوگرام تصویر دو صورت انسان بسیار شبیه تر است تا هیستوگرام صورت یک انسان و یک ببر. برای مقایسه هیستوگرام دو تصویر از تابع `comparHist()` استفاده می شود. خروجی این تابع یک عدد است. هرچه این عدد بزرگتر باشد، دو هیستوگرام و دو تصویر به هم شبیه ترند و مقدار صفر به معنای عدم هیچگونه شباهت است:

`compareHis ( Hist ۱ , Hist ۲ , Compare method)`

Hist ۱, Hist ۲ : هیستوگرام هایی که قرار د باهم مقایسه شوند.

Compare method : روش مقایسه دو هیستوگرام که به صورت های زیر است:

- ۱- HISTCMP_CHISQR : روشی که تفاضل مربعی بین bin (میله های نمودار میله ای) ها را بدست می آورد
- ۲- HISTCMP_CORREL : روشی مبتنی بر عملگر همبستگی نرمال که از آن برای اندازه گیری شباهت بین دو سیگنال استفاده می شود.
- ۳- HISTCMP_BHATTACHARYYA : برای تخمین شباهت بین دو توزیع احتمال مورد استفاده قرار می گیرد
- ۴- HISTCMP_INTERSECT : مبتنی بر تقاطع دو هیستوگرام
- ۵- HISTCMP_HELLINGER : همانند روش شماره ۳ است.

تذکر: کلیه این روش ها مقایسه را bin به bin انجام می دهند

مثال:

```

import cv2

face1=cv2.imread("face1.JPG")
face2=cv2.imread("face2.JPG")
face3=cv2.imread("face3.JPG")

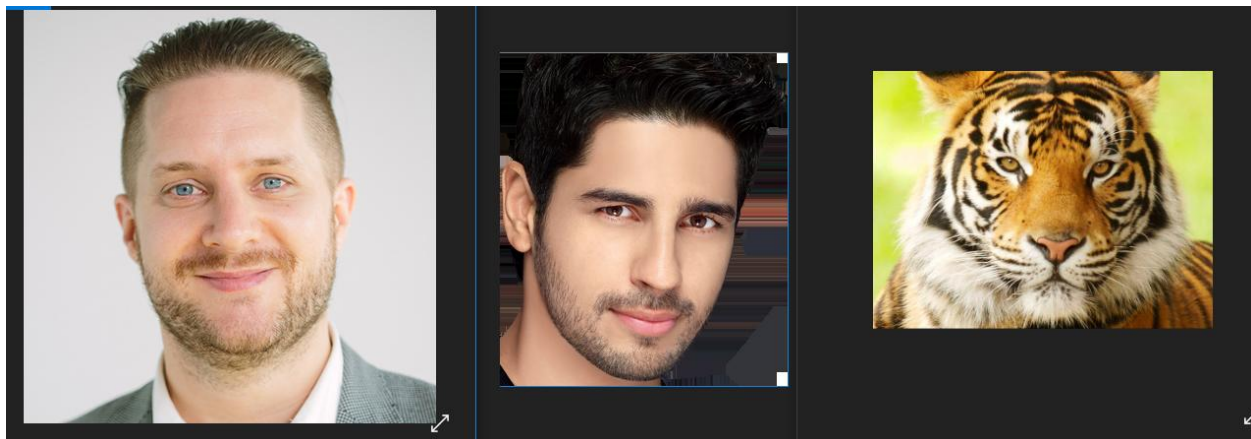
hsv1=cv2.cvtColor (face1,cv2.COLOR_BGR2HSV)
hsv2=cv2.cvtColor (face2,cv2.COLOR_BGR2HSV)
hsv3=cv2.cvtColor (face3,cv2.COLOR_BGR2HSV)

hist1=cv2.calcHist([hsv1],[0,1] , None , [180,255],[0,180,0,255],1)
hist2=cv2.calcHist([hsv2],[0,1] , None , [180,255],[0,180,0,255],1)
hist3=cv2.calcHist([hsv3],[0,1] , None , [180,255],[0,180,0,255],1)

com12=cv2.compareHist(hist1 , hist2 , cv2.HISTCMP_INTERSECT)
com13=cv2.compareHist(hist1 , hist3 , cv2.HISTCMP_INTERSECT)
com23=cv2.compareHist(hist2 , hist3 , cv2.HISTCMP_INTERSECT)

cv2.imshow("face1",face1)
cv2.imshow("face2",face2)
cv2.imshow("face3",face3)

```



تصاویر به ترتیب از سمت چپ به راست face۱ , face۲ , face۳

```
===== RESTART: C:\Users\Amir_PC\Desktop\opencv.py =====
>>> com12
51845.0
>>> com13
36233.0
>>> com23
8255.0
>>> |
```

همان گونه که از نتایج پیداست بیشترین شباهت میان تصاویر ۱ و ۲ است که هر دو صورت انسان را تشکیل می‌دهند و تصویر ۳ و ۴ که یکی متعلق به ببر و دیگری متعلق به انسان است، کمترین شباهت را دارند.

در این مثال در صورتی که با بر افکنش هیستوگرام پوست انسان و با الگوریتم meamShift بخشی از هر تصویر که بیشترین شباهت به صورت را دارند جدا کرده و آن بخش‌ها را با هم مقایسه کنیم، نتایج بهتری را شاهد خواهیم بود. در این مثال با تست متد HISTCMP_CORREL، نتایج زیر دریافت شد. که قابل قبول تر است

```
===== RESTART: C:\Users\Amir_PC\Desktop\opencv.py =====
>>> com12
0.2178886735836143
>>> com13
0.0018759967839581284
>>> com23
-0.0011413661431428628
>>> |
```

تطابق الگو (TempLate Machining)

هدف از تطابق الگو، پیدا کردن یک تصویر الگو یا object در یک تصویر می‌باشد. مثلاً پیدا کردن صورت در یک تصویر. تابع `matchTemplate()` در `openCV` برای همین منظور ایجاد شده‌است. در این تابع تصویر الگو روی تصویر اصلی حرکت می‌دهد و در هر مرحله، میزان شباهت تصویر الگو با بخشی از تصویر که روی آن قرار دارد را بررسی می‌کند. خروجی این تابع یک تصویر خاکستری است که هر پیکسل آن میزان شباهت پیکسل‌های محدوده خود را نشان می‌دهد. اگر ابعاد تصویر اصلی W, H و ابعاد تصویر الگو w, h باشد، ابعاد تصویر خروجی $(W-w+1, H-h+1)$ می‌باشد. در نهایت با تابع `minMaxLoc()` میتوان پیکسلی که بیشترین شدت را دارد پیدا نموده و به مرکزیت آن، یک مستطیل با ابعاد w, h رسم نمود. لازم به ذکر است که اندازه تصویر `template` شی مورد نظر باید مطابق با اندازه همان شی در تصویر اصلی باشد.

`matchTemplate ( img , templ , method )`

`img` : تصویر ورودی که می‌خواهیم عملیات جست و جو را روی آن انجام دهیم

`Templ` : تصویر الگویی که می‌خواهیم آن را در تصویر اصلی جست و جو کنیم، تصویر شی مورد نظر

`Method` : روش جست و جو که یکی از گزینه‌های زیر میتواند باشد :

- ۱- پرچم‌های `TM_CCOEFF`, `TM_CCOEFF_NORMED`, `TM_CCORR`, `TM_CCORR_NORMED` که در تصویر خروجی آن‌ها، پیکسل‌هایی که بیشترین شدت را دارند (نزدیک به سفید هستند) محل هدف است
- ۲- پرچم‌های `TM_SQDIFF`, `TM_SQDIFF_NORMED` که در تصویر خروجی آن‌ها، پیکسل‌هایی که کمترین شدت (نزدیک به سیاه هستند) را دارند محل هدف هستند

مثال :

```

import cv2

img = cv2.imread('messi.jpg',0)
img2 = img.copy()
template = cv2.imread('templ.jpg',0)
w, h = template.shape[::-1]

methods = ['cv2.TM_CCOEFF', 'cv2.TM_CCOEFF_NORMED', 'cv2.TM_CCORR',
           'cv2.TM_CCORR_NORMED', 'cv2.TM_SQDIFF', 'cv2.TM_SQDIFF_NORMED']

for meth in methods:
    img = img2.copy()
    method = eval(meth)
    res = cv2.matchTemplate(img,template,method)
    min_val, max_val, min_loc, max_loc = cv2.minMaxLoc(res)
    if method in [cv2.TM_SQDIFF, cv2.TM_SQDIFF_NORMED]:
        top_left = min_loc
    else:
        top_left = max_loc
    bottom_right = (top_left[0] + w, top_left[1] + h)

    cv2.rectangle(img,top_left, bottom_right, 255, 2)
    cv2.imshow (meth , img)
    cv2.imshow (meth + " res" , res)

```

: TM_CCOEFF

Matching Result



Detected Point



: TM_CCOEFF_NORMED

Matching Result



Detected Point



: TM_CCORR

Matching Result



Detected Point



: TM_CORR_NORMED

Matching Result



Detected Point



: TM_SQDIFF

Matching Result




Detected Point



: TM_SQDIFF_NORMED

Matching Result



Detected Point



در مثال بالا تنها یک عدد از سوژه مورد نظر ما در تصویر وجود داشت اما اگر از سوژه ما چند عدد در تصویر باشد و ما بخواهیم همه آنها را پیدا کنیم، استفاده از تابع `minMaxLoc` مناسب نخواهد بود و از تابع `np.where()` استفاده میکنیم. با توجه به مثال زیر، این تابع پیکسل هایی که مقدارشان از ۰.۰۵ کمتر است را پیدا میکند (دقت داشته باشید با توجه به متد `TM_SQDIFF_NORMED` مقدار پیکسل های تصویر خروجی بین ۰ و ۱ است).

مثال :

```

import cv2
import numpy as np

img=cv2.imread ( "image.jpg")
tpl=cv2.imread ("template.jpg")

img_gray=cv2.cvtColor ( img , cv2.COLOR_BGR2GRAY )
tpl_gray=cv2.cvtColor ( tpl , cv2.COLOR_BGR2GRAY )

w,h,_=tpl .shape

res=cv2.matchTemplate( img_gray , tpl_gray , cv2.TM_SQDIFF_NORMED )

loc=np.where ( res<0.05)
cv2.imshow ("t" , res )

for px in zip(*loc):
    y,x=px
    px=x,y
    cv2.rectangle( img , px , (px[0]+h , px[1]+w) , (0,180,200), thickness=3)

cv2.imshow ("result" , img)

```




تشخیص دایره و خط

تشخیص خطوط


تبدیل هاف الگوریتمی است برای تشخیص اشکال در تصویر. اشکالی در تبدیل یافت می‌شوند که دارای معادلات ریاضی باشند. در این بخش به توضیح تبدیل هاف برای یافتن خطوط می‌پردازیم

Hough Line Transform : در این تبدیل خطوط به فرم $p = x \cos \theta + y \sin \theta$ نمایش داده می‌شوند. پارامتر p فاصله عمودی خط از مبدا و پارامتر θ زاویه است که خط گذرنده از مبدا و عمود بر خط مورد نظر، با محور افقی تشکیل می‌دهد. مبدا در تصویر گوشه بالا سمت چپ می‌باشد



در یک تصویر مقدار θ بین 0° تا 180° و اندازه p از 0 تا نهایت قطر تصویر می‌تواند باشد. اگر خط واسط بین مبدا و خط مورد نظر، در زیر مبدا قرار بگیرد، مقدار p یک عدد مثبت و مقدار θ بین 0° تا 180° می‌باشد اما اگر خط واسط در بالا مبدا قرار گیرد، مقدار p یک عدد منفی و مقدار θ باز هم بین 0° تا 180° خواهد بود

نحوه کار این الگوریتم به این صورت است که ابتدا یک آرایه دو بعدی ایجاد میکند که یک بعد آن نشانگر زاویه بودی و نهایتاً طولی معادل 180° دارد و بعد دیگر نشانگر پارامتر p بوده که طولش نهایتاً به اندازه قطر تصویر می‌باشد. در نتیجه هر درایه این آرایه نشانگر یک خط است، سپس تابع به ازای هر نقطه بررسی میکند که چه خطوطی از آن نقطه عبور میکنند و به هر خطی که از آن نقطه بگذرد یک امتیاز می‌دهد و اینکار نقطه به نقطه انجام می‌شود در نهایت هر خط به اندازه نقاطی که از آنها عبور میکند دارای امتیاز و اهمیت است. در آخر تابع خطوطی را که دارای امتیاز پایینی هستند را حذف، و سایر خطوط را به عنوان خط در نظر می‌گیرد.



تابع یافتن خطوط در تصویر، تابع `HoughLines()` می‌باشد

HoughLines(img , rho , theta , threshold) -> lines

Img : تصویر ورودی که بایستی باینری باشد

rho : دقت یا رزولوشن فاصله از مبدا

Theta : دقت یا رزولوشن زاویه خط عمود

Threshold : این پارامتر حداقل امتیاز خط برای آنکه یک خط در نظر گرفته شود را مشخص می‌کند. از نگاهی دیگر این پارامتر حداقل طول یک خط را مشخص میکند زیرا امتیاز یک خط همان تعداد پیکسل هایی است که از آنها می‌گذرد


خروجی این تابع یک لیست از دوتایی (rho , theta) می‌باشد که rho بر حسب پیکسل و theta بر حسب رادیان است

```
import cv2
import numpy as np

img=cv2.imread ("img.jpeg")
gray = cv2.cvtColor(img,cv2.COLOR_BGR2GRAY)
gray=cv2.blur( gray , (3,3) )
edges = cv2.Canny(gray,50,150,apertureSize = 3)
lines=cv2.HoughLines (edges , 1 , np.pi/180 , 110)

for line in lines:
    rho,theta = line[0]
    a = np.cos(theta)
    b = np.sin(theta)
    x0 = a*rho
    y0 = b*rho
    x1 = int(x0 + 1000*(-b))
    y1 = int(y0 + 1000*(a))
    x2 = int(x0 - 1000*(-b))
    y2 = int(y0 - 1000*(a))
    cv2.line(img,(x1,y1),(x2,y2),(200,50,0),2)
cv2.imshow ( "result" , img)
```

مثال :



تشخیص دوائر در تصویر

Probabilidtic Hough Line یا تبدیل هاف احتمالی، بهینه شده تبدیل هاف معمولی است که در آن به جای بررسی همه نقاط، بخشی از آنها را به صورت رندوم انتخاب و بررسی می کند. از طرفی هنگامی که امتیاز یک خط به مقدار قابل قبولی رسید، کلیه خطوط گذرنده از آن، از تصویر حذف می شوند. با توجه به موارد گفته شده، واضح است که حجم محاسبات در تبدیل هاف احتمالی کمتر است. لازم به ذکر است از آن جا که در تبدیل هاف احتمالی، همه نقاط بررسی نمی شوند، امتیاز خطوط نسبت به تبدیل هاف معمولی کمتر است و این موضوع باید در پارامتر دهی تابع مربوطه در نظر گرفته شود. تابع تشخیص خط با تبدیل هاف احتمالی HoughLinesP() می باشد.

HoughLinesP (img , rho , theta ,threshold [, Lines [, minLineLength [, maxLineGap]]) -> Lines

چهار پارامتر اول مشابه تبدیل هاف معمولی می باشد


Min Line Lenght : حداقل طول خط را بر حسب پیکسل مشخص می کند

Max Line Gap : حداکثر فاصله قابل قبول بین نقاط یک خط را مشخص می کند.

خروجی این تابع مختصات نقاط ابتدا و انتهای خط می باشد (x_1, y_1, x_2, y_2)

```
img=cv2.imread ("img.jpeg")
gray = cv2.cvtColor(img,cv2.COLOR_BGR2GRAY)
gray=cv2.blur( gray , (3,3) )
edges = cv2.Canny(gray,50,150,apertureSize = 3)
lines=cv2.HoughLinesP ( edges , 1 , np.pi/180 , 50 , minLineLength=110 ,
maxLineGap=15)

for line in lines:
    x1,y1,x2,y2=line[0]
    cv2.line(img,(x1,y1),(x2,y2),(255,0,200),3)
cv2.imshow ( "HoghP result" , img)
```



تشخیص دوائر با **Hough Circle** : دوائر را با معرفی مرکز و شعاع دایره پیدا می کند. پس برای هر دایره سه پارامتر وجود دارد.
تابع تشخیص دوائر `HoughCircles()` است

`HoughCircles ( img , method , dp , minDist [, circles [, param\ [, param۲ [,min R [, max R ]]]])`

- `Img` : تصویر باینری ورودی
- `Method` : روش جست و جو را مشخص میکند و در حال حاضر تنها روش تعریف شده `HOUGH_GRADIENT` می باشد
- `Dp` : رزولوشن `accumulator` را مشخص میکند. برای مقدار ۱ به معنی برابر بودن رزولوشن آکومولاتور با تصویر اصلی است.
- `minDist` : حداقل فاصله قابل قبول بین مراکز دایره های شناسایی شده.
- `Param۱` : این تابع در حالت `HOUGH_GRADIENT` دارای عملگر `canny` داخلی است و مقدار این پارامتر در واقع همان حد آستانه بالا برای عملگر `canny` است. حد آستانه پایین نیز به طور پیشفرض، نصف حد آستانه بالا است.
- `Param۲` : مشابه پارامتر حداقل امتیاز در تابع `HoughLine()` است
- `Min R / Max R` : به ترتیب حداقل و حداکثر مقدار شعاع را مشخص می کنند

```
img=cv2.imread ("img.jpeg")
gray = cv2.cvtColor(img,cv2.COLOR_BGR2GRAY )
gray=cv2.GaussianBlur ( gray , (9,9) , 0)
circles = cv2.HoughCircles(gray,cv2.HOUGH_GRADIENT,1,8,
param1=150,param2=150,minRadius=50,maxRadius=230)

circles = np.uint16(np.around(circles))
for circ in circles:
    x,y,r=circ[0]
    cv2.circle(img,(x,y),r,(200,0,0),5)
    cv2.circle(img,(x,y),2,(0,0,255),5)

cv2.imshow('detected circles',img)
```

مثال :



الگوریتم آبگیر یا watershed

این الگوریتم برای جدا سازی نواحی مختلف همگن از یکدیگر است. برای مثال در تصویر سکه روی یک میز، ناحیه های همگن مختلف که در این جا سکه و میز است را قطعه بندی می کند. این الگوریتم بر اساس ریخت شناسی است. این الگوریتم بر پایه یک تصویر marker کار می کند. تصویر مارکر یک تصویر 32 بیتی علامت دار و هم اندازه تصویر اصلی می باشد. در این تصویر به پیکسل هایی که مطمئنیم به یک ناحیه تعلق دارند یک مقدار یکسان غیر صفر (مثلا 2000) می دهیم و برای نواحی مختلف، مقادیر مختلف در نظر می گیریم. مثلا در مثال بالا به نواحی که مطمئنیم متعلق به سکه هستند مقدار 255 و به نواحی که مطمئنیم متعلق به میز هستند مقدار 127 می دهیم. سپس با دادن مارکر و تصویر اصلی به این الگوریتم، این الگوریتم درباره سایر نواحی تصمیم گیری میکند که متعلق به کدام ناحیه هستند. تابع این الگوریتم watershed() است. خروجی این تابع مارکر جدیدی است که همه نواحی را پوشش می دهد و همچنین به لبه ها برچسب 1- اختصاص می دهد

Watershed(img , markers)

```

import numpy as np
import cv2
from matplotlib import pyplot as plt

img = cv2.imread('coins.jpg')

gray = cv2.cvtColor(img,cv2.COLOR_RGB2GRAY )
_,thresh = cv2.threshold(gray,150,255,cv2.THRESH_OTSU + cv2.THRESH_BINARY_INV )

cv2.imshow ("gray coins" , gray)
cv2.imshow ("bin coins" , thresh)

# noise removal
kernel = np.ones((3,3),np.uint8)
opening = cv2.morphologyEx(thresh,cv2.MORPH_OPEN,kernel, iterations = 2)

cv2.imshow ("openin thresh coins" , opening )

# sure background area
sure_bg = cv2.dilate(opening,kernel,iterations=1)
cv2.imshow ("shure background" , sure_bg)


# Finding sure foreground area
kernel =cv2.getStructuringElement (cv2.MORPH_ELLIPSE ,(9,9) )
sure_fg = cv2.erode (opening,kernel,iterations=5)
cv2.imshow ("shure forcground" , sure_fg)

# Finding unknown region
unknown = cv2.subtract(sure_bg,sure_fg)
cv2.imshow ("unknown area" , unknown)

#markers=np.zeros ((312,252),np.int32)
#markers [sure_fg==255]=5
ret, markers = cv2.connectedComponents(sure_fg)
markers = markers+1
markers[unknown==255] = 0

markers = cv2.watershed(img ,markers)
img[markers == -1] = [255,0,0]
cv2.imshow ("img " , img)

```



در مثال بالا ابتدا تصویر را به فضای رنگ خاکستری برده‌ایم. سپس یک **threshold** روی آن اعمال کردیم تا یک تصویر باینری بدست آید. سپس برای رفع نویز احتمالی، یک عملگر **opening** روی آن اعمال کردیم. سپس برای بدست آوردن ناحیه پس‌زمینه و اطمینان از اینکه هیچ ناحیه‌ای از سکه‌ها، جز پس‌زمینه نباشند، با عملگر **dilate** آن را گسترش دادیم. سپس برای بدست آوردن ناحیه سکه‌ها و اطمینان از اینکه هیچ ناحیه‌ای از پس‌زمینه، جز سکه‌ها نباشد به کمک عملگر **erode** آنرا فرسایش دادیم. سپس برای بدست آوردن ناحیه نامعلوم، این دو تصویر را از هم کم کردیم. حال نوبت به تعریف **marker** می‌رسد. در اینجا تابع **connectedComponents()** بر اساس ورودی آن که تصویر **sure_fg** است یک مارکر تعریف می‌کند. خروجی دیگر این تابع که **ret** است، تعداد نواحی را بر میگرداند. (در اینجا می‌توان به جای تعریف تابع یک آرایه تعریف کرد و آرایه‌های آن را مقدار دهی کرد که این دوخط در بالای فراخوانی تابع، به صورت کامنت درآمده‌اند). از طرفی میدانیم پیکسل‌هایی که برجسبشان صفر است، ناحیه نامعلوم به حساب می‌آیند. از این رو کل **markers** را با مقدار 1 جمع می‌کنیم و پیکسل‌هایی که در تصویر **unknown** میدانیم جز ناحیه نامعلوم هستند. مقدار برجسبشان را صفر می‌کنیم. و سپس الگوریتم آبگیر را اجرا می‌کنیم. در نهایت پیکسل‌هایی از تصویر که برجسبشان 1- است (لبه‌ها) را قرمز می‌کنیم تا نواحی معلوم گردند.

الگوریتم Grab Cut

هدف از این الگوریتم جداسازی تصویر پیش زمینه از پس زمینه می‌باشد. روش کارکرد این الگوریتم به این صورت است که در ابتدا یک مستطیل اطراف تصویر پیش زمینه رسم می‌کنیم تا تصویر پیش زمینه به طور کامل درون آن قرار گیرد. سپس با اجرای الگوریتم با یک تعداد تکرار معین تصویر پیش زمینه شناسایی می‌گردد. اما در برخی موارد ممکن است که بخش هایی از پس زمینه به عنوان پیش زمینه انتخاب شده باشند یا بر عکس. در این موارد کاربر باید یک تصویر ماسک ایجاد کند و در آن بخش هایی از نواحی که باید به عنوان پس زمینه تشخیص داده می‌شدند اما به عنوان پیش زمینه شناسایی شدند را با رنگ مشکی و بخش هایی از نواحی که به عنوان پیش زمینه باید تشخیص داده می‌شدند اما به عنوان پس زمینه شناسایی شدند را با پیکسل سفید نشانه گذاری نماید تا الگوریتم آن نواحی را تصحیح نماید.

برای درک بهتر به تصویر زیر توجه نمایید که در تصویر سمت چپ با رسم یک مستطیل اطراف پیش زمینه و نشانه گذاری در نواحی که دچار تشخیص اشتباه شده اند؛ تصویر راست را خروجی می‌دهد که در آن پیش زمینه به طور کامل جدا شده است.



تابع پیاده سازی این الگوریتم `grabCut()` است.

`grabCut ( imag , mask , rect, bgd model , fgd mode, itrations , type)`

`image` : تصویر ورودی

Mask : ماسکی که در آن مشخص میکنیم کدام نواحی به طور حتم جزو پیش زمینه یا پس زمینه هستند و یا نواحی که احتمالا جزو پیش زمینه یا پس زمینه هستند و... . که این موارد را با پرچم های زیر و یا اعداد 0 و 1 و 2 و 3 مشخص می‌کنیم.

`cv.GC_BGD (0) , cv.GC_FGD (1), cv.GC_PR_BGD (2) , cv.GC_PR_FGD (3)`

rect : مستطیلی که دور پیش زمینه رسم می‌شود و با فرمت `(x,y,w,h)` می‌باشد.

Bgd model-fgd model: دو آرایه که در درون الگوریتم مورد استفاده قرار می‌گیرند و شما آنها را به طور پیشفرض با نوع `np.float64` و ابعاد `(1,65)` و درایه ای صفر، تعریف کنید.

Iteration: تعداد تکرار الگوریتم را مشخص می‌نماید

Type: این پارامتر مشخص می‌کند که اجرای این الگوریتم مبتنی بر قاب مستطیلی، ماسک نشانه گذاری شده یا هردو باشد. این موارد با پرچم‌های زیر مشخص می‌شود.

, Or Both of them , cv.GC_INIT_WITH_MASK cv.GC_INIT_WITH_RECT

این تابع پس از اجرا `mask` ورودی را به عنوان خروجی اصلاح می‌کند و در ماسک خروجی به هر پیکسل یک عدد با پرچم‌هایی که پیش از در پارامتر `mask` توضیح داده شده است می‌دهد

مثال: در مثال زیر ما ابتدا یک مستطیل اطراف پیش‌زمینه ایجاد می‌کنیم به طوریکه پیش‌زمینه را به‌طور کامل در بر بگیرد. سپس ایم مستطیل را به عنوان پارامتر را به تابع می‌دهیم و پارامتر نوع عملکرد الگوریتم را مبتنی بر قاب مستطیلی می‌دهیم. سپس این الگوریتم `mask` ورودی را اصلاح میکند. سپس ما به پیکسل‌هایی که مقدار `0` و `2` دارند مقدار `0` (رنگ سیاه) و به پیکسل‌هایی که مقدار `1` و `3` دارند مقدار `255` (رنگ سفید) اختصاص می‌دهیم و یک ماسک برای تصویر پیش‌زمینه می‌سازیم و با `and` کردن این ماسک با تصویر اصلی، پیش‌زمینه را جدا می‌کنیم.

```
import cv2
import numpy as np

img=cv2.imread("panda1.jpg")


mask = np.zeros(img.shape[:2],np.uint8)
bgdModel = np.zeros((1,65),np.float64)
fgdModel = np.zeros((1,65),np.float64)
rect = (70,5 , 380 , 585)

img_rec=img.copy ()
img_rec=cv2.rectangle (img_rec, (70,5), (450,590) , (255,0,0))
cv2.imshow ("img whit rect", img_rec)

cv2.grabCut ( img , mask , rect , bgdModel , fgdModel , 5 , cv2.GC_INIT_WITH_RECT)

#mask2 = np.zeros(img.shape[:2],np.uint8)
#mask2[ mask== 1 ]=255
#mask2[ mask==3]=255
mask2 = np.where((mask==2)|(mask==0),0,255).astype('uint8')

img_cut=cv2.bitwise_and (img , img , mask=mask2)
cv2.imshow ("image Cut", img_cut)
```



در تصویر بالا نتیجه تا حد زیادی قابل قبول است اما در برخی قسمت ها تشخیص درست صورت نگرفته است و نیاز است که با استفاده از یک ماسک آن ها را اصلاح کنیم. ما برای ساخت ماسک از فتوشاپ کمک گرفته ایم. به این صورت که بخش هایی که متعلق به پیش زمینه بودند اما حذف شده اند را سفید، بخش های متعلق به پس زمینه که حذف نشده اند را سیاه و سایر بخش ها را خاکستری میکنیم سپس با استفاده از این تصویر یک ماسک برای استفاده در `grabCut()` مطابق مثال زیر ایجاد میکنیم.

تذکر : در مثال بالا با افزایش تعداد تکرار تابع به ۱۰ باز، به نتیجه مطلوب رسیدیم که البته حجم پردازش بسیار زیاد گشت

```

import cv2
import numpy as np

img=cv2.imread("panda1.jpg")

mask = np.zeros(img.shape[:2],np.uint8)
bgdModel = np.zeros((1,65),np.float64)
fgdModel = np.zeros((1,65),np.float64)

rect = (70,5 , 380 , 585)

cv2.grabCut ( img , mask , rect , bgdModel , fgdModel , 5 , cv2.GC_INIT_WITH_RECT)

mask2 = np.where((mask==2)|(mask==0),0,255).astype('uint8')

img_cut=cv2.bitwise_and (img , img , mask=mask2)

#####
#                               mask                               #
#####
mask_img=cv2.imread("mask.jpg",0)

mask [ mask_img==255]=1
mask [ mask_img==0]=0


cv2.grabCut ( img , mask , None , bgdModel , fgdModel , 5 , cv2.GC_INIT_WITH_MASK )

mask2 = np.where((mask==2)|(mask==0),0,255).astype('uint8')

img_cut=cv2.bitwise_and (img , img , mask=mask2)
cv2.imshow ("image Cut by Mask", img_cut)

```

مثال کد مثال قبل را به صورت زیر تکمیل نمودیم. تصویر سمت چپ، تصویر ماسکی است که با طراحی کردیم:



درک ویژگی‌های یک تصویر و تطابق دو تصویر

درک ویژگی‌های یک تصویر

بسیاری از شما بازی پازل را انجام داده‌اید. در پازل ما قطعه‌های کوچک یک تصویر را به یکدیگر متصل می‌کنیم و یک تصویر واحد می‌سازیم. اما چگونه ما اینکار را انجام می‌دهیم. چگونه میتوان این تئوری را روی کامپیوتر پیاده سازی کرد و مثلاً تعداد تصویر از یک منطقه طبیعی را به کامپیوتر بدهیم تا یک تصویر کامل و واحد از آن منظره ایجاد کند یا تعداد تصویر از یک ساختمان به کامپیوتر بدهیم و کامپیوتر تصویر ۳D از آنها بدست آورد. ما ابتدا باید به این سوال پاسخ دهیم که چگونه ما قطعه‌های یک پازل را بهم متصل می‌کنیم؟

در پاسخ باید گفت که ما در تصویر به دنبال ویژگی‌ها و الگوهای منحصر به فرد هستیم که به راحتی بتوان آنها را ردیابی و مقایسه کرد. ما به راحتی این ویژگی‌ها را درک می‌کنیم با اینکه ممکن است توصیف آنها در کلمات برایمان دشوار باشد اگر از ما بخواند تا در بین چند تصویر، ویژگی بیایم که بتوان به کمک آن، آنها را باهم مقایسه کرد، به راحتی اینکار را انجام می‌دهیم. در واقع ما در یک پازل ویژگی‌های یک قطعه را شناسایی می‌کنیم و ویژگی‌های مشابهی را در تصویر دیگر پیدا می‌کنیم و بر این اساس آن قطعات را در کنار هم قرار می‌دهیم. توضیح اینکه ما چگونه این ویژگی‌ها را شناسایی می‌کنیم سخت است زیرا این ویژگی ذاتی ما است. اما اگر ما به طور عمیق به تعداد تصویر نگاه کنیم و برای آنها به دنبال الگو باشیم به نتیجه جالبی خواهیم رسید.


برای مثال به تصویر زیر نگاه کنید و سعی کنید محل دقیق ۶ تکه مشخص شده را در تصویر بیابید



قطعات A و B متعلق به یک سطح هستند و در نواحی زیادی گسترش یافته اند. از این رو پیدا کردن محل دقیق آنها مشکل است.

پیدا کردن قطعات C و D بسیار ساده است. این قطعات متعلق به لبه‌های ساختمان هستند اما باز هم پیدا کردن محل دقیق آنها مشکل است زیرا در امتداد لبه این تکرار شده اند. پس آن‌ها را می‌توان به عنوان یک ویژگی خوب در نظر گرفت اما باز هم به اندازه کافی خوب نیستند

در نهایت قطعات E و F متعلق به گوشه‌ها هستند و به راحتی می‌توان محل دقیق آن‌ها را مشخص کرد. زیرا منحصر به فرد هستند. از این رو آنها را میتوان به عنوان یک ویژگی خوب در نظر گرفت .



به تصویر بالا نگاه کنید. قطعه آبی متعلق به سطح است و یافتن محل دقیق آن دشوار است. زیرا هرچه آنرا حرکت دهیم به نظر همان است. همچنین قطعه مشکی متعلق به لبه ها است و یافتن آن ساده تر است. این قطعه را اگر به صورت عمودی حرکت دهیم به راحتی تغییر را میتوان فهمید اما با این حال با حرکت افقی این قطعه تغییری حس نخواهد شد. اما قطعه قرمز متعلق به گوشه است و با هر حرکتی میتوان تغییر آن را متوجه شد و منحصر به فرد است. از این رو گوشه های یک تصویر ویژگی خوبی هستند. پس ما توانستیم ویژگی خوبی برای شناسایی بیابیم.

پس ما ویژگی های خوب را درک کردیم. بخش هایی از تصویر، نظیر گوشه ها که بتوان با کوچکترین حرکت، تغییر در آن ها را حس کرد. هنگامی که ما ویژگی های یک تصویر را درک کردیم باید به دنبال ویژگی های مشابه در تصاویر دیگر باشیم. در واقع ما یک ناحیه اطراف آن ویژگی را در نظر میگیریم و آن را توصیف میکنیم. مثلاً "قسمت بالا آبی آسمان است، قسمت پایینی ساختمان است که دارای نمای شیشه ای بوده و..." و ما همان منطقه را در تصاویر دیگر جست و جو می کنیم. این همان کاری است که کامپیوتر باید انجام دهد. یعنی توصیف منطقه اطراف یک ویژگی و جست و جو آن در تصاویر دیگر. اینکار شرح ویژگی یا **description feature** نام دارد.

پس هدف از این بخش، یافتن ویژگی های یک تصویر، توصیف آنها، مقایسه آن ها در تصاویر دیگر و ... است. تا بر اساس آن بتوان کارهایی از قبیل یافتن یک شی در یک تصویر را نسبت به هم، تناظر یابی دو تصویر و... را انجام داد

تشخیص گوشه های تصویر با الگوریتم هریس

برای تشخیص گوشه از تشخیص گوشه هریس استفاده می شود. در این الگوریتم با حرکت یک قاب کوچک، میانگین شدت روشنایی پیکسل های درون آن اندازه گیری می شود. اگر این مقدار با حرکت جزئی، تغییرات شدید داشته باشد متعلق به لبه یا گوشه هستند. حال اگر این تغییرات در بیش از یک جهت (عمودی و افقی) شدید باشند، آن ناحیه متعلق به یک گوشه است. تابع تشخیص گوشه هریس `cornerHarris()` می باشد.

`cornerHarris( img , block size , ksize , k ) ->dst`

img : تصویر ورودی که باید خاکستری بوده و نوع درایه های آن باید float32 باشد

Block Size : محدوده پیکسل های همسایه گوشه را مشخص می کند

Ksize : پارامتری برای مشتقات سوبل

K : یک پارامتر آزاد در معادله تشخیص هریس . مقدار آن معمولا بین ۰ تا ۰.۵ است



تصویر خروجی یک تصویر خاکستری از محل گوشه های تصویر ورودی است.

```
import cv2
import numpy as np

img=cv2.imread ( "chess.jpg")
gray=cv2.cvtColor (img , cv2.COLOR_BGR2GRAY)
gray= np.float32 (gray)
dst=cv2.cornerHarris( gray , 3 , 3, 0.04)


#for increas corner Area
dst = cv2.dilate(dst,None)

img[ dst > 0.1 * dst.max()] = [255,0,0]
cv2.imshow( " detect Corner " , img)
```



یافتن گوشه ها با الگوریتم shi_tomasi

این الگوریتم با ایجاد تغییراتی در الگوریتم هریس، به وجود آمده است و بهبود یافته الگوریتم هریس می باشد.



با توجه به تصویر بالا اگر λ_1 و λ_2 (تغییرات میانگین روشنایی با جابه جایی تصویر در جهت عمودی و افقی) هر دو از λ_{min} بیشتر شوند آن قسمت یک گوشه است (بخش سبز) و اگر تنها یکی از آنها از λ_{min} بیشتر باشد آن بخش متعلق به لبه است (بخش نارنجی) و اگر هر دو کوچک تر باشند آن بخش متعلق به یک سطح است (بخش خاکستری)

تابع مربوطه در open cv تابع `goodFeaturesToTrack()` است

`goodFeaturesToTrack( img ,max corners , qualityLevel , minDistance ) -> corners`

- `img` : تصویر ورودی که باید خاکستری باشد و نوع آن `uint8` و یا `float32` باشد
- `Max corners` : حداکثر تعداد گوشه ها که تابع باز میگرداند را مشخص میکند. اگر تعداد گوشه های تصویر بیشتر از این مقدار باشد، تابع تنها گوشه های با کیفیت و اهمیت بالا را باز می گرداند
- `qualityLevel` : حداقل کیفیت قابل قبول برای آنکه یک نقطه به عنوان گوشه در نظر گرفته شود را مشخص می کند. این پارامتر عددی است بین ۰ و ۱ که این مقدار در ماکزیمم کیفیت موجود ضرب می شود و حداقل کیفیت قابل قبول را تولید می کند. برای مثال اگر ماکزیمم کیفیت ۲۰۰۰ و مقدار پارامتر ۰.۰۱ باشد، نقاطی که کیفیتشان کمتر از ۲۰ باشد حذف می شوند.
- `MinDistance` : حداقل فاصله قابل قبول بین گوشه

خروجی این تابع لیستی از مختصات گوشه های تصویر است که هر سطر شامل یک آرایه با دو درایه x, y است

```

import cv2
import numpy as np

img=cv2.imread("cube.jpg")
gray=cv2.cvtColor( img , cv2.COLOR_BGR2GRAY)

#delete noise
gray =cv2.GaussianBlur (gray , (3,3) , 0)


corners=cv2.goodFeaturesToTrack( gray , 60 , 0.05 , 20 )

for corner in corners:
    x,y=corner[0]
    img2=cv2.circle ( img , (x,y) , 5 , (100,0,200), thickness=-1 )

cv2.imshow( "corners image " , img2)


```

مثال :



الگوریتم SIFT

در بخش قبل آموختیم که چگونه گوشه‌های یک تصویر را استخراج نماییم. هدف از یافتن گوشه‌ها بدست آوردن ویژگی از تصویر بود تا از طریق آن بتوانیم تصاویر مختلف را تطبیق دهیم و یا عملیات‌های دیگر. گوشه‌ها مستقل از چرخش تصویرند به این مفهوم که اگر یک تصویر را بچرخانیم باز همان گوشه‌هایی را خواهیم یافت که در تصویر بدون چرخش پیدا نموده ایم و این مطلوب ما است. اما ویژگی گوشه‌ها نسبت به تغییر ابعاد مستقل نیست و اگر روی یک تصویر بزرگ نمایی یا کوچک نمایی اعمال کنیم ممکن است گوشه‌های یافت شده نسبت به تصویر اصلی متفاوت باشند. برای درک بهتر این موضوع به تصویر زیر توجه فرمایید



در تصویر سمت چپ ما یک گوشه تشخیص می‌دهیم اما در تصویر سمت راست که بزرگ‌نمایی شده است، ما تنها لبه تشخیص می‌دهیم و گوشه یافت نمی‌شود زیرا لازم است تا ابعاد قاب جست و جو نیز بزرگ‌نمایی شوند. تا ویژگی‌ها همسان درک شوند. پس ما نیازمند الگوریتمی هستیم که ویژگی‌های یک تصویر یا دقیق‌تر بگوییم، توصیف ویژگی‌های یک تصویر را مستقل از اندازه، چرخش، زاویه دید، روشنایی و... استخراج نماید. الگوریتم SIFT نیز به همین منظور طراحی شده است. کارکرد این الگوریتم استخراج ویژگی‌های تصویر می‌باشد که علاوه بر یافتن نقاط کلیدی یا همان **keypoint** های تصویر، یک بردار توصیف یا **Descriptor** برای هر کدام از این نقاط تعریف می‌کند. که می‌توان به کمک آن، نقاط کلیدی دو تصویر را یک به یک نسبت به هم بررسی نمود و اگر بردار توصیف آنها به هم نزدیک بود این دو نقطه را تطبیق داد. برای درک بهتر به تصویر زیر توجه فرمایید



در تصویر بالا نقاط کلیدی هر دو عکس بررسی شده و نقاطی را که با هم تطبیق داشتند (بردار توصیفشان تقریباً برابر بوده)، با یک خط به هم وصل شدند.

الگوریتم SIFT شامل ۵ مرحله به صورت زیر است

- ۱- پیدا کردن **keypoint** ها بر اساس مقیاس بندی های مختلف
- ۲- پیدا کردن محل دقیق این نقاط کلیدی
- ۳- تعریف یک بردار جهت برای هر نقطه کلیدی
- ۴- تعریف یک بردار توصیف برای هر نقطه کلید بر اساس بردار جهت مورد ۳
- ۵- تطبیق نقاط کلیدی

برای استفاده از ماژول مربوطه باید ماژول **opencv-contrib** نصب باشد این ماژول از نسخه ۳ دیگر همراه **opencv** ارائه نمیشود. برای نصب آن کافی است یکی از دو دستور زیر را در **CMD** ویندوز وارد کنید.

Pip install opencv-contrib-python

Pip install opencv-contrib-python-headless

در صورتی که خطای **permtion** داد، کافی است عبارت **--user** را پس از کلمه **install** در دستورات بالا قرار دهیم.

تذکر : نکته مهمی که باید بدان توجه داشت غیر رایگان بودن الگوریتم های **SURF** و **SIFT** است و در کاربرد های تجاری استفاده از آن ها نیازمند مجوز می باشد

برای استفاده از الگوریتم SIFT ابتدا باید یک شی SIFT از کلاس SIFT_creat از ماژول xfeatures2d ایجاد نمود. سپس با کمک تابع detect() از همان کلاس keypoint های تصویر را استخراج می‌نماییم. همچنین تابع دیگری نیز در این ماژول با نام detectAndCompute() موجود است که علاوه بر یافتن نقاط کلیدی، توصیفگر نیز برای آنها باز میگرداند.

detect (image [, mask]) -> keypoints

image : تصویر ورودی که باید از نوع خاکستری باشد.

Mask : پارامتر ماسک در صورتی که بخواهیم بخشی از تصویر را بررسی کنیم

خروجی این تابع نقاط کلید تصویر است. هر نقطه کلیدی یا keyPoint دارای یک ساختار خاص است که ویژگی های بسیاری نظیر مختصات نقطه ، زاویه جهت گیری، محدوده پیکسل های همسایه و... را مشخص میکند.

برای نمایش keypoint های یافته شده از تابع drawKeypoints() استفاده می‌شود

out image drawKeypoint (image , KeyPoints , out imgel [, color [, flags]]) ->

image : تصویر ورودی

Keypoint : نقاط کلیدی مورد نظر که همان خروجی تابع detect() است

Out image : تصویر خروجی

Color : رنگ keypoint ها را مشخص میکند و اگر ۱- باشد برای هر keypoint یک رنگ رندوم در نظر می‌گیرد.

Flags : این پارامتر میتواند دارای مقادیر زیر باشد

۱- DRAW_MATCHES_FLAGS_DRAW_DEFAULT : حالت پیشفرض بوده و با فراخوانی این پرچم برای تصویر

خروجی (مقدار بازگشتی) یک ماتریس جدید تعریف می‌شود و تصویر نهایی در آن ریخته می‌شود

۲- DRAW_MATCHES_FLAGS_DRAW_OVER_OUTIMG : با فراخوانی این پرچم، تصویر خروجی در همان

پارامتر ورودی out image ذخیره می‌شود. در این حالت اگر پارامتر وردی مذکور تصویری رنگی باشد، خروجی نیز

رنگی خواهد بود

۳- DRAW_MATCHES_FLAGS_DRAW_RICH_KEYPOINTS : با فراخوانی این پرچم، نقاط کلیدی را با یک

دایره به اندازه محدوده همسایگی و جهتشان رسم میکند. در غیر این صورت keypoint ها تنها با یک دایره تو خالی

نمایش داده می‌شوند

۴- DRAW_MATCHES_FLAGS_NOT_DRAW_SINGLE_POINTS : با این پرچم تابع نقاط کلیدی تکی را رسم

نمی‌کند. کاربرد اصلی آن در تابع رسم تطابق ها است که فقط نقاطی را که باهم تطابق دارند را نشان می‌دهد

```
import cv2

img=cv2.imread("bulding.jpg")
gray=cv2.cvtColor( img , cv2.COLOR_BGR2GRAY)

sift=cv2.xfeatures2d .SIFT_create ()
keyPoint=sift.detect ( gray , None)
outimg=cv2.drawKeypoints(gray,keyPoint,img)

cv2.imwrite('sift_keypoints.jpg',outimg)
```

مثال :



مثال :

```
import cv2

img=cv2.imread("bulding.jpg")
gray=cv2.cvtColor( img , cv2.COLOR_BGR2GRAY)

sift=cv2.xfeatures2d .SIFT_create ()
keyPoint=sift.detect ( gray , None)
outimg=cv2.drawKeypoints(gray,keyPoint,img , flags=cv2.DRAW_MATCHES_FLAGS_DRAW_RICH_KEYPOINTS)

cv2.imwrite('sift_keypoints.jpg',outimg)
```



الگوریتم SURF

الگوریتم SIFT زمان زیادی برای اجرا صرف میکند. در سال ۲۰۰۶ الگوریتم دیگری با نام SURF با همان عملکرد SIFT ولی با سرعتی به مراتب بیشتر طراحی شد. این الگوریتم همانند الگوریتم SIFT می‌باشد که سرعت اجرای آن بالاتر می‌باشد هزینه این سرعت بالا در کاهش دقت می‌باشد که عموماً قابل چشم پوشی است. الگوریتم SIFT همانند یک آشکار ساز لکه است. برای استفاده از این الگوریتم ابتدا باید یک شی از کلاس SURF از ماژول `xfeatures2d` ایجاد نمود. ورودی های متد سازنده این کلاس به صورت زیر است

`SURF_creat ( [hessianThreshold [, nOctaves [, nOctaveLayers [, extended [, upRights]]]] )`

hessianThreshold : پارامتر مقدار آستانه که حداقل میزان اهمیت را برای اینکه یک نقطه به عنوان **keyPoint** در نظر گرفته شود را مشخص می‌کند و هرچه این عدد افزایش یابد تعداد نقاط کلیدی کم خواهد شد. مقداری بین ۳۰۰ تا ۵۰۰ می‌تواند مقدار پیشفرض خوبی باشد.

nOctaves : مقدار این پارامتر به طور پیشفرض برابر ۴ است. اگر مقدار آن افزایش یابد، الگوریتم ویژگی های بزرگتر را می یابد و اگر کوچک تر باشد، الگوریتم تنها ویژگی های کوچک را می یابد

nOctaveLayers : تعداد لایه های در هر هرم گاوسی را مشخص میکند و مقدار پیشفرض آن ۲ است.

Extended : اگر این پارامتر ۰ باشد توصیف گر برای هر نقطه کلیدی به صورت ۶۴ عنصری و اگر ۱ باشد ۱۲۸ عنصری خواهد بود

upRights : اگر این پارامتر ۰ باشد الگوریتم **keyPoint** ها را به همراه زاویه جهت گیرشان مشخص میکند و اگر ۱ باشد آنها را بدون جهت گیری می یابد. در تصاویری که تغییر زاویه کم است با ۱ کردن این پارامتر می توان سرعت اجرا را تا حد زیادی افزایش داد

معرفی توابع کلاس **SURF_creat** :

getExtended() -> bool retVal / **setExtended(bool extend)**

getHessianThreshold() -> double retVal / **setHessianThreshold(double thresh)**

getNOctaveLayers() -> int retVal / **setNOctaveLayers(int nOctaveLayers)**

getNOctaves() -> int retVal / **setNOctaves(int nOctaves)**

getUpright() -> bool retVal / **setUpright(bool upright)**

کلیه توابع بالا به ترتیب برای دریافت و تغییر پارامتر مربوطه مورد استفاده قرار می گیرند

برای تشخیص **keyPoint** ها و ارایه توصیفگر برای آنها از تابع **detectAndComput()** استفاده می کنیم. تفاوت این تابع با تابع **detect()** آن است که علاوه بر یافتن نقاط کلیدی، توصیف گر نیز برای آنها ارایه می دهد

detectAndComput (image , mask) -> keyPoints , Descriptors

- **image** : تصویر ورودی که باید یک تصویر خاکستری باشد.
- **Mask** : ماسک در صورتی که بخواهیم تنها بخشی از عکس را بررسی کنیم.

این تابع دارای دو خروجی است. خروجی اول **keyPoint** ها و خروجی دوم **Descriptor** یا توصیفگر آنها می باشد.

برای رسم **keyPoint** ها از همان تابع **drawKeypoints()** که در بخش الگوریتم **SIFT** معرفی کردیم، استفاده می کنیم.

مثال :

```
import cv2
from matplotlib import pyplot as plt

img=cv2.imread ("img.jpg" , 0)
outimg=img.copy ()

surf=cv2.xfeatures2d .SURF_create (6000)
kp , des =surf.detectAndCompute( img , None)

outimg=cv2.drawKeypoints ( img , kp , outimg , flags=cv2.DRAW_MATCHES_FLAGS_DRAW_RICH_KEYPOINTS)

plt.imshow( outimg)
plt.show()
```



در مثال بالا ابتدا حد آستانه SURF را روی ۴۰۰ تنظیم کردیم و تعداد نقاط (با تابع len()) ۱۶۰۰ عدد بدست آمد. از این رو تصویر خروجی بشدت شلوغ بود و برای استفاده در این آموزش نا مناسب بود. از این رو مقدار حد آستانه را به ۶۰۰۰ افزایش دادیم و تعداد keypoint ها به ۷۹ عدد کاهش یافت.

مثال :

```
import cv2
from matplotlib import pyplot as plt

img=cv2.imread ("img.jpg" , 0)
outimg=img.copy ()

surf=cv2.xfeatures2d .SURF_create (7000)
surf.setUpright (True)

kp , des =surf.detectAndCompute( img , None)
outimg=cv2.drawKeypoints ( img , kp , outimg , flags=cv2.DRAW_MATCHES_FLAGS_DRAW_RICH_KEYPOINTS)

plt.imshow( outimg)
plt.show()

print (" kp len=" , len(kp))
print ("des shape=" , des.shape)
```




همان گونه که مشخص است، در مثال بالا با true کردن upright، نقاط کلیدی بدون جهت گیری یافت شدند.

```
>>> kp len = 50
>>> des shape = (50 , 64)      # 64 elements
```

الگوریتم FAST

الگوریتم های ارایه شده در بخش های قبلی بسیار مفید و کارآمد بودند اما به اندازه کافی سریع نبودند . در کاربرد هایی که سرعت محاسبات محدود است، میتواند ما را با مشکل مواجه کند. در سال ۲۰۰۶ الگوریتمی برای تشخیص گوشه ها با نام FAST ارایه

شد که دارای سرعت بالا است. این الگوریتم در سال ۲۰۱۰ تا حدی اصلاح شد. در این الگوریتم برای تشخیص یک نقطه به عنوان گوشه ابتدا یک دایره با شعاع مشخص به مرکز نقطه مذکور رسم می‌کنیم. حال اگر کمائی به طول حداقل $\frac{3}{4}$ متشکل از پیکسل های روی محیط این دایره وجود داشته باشد به طوریکه همه آنها به مقدار زیادی از پیکسل مرکزی بیشتر یا کمتر باشند، آن نقطه به عنوان گوشه یا نقطه کلیدی در نظر گرفته می‌شود. برای سرعت بخشیدن به این عملیات ابتدا چهار پیکسل با زاویه ۹۰ درجه روی محیط دایره انتخاب می‌شوند و اگر حداقل سه تای آنها اختلافشان با پیکسل مرکزی زیاد نباشد آن نقطه گوشه نبوده و به سراغ پیکسل بعدی می‌رویم. برای درک بهتر موضوع به تصویر زیر توجه نمایید.



در تصویر بالا پیکسل p ، نقطه مورد بررسی ما است و ما یک دایره به طول ۱۶ پیکسل حول آن در نظر می‌گیریم. مقدار آستانه را t و مقدار روشنایی پیکسل مرکزی را ip در نظر بگیرید. حال اگر $\frac{3}{4}$ این ۱۶ پیکسل، یعنی ۱۲ پیکسل، مقدار روشنایشان همه بیشتر از $ip+t$ یا کمتر از $ip-t$ باشد، این نقطه به عنوان گوشه در نظر گرفته می‌شود. در آزمون سرعتی، پیکسل های ۱،۵،۹،۱۳ را بررسی میکنیم اگر حداقل ۳ تا از آنها روشن تر $ip+t$ یا تیره تر از $ip-t$ نباشند، آن نقطه گوشه نیست.

برای پیاده سازی این الگوریتم مانند الگوریتم های قبل ابتدا یک شی FAST ایجاد می‌کنیم. پارامترهای متد سازنده این کلاس به صورت زیر است

`FastFeatureDetector_create( [ , threshold [ , nonmaxSuppression [ ,type ] ] ] )`

Threshold : آستانه تفاوت میان شدت شدت روشنایی پیکسل مرکزی و پیکسل های روی محیط دایره. مقدار پیشفرض برای پارامتر برابر ۱۰ است

nonmaxSuppression : یک مقدار منطقی است برای سرکوب غیر حداکثر، که اگر True باشد، تابع از میان نقاط تشخیص داده شده برای هر گوشه، بهترین آنها را انتخاب و بقیه را حذف میکندو اگر false باشد همه آن نقاط را باز می‌گرداند. مقدار این تابع در حالت پیشفرض True است

type : یکی از سه حالت زیر می‌تواند باشد

FAST_FEATURE_DETECTOR_TYPE_5_8 -۱

FAST_FEATURE_DETECTOR_TYPE_۷_۱۲ -۲

FAST_FEATURE_DETECTOR_TYPE_۹_۱۶ -۳

معرفی برخی توابع کلاس **FAST** :

/ setThreshold(int threshold) ۱-getThreshod()

۲-getNonmaxSuppression() / setNonmaxSuppression(bool NonmaxSuppression)

۳-getType() / setType()

```
import cv2
from matplotlib import pyplot as plt

img=cv2.imread ( "shape.jpg")
gray=cv2.cvtColor( img , cv2.COLOR_BGR2GRAY)

fast=cv2.FastFeatureDetector_create()
kp=fast .detect( gray , None)
gray=cv2.drawKeypoints(gray , kp , None , (0,0,255))

plt.imshow ( gray)
plt .show ()

print("point number" , len(kp))
print(" fast Th" , fast.getThreshold () )
print(" fast NonmaxSuppression " , fast.getNonmaxSuppression () )
print(" fast Type" , fast.getType () )
```

این توابع به ترتیب برای دریافت و یا تغییر مقدار پارامتر مربوطه است.



BRIEF

همان طور که در بخش های قبلی ملاحظه نمودید الگوریتم SIFT از یک توصیفگر ۱۲۸ تایی استفاده می کند. هر کدام از این مقادیر یک داده float است از این رو حجم توصیفگر برای هر نقطه ۵۱۲ بایت خواهد بود و این می تواند برای هزاران ویژگی، حجم زیادی اشغال کند. الگوریتم SURF نیز حداقل از توصیفگر ۶۴ تایی استفاده میکند که حافظه ای معادل با ۲۵۶ بایت برای هر یک اشغال می کند. مشخصا بررسی این حجم بالا از اطلاعات، زمانبر نیز خواهد بود. ما می دانیم که همه این ابعاد برای تطبیق لازم نیستند و میتوان این توصیفگر ها را با روش هایی فشرده کرد. برای مثال می توان به جای استفاده از داده های اعشاری از رشته های باینری بهره برد. الگوریتم BRIEF برای همین موضوع طراحی شده است. این الگوریتم برای نقاط کلیدی تصویر، توصیفگری به صورت رشته های باینری ارائه می دهد. برای بهره برد از این الگوریتم ابتدا باید نقاط کلیدی را توسط یک الگوریتم دیگر بیابیم و نقاط پیدا شده را به BRIEF دهیم تا برای آن یک توصیفگر فشرده ارائه دهد. توصیف گر BRIEF میتواند ۱۲۸، ۲۵۶ یا ۵۱۲ تایی باشد که حافظه هایی معادل ۳۲، ۶۴ و ۱۲۸ بیتی اشغال می کند.

برای استفاده از این الگوریتم ابتدا باید یک شی `brief` از کلاس `briefDescriptorExtractor_create()` از ماژول `xfeatures2d` ایجاد نمود. سپس توسط یک الگوریتم `keypoint` ها را بیابیم. متد سازنده این کلاس به صورت زیر است

```
briefDescriptorExtractor_create([,bytes])
```

bytes : چند بایتی بودن توصیف گر را مشخص می کند که می تواند ۳۲، ۶۴ یا ۱۲۸ باشد.

در نهایت توسط تابع `compute()` از کلاس فوق، برای `keypoint` ها، توصیفگر ایجاد کنیم.

```
Compute ( image , keypoints ) -> keypoints , descriptors
```

Image : تصویر ورودی

Keypoints : نقاط کلیدی که توسط یک الگوریتم ویژگی یاب نظیر SIFT یافت شده

این تابع دو خروجی دارد. خروجی اول نقاط کلیدی و خروجی دوم توصیفگر این نقاط

تذکر: الگوریتم BRIEF در برابر چرخش های زیاد ، ضعیف عمل می کند و ممکن است توصیفگر با چرخش تصویر دچار تغییر شود.

مثال :

```
import cv2
img=cv2.imread ("Wall-E.jpg" , 0)

brief=cv2.xfeatures2d .BriefDescriptorExtractor_create()
surf=cv2.xfeatures2d .SURF_create()

kp=surf .detect (img , None)
kp,ds = brief .compute (img , kp)

print ( "brief size : ",brief.descriptorSize())
print ( "ds shape : " ,ds.shape)
```

خروجی به صورت زیر خواهد بود :

```
>>>
brief size : 32
ds shape : (4485, 32)
>>>
```

الگوریتم ORB

این الگوریتم در سال ۲۰۱۱ به عنوان یک جایگزین برای SURF و SIFT، مطرح شد. این الگوریتم بر خلاف الگوریتم های SIFT و SURF رایگان است. این الگوریتم را میتوان ترکیب از آشکار ساز FAST و توصیف کننده BRIEF دانست که بهبود یافته است. در ابتدا این الگوریتم با استفاده از FAST نقاط کلیدی تصویر را پیدا می کند. سپس با الگوریتم Hariss تعداد n نقطه را از بین آنها انتخاب می کند. با توجه به این که هر دوی این الگوریتم ها نسبت به چرخش تصویر مستقل نیستند، برای حل این مشکل راهکاری

ارایه شده است. در نهایت این الگوریتم با استفاده از BRIEF برای نقاط ویژگی descriptor ارایه می‌دهد. همچنین مشکل حساسیت BRIEF به تغییر زاویه نیز در این الگوریتم اصلاح شده است.

برای استفاده از این الگوریتم مانند قبل ابتدا یک شی orb ایجاد میکنیم. متد سازنده این کلاس به صورت زیر است

```
ORB_creat ( [,nF [, typeScore [, WTA_K [... ]]])
```

nFeatures : تعداد نقاط ویژگی را مشخص می‌کند. مقدار پیشفرض آن ۵۰۰ است.

TypeScore : این پارامتر مشخص می‌کند که رتبه بندی بر اساس FAST صورت گیرد و یا Harris که می‌تواند به صورت یکی از مقادیر ORB_FAST_SCORE یا ORB_HARRIS_SCORE باشد که به طور پیشفرض، هریس است

WTA_K : این پارامتر نیز می‌تواند NORM_HAMMING یا NORM_HAMMING۲ باشد

پس از ایجاد یک شی orb، برای بدست آوردن keypoints ها از تابع detect() استفاده می‌کنیم و سپس برای بدست آوردن descriptors از تابع compute() بهره می‌بریم.

```
detect ( image , mask ) -> keypoints
```

• compute(image , keypoints) -> keypoints , descriptor

- image : تصویر ورودی
- Mask : پارامتر ماسک در صورتی که بخواهیم بخشی از تصویر را بررسی کنیم.
- Keypoints : نقاط ویژگی که از تابع detect() بدست آورده‌ایم



تطبیق ویژگی ها با Brue_Force

هدف در این بخش تطبیق ویژگی های دو تصویر است. در اینجا یک توصیفگر از مجموعه اول انتخاب و با کلیه توصیفگرهای مجموعه دوم مقایسه می شود. و فاصله آن ها دو به دو محاسبه می شود. سپس تابع توصیفگری که کمترین فاصله را با توصیفگر دوم داشته باشد را باز می گرداند. که در واقع این دو توصیف گر نشان دهنده دو نقطه همسان در تصویر هستند. برای استفاده از تطبیق دهنده BF، ابتدا باید یک شی از کلاس `BFMatcher_create()` تعریف می کنیم. متد سازنده این کلاس به صورت زیر است

```
cv::BFMatcher_create ( [normType [, crossCheck]] )
```

normType: این پارامتر روش اندازه گیری فاصله را مشخص می کند. که می تواند به صورت های زیر باشد

۱- **NORM_L1** یا **NORM_L2**: این روش برای توصیفگر الگوریتم های **SIFT** و **SURF** مناسب است

۲- **NORM_HAMMING**: برای توصیفگر الگوریتم های **ORB**، **BRIEF** و **BRISK** مناسب است. اگر در الگوریتم **ORB**

پارامتر **WTA_K** برابر ۳ یا ۴ باشد باید از **NORM_HAMMING2** استفاده کنیم.

crossCheck: این پارامتر یک مقدار **Boolean** است که در حالت پیش فرض **false** است. اگر این پارامتر **true** باشد تابع تطابق ها را به صورت (i, j) باز میگرداند که i نشان دهنده درایه توصیفگر اول از مجموعه اول و j نشان دهنده توصیفگر دوم از مجموعه دوم است.

پس از ایجاد شی **bf** ما دو روش برای بدست آوردن تطابق ها داریم. روش اول استفاده از تابع **match()** و روش دوم استفاده از تابع **KnnMatch()**. تابع **match()** تنها بهترین تطابق را باز می گرداند اما در تابع دوم **k** تا از بهترین تطابق ها را باز می گرداند

`match ( descriptors1 , descriptors2 ) -> matches`

`knnMatch ( descriptors1 , descriptors2 , k ) -> matches`

- **descriptor₁**: مجموعه توصیفگرهای اول
- **descriptor₂**: مجموعه توصیفگر های دوم
- **k**: این پارامتر در تابع **knnMatch()** مشخص می کند تابع برای هر ویژگی چند تطبیق باز گرداند.

برای رسم تطابق ها، از تابع **drawMatches()**. این تابع دو تصویر را به صورت افقی رسم می کند و نقاطی را که مطابق هم هستند با رسم یک خط از تصویر اول به تصویر دوم نشان می دهد

`drawMatches( img1 , keypoints1 , img2 , keypoints2 , matches , out img [,color [,flag]] )`

- **img₁** و **img₂**: به ترتیب تصاویر اول و دوم که می خواهیم مطابقتشان را بررسی کنیم.
- **keypoints₁** و **keypoints₂**: به ترتیب نقاط کلیدی تصاویر اول و دوم هستند
- **Matches**: م تطابق ها که همان خروجی تابع **match()** می باشد
- **Out img**: تصویر خروجی که شامل دو تصویر ورودی است و نقاطی که مطابق دارند در آن با اتصال خط مشخص شده اند
- **Color**: رنگ خطوطی که نقاط را به هم متصل می کند را مشخص می نماید و اگر ۱- باشد، رنگ خطوط تصادفی انتخاب می شوند
- **Flag**: پرچم های این پارامتر درست همانند پرچم های متد **drawKeypoints()** است که قبلا به آن ها اشاره شده.

.....

همچنین تابع `drawMatchesKnn()` برای رسم k تا از بهترین ویژگی های تصویر را رسم می کند که برای رسم خروجی تابع `knnMatch()` کاربرد دارد.

مثال :

```
import cv2
from matplotlib import pyplot as plt

img1=cv2.imread("dollar.jpg",0)
img2=cv2.imread("image.jpg",0)

surf=cv2.xfeatures2d .SURF_create(1000)

kp1, des1=surf .detectAndCompute( img1 , None)
kp2, des2=surf .detectAndCompute( img2 , None)

bf=cv2.BFMatcher_create( cv2.NORM_L1)
matches=bf.match (des1 , des2)
imgOut=cv2.drawMatches( img1 , kp1 , img2 , kp2 , matches[0:20] , None ,
                        flags=cv2.DRAW_MATCHES_FLAGS_NOT_DRAW_SINGLE_POINTS)

plt.imshow(imgOut),plt.show()

cv2.imwrite ( "out.jpg" , imgOut)
```



خروجی تابع `match()` یک لیست از `Dmatch` ها است. هر `Dmatch` شامل ویژگی های از یک تطابق است که شامل موارد زیر می شود

۱- `Dmatch.distance` : این پارامتر نشان دهنده فاصله آن تطابق است که هر چه کمتر باشد، تطابق بهتر است.

۲- Dmatch.trainIdx : درایه توصیفگر از لیست دوم

۳- Dmatch.queryIdx : درایه توصیفگر از لیست جست جو که همان لیست اول است (عموماً تصویر اول شی است که

میخواهیم آن را در تصویر دوم پیدا کنیم)

۴- Dmatch.imgIdx : درایه تصویر دوم

اگر از تابع knnMatch() استفاده نماییم هر سطر شامل k تا Dmatch می‌باشد همچنین keypoints ها نیز لیستی از Dkp ها است که شامل ویژگی های زیر است

۱- Dkp.angle : زاویه آن نقطه کلیدی را نشان می‌دهد

۲- Dkp.pt : مختصات نقطه کلیدی را نشان می‌دهد

۳- Dkp.size : قطر همسایگی نقطه کلیدی مربوطه را نشان می‌دهد. هر چه این پارامتر بزرگتر باشد، نقطه کلیدی اطلاعات

بیشتری را پوشش می‌دهد

۴- Dkp.response : این پارامتر نشان دهنده میزان اهمیت نقطه کلیدی است و از این پارامتر میتوان برای رتبه بندی

نقاط کلیدی استفاده کرد

```
import cv2
from matplotlib import pyplot as plt

img1=cv2.imread("dollar.jpg",0)
img2=cv2.imread("image.jpg",0)

surf=cv2.xfeatures2d .SURF_create(1000)

kp1, des1=surf .detectAndCompute( img1 , None)
kp2, des2=surf .detectAndCompute( img2 , None)

bf=cv2.BFMatcher_create( cv2.NORM_L1)
matches=bf.match (des1 , des2 )

Min=matches [0].distance
for i in range(0,len(matches )-1) :
    if( matches[i].distance < Min):
        Min=matches[i].distance

best=[]
for m in matches:
    if( m.distance<= Min * 1.6):
        best.append(m)

imgOut=cv2.drawMatches( img1 , kp1 , img2 , kp2 , best[0:13] , None ,
                        flags=cv2.DRAW_MATCHES_FLAGS_NOT_DRAW_SINGLE_POINTS)

plt.imshow(imgOut),plt.show()
```

مثال : در مثال زیر ما بر اساس ویژگی های ذکر شده، ۱۳ تا از بهترین تطابق ها را پیدا و رسم نمودیم



مثال : در مثال زیر ما بر از `knnMatch()` استفاده نمودیم و $k=2$ قرار دادیم. سپس برای هر توصیفگر، تطبیقی را باز می‌گردانیم که از ۰.۸ دیگری کوچک تر باشد

```
import numpy as np
import cv2
from matplotlib import pyplot as plt
img1=cv2.imread("dollar.jpg",0)
img2=cv2.imread("image.jpg",0)

surf=cv2.xfeatures2d .SURF_create()

kp1, des1 = surf.detectAndCompute(img1,None)
kp2, des2 = surf.detectAndCompute(img2,None)

bf = cv2.BFMatcher()
matches = bf.knnMatch(des1,des2, k=2)

good = []
for m,n in matches:
    if m.distance < n.distance*0.8:
        good.append([m])
    elif n.distance < m.distance*0.8:
        good.append([n])

imgOut = cv2.drawMatchesKnn(img1,kp1,img2,kp2,good[0:10],None,flags=2)

plt.imshow(imgOut),plt.show()
cv2.imwrite ( "outKnn.jpg" , imgOut)
```



تطبیق ویژگی با FLANN

الگوریتم FLANN همانند Bure-Force برای بررسی تطابق دو تصویر کاربرد دارد. این الگوریتم برای داده‌های بزرگ، سریع تر از الگوریتم BF عمل می‌کند.

برای استفاده از این الگوریتم ابتدا باید یک شیء `flann` از کلاس `FlannBasedMatcher()` تعریف نمود. متد سازنده کلاس به صورت زیر است

`FlannBasedMatcher(indexParams , searchParams)`

`indexParams`: برای درک جزئیات و تنظیم پارامتر اول لازم است تا به مقالات ارایه شده برای این تابع مراجعه نمایید. اما به طور پیشفرض میتوان دو مقدار دهی برای این پارامتر در نظر گرفت. اگر الگوریتم ویژگی‌یاب استفاده شده، الگوریتم‌های SIFT یا SURF باشد، میتوان این پارامتر را به صورت زیر تنظیم کرد

```
FLANN_INDEX_KDTREE = 1
index_params = dict(algorithm = FLANN_INDEX_KDTREE, trees = 5)
```

```
FLANNINDEX_LSH = 6
index_params= dict(algorithm = FLANN_INDEX_LSH,
table_number = 12,
key_size = 20,
multi_probe_level = 2)
```

```
FLANNINDEX_LSH = 6
index_params= dict(algorithm = FLANN_INDEX_LSH,
table_number = 6,
key_size = 12,
multi_probe_level = 1)
```

برای الگوریتم‌هایی مانند ORB و BRISK برای رسیدن به نتیجه مطلوب میتوان از یکی از تنظیمات زیر بهره بود

```
search_params = dict(checks=x)
```

search: پارامتر دوم نیز به صورت زیر تنظیم می‌شود. مقدار x برای این پارامتر هرچه بیشتر باشد، دقت الگوریتم بالا رفته و زمان پردازش نیز افزایش می‌یابد.

پس از تنظیم پارامترهای فوق این دو پارامتر را به متد سازنده کلاس FLANN می‌دهیم و یک شی ایجاد می‌کنیم و در نهایت برای بدست آوردن تطابق، همانند الگوریتم BF از تابع `knnMatch()` یا `match()` استفاده میکنیم

مثال: در این مثال، مثال شماره ۳ در بخش الگوریتم BF را با الگوریتم FLANN پیاد سازی کردیم. تنها تفاوت این مثال با مثال قبلی در بخشی است که میان کامنت‌ها قرار گرفته. نکته مهم آن است که در مقایسه بین تطابق‌های m و n میدانیم همواره m بهتر از n است و فاصله آن کمتر است پس `elif` هیچگاه رخ نمی‌دهد و ما در این مثال آن را کامنت کردیم.

```

import cv2
from matplotlib import pyplot as plt
img1=cv2.imread("dollar.jpg",0)
img2=cv2.imread("image.jpg",0)
surf=cv2.xfeatures2d .SURF_create(1000)
kp1, des1=surf .detectAndCompute( img1 , None)
kp2, des2=surf .detectAndCompute( img2 , None)
#####
FLANN_INDEX_KDTREE = 1
index_params = dict(algorithm = FLANN_INDEX_KDTREE, trees = 5)
search_params = dict(checks=50)
flann=cv2.FlannBasedMatcher (index_params , search_params)
matches=flann.knnMatch ( des1 , des2 , k=2 )
#####
good = []
for m,n in matches:
    if m.distance < n.distance*0.8:
        good.append([m])
    #elif n.distance < m.distance*0.8:
    #good .append ([n])

imgOut = cv2.drawMatchesKnn(img1,kp1,img2,kp2,good[0:10],None,flags=2)

plt.imshow(imgOut),plt.show()
cv2.imwrite ( "outKnn.jpg" , imgOut)

```



یافتن شی با استفاده از تطابق و هوموگرافی

در بخش قبلی ما ویژگی های تصویر query را در یک تصویر train جست و جو کردیم و تطابق هایی را برای آن یافتیم و بهترین آن ها را انتخاب نمودیم. حال با داشتن این اطلاعات می توانیم به راحتی با استفاده از homography محل سوژه مورد نظر را در تصویر train بیابیم. اگر ما نقاطی از تصویر query و تطابق آنها در train را به تابع بدهیم، تابع تغییرات پرسپکتیوی سوژه را به ما خروجی می دهد که با استفاده از آن میتوان با کمک تابع perspectiveTransform() سوژه مورد نظر را پیدا کنیم.

برای شروع ابتدا باید مختصات نقاط تطابق را در تصویر train و query در دو آرایه جداگانه با نوع float^{۳۲} قرار دهیم. سپس تابع findHomography() را فراخوانی می کنیم

findHomography(SrcPoint , dstPoint , method , ransanReprojThreshold) -> homography , mask

- SrcPoint : مختصات نقاط از تصویر اصلی (تصویر سوژه)
- dstPoint : مختصات نقاط از تصویر که میخواهیم سوژه را در آن بیابیم
- Method : روش مورد استفاده برای پیدا کردن پیدا کردن ماتریس Homography یا همگرایی که می تواند یکی از حالات زیر باشد

○ : یک روش منظم بر اساس کلیه نقاط

○ RANSAC : یک روش قدرتمند

○ LMEDS : یک روش قدرتمند مبتنی بر کمترین میانه

- ransanReprojThreshold : این پارامتر برای روش RANSAC مورد استفاده قرار میگیرد و حداکثر خطا قابل قبول را مشخص میکند که عموماً عددی بین ۱ تا ۱۰ است.

خروجی اول این تابع یک ماتریس تبدیل و یک ماسک است

پس از فراخوانی تابع فوق مختصات چهار گوشه تصویر query را که متعلق به سوژه ما است را به همراه ماتریس تبدیل حاصل از تابع بالا را به تابع perspectiveTransform() می دهیم تا مختصات گوشه ها را در تصویر train پیدا کنیم.

perspectiveTransform(src , m) -> dst

- SRC : مختصات های اولیه

• M : ماتریس تبدیل که همان خروجی تابع findHomography() است

خروجی این تابع مختصات های انتقال یافته است

مثال :

```
import cv2
import numpy as np
from matplotlib import pyplot as plt

img1 = cv2.imread("dollar.jpg",0)
img2 = cv2.imread("image.jpg",0)

sift = cv2.xfeatures2d.SIFT_create ()

kp1 , des1 = sift.detectAndCompute ( img1 , None)
kp2 , des2 = sift.detectAndCompute ( img2 , None)

FLANN_INDEX_KDTREE = 1
index_params = dict(algorithm = FLANN_INDEX_KDTREE, trees = 5)
search_params = dict(checks=50)

flann = cv2.FlannBasedMatcher ( index_params , search_params)

matches=flann .knnMatch ( des1 , des2 , 2)

best=[]
for m,n in matches:

    if m.distance < n.distance * 0.6 :
        best.append( m )

#####

src_pts = np.float32 ( [kp1[ m.queryIdx ].pt for m in best ]).reshape(-1,1,2)
dst_pts = np.float32 ( [kp2[ m.trainIdx ].pt for m in best ]).reshape(-1,1,2)

#find Homography
HM, mask= cv2.findHomography ( src_pts , dst_pts , cv2.RANSAC , 5)

#find object in train image
h,w = img1 .shape
src = np.float32 ( [[0,0] , [0,h] , [w,h] , [w,0] ]).reshape(-1,1,2)
dst=cv2.perspectiveTransform ( src , HM)

#draw dst
imgOut = cv2.polylines(img2,[np.int32(dst)],True,255,3, cv2.LINE_AA)

plt.imshow(imgOut, 'gray'),plt.show()
```



همچنین برای رسم تطابق ها می توان از ماسک خروجی تابع `findHomography()` استفاده کرد تا تنها نقاط درون محدوده جسم رسم شود. کد آن به صورت زیر است که در ادامه کد قبل می آید


```
matchesMask = mask.ravel().tolist()
draw_params = dict(matchColor = (0,255,0), # draw matches in green color
                    singlePointColor = None,
                    matchesMask = matchesMask, # draw only inliers
                    flags = 2)
img3 = cv.drawMatches(img1,kp1,img2,kp2,good,None,**draw_params)
plt.imshow(img3, 'gray'),plt.show()
```



پردازش دنباله‌های ویدیویی

الگوریتم meanshift

کاربرد این الگوریتم در ترکیب و دنبال کردن یک سوژه در تصویر است تیوری این الگوریتم بسیار ساده است. در این الگوریتم ما یک مجموعه نقاط یا یک توزیع پیکسل مانند تصویر احتمال **Backproject** داریم و آن را به همراه یک قاب به تابع می‌دهیم. این الگوریتم با جست‌وجو روی این نقاط یا توزیع پیکسل، قاب را به سمتی که بیشترین تراکم در آن وجود دارد می‌برد تا در نهایت به یک ناحیه همگرا شود. برای درک عملکرد این الگوریتم به تصویر زیر نگاه کنید که قاب دایره‌ای شکل به سمت تراکم بیشتر حرکت می‌کند.



در این الگوریتم دو معیار برای توقف جست و جو در نظر گرفته می‌شود. یکی تعداد دفعات تکرار یا به عبارت دیگر تعداد حرکات قاب جست‌وجو و دیگری، میزان حداکثر جابه‌جایی مرکز قاب یا پنجره جست و جو. میزان جابه‌جایی کمتر از یک حد را میتوان همگرایی به یک نقطه پایدار در نظر گرفت و عملیات را پایان دهیم

این الگوریتم توسط تابع `meanShift()` پیاده سازی می شود.

`meanShift( src image , Windows , criteria) -> move count , widow`

src image: تصویر ورودی که عموماً تصویر احتمال `backproject` مورد بررسی (پس افکنش یک هیستوگرام) است که همان خروجی تابع `calcBackprjct()` است. این تصویر می تواند مجموعه ای از نقاط و یا هر تصویر خاکستری دیگری نیز باشد.

Windows: قاب یا پنجره ای اولیه که روی تصویر برای یافتن بیشتر محل احتمال، حرکت می کند. برای توصیف یک پنجره چهار عدد تعریف می شود. عرض و طول پنجره به همراه مختصات راس بالا سمت راست مستطیل

`windows = (x,y,wight,height).`

Criteria: شرایط توقف جست و جو را معین می کند. این ورودی به صورت یک سه تایی مشخص می شود. ورودی اول شروط توقف ، ورودی دوم ماکزیمم تعداد حرکت و ورودی سوم حداقل میزان حرکت بر اساس پیکسل را معین می کند.

Criteria = (condition , Max number of move , epsilon Moving)

```
Condition= cv2.TERM_CRITERIA_EPS | cv2.TERM_CRITERIA_COUNT
```

این تابع همچنین دو خروجی دارد

Move count : تعداد حرکات انجام شده، پنجره برای پیدا کردن محلی با بیشترین تراکم پیکسلی

Windoe : پنجره جست و جو خروجی بعد از پایان الگوریتم که پارامترهای آن همانند پنجره ورودی است

مثال : در مثال زیر ما ابتدا فریم اول فیلم مورد نظر را دریافت می کنیم. سپس بخشی از تصویر را که آبجکت مورد نظر در آن قرار دارد را جدا کرده و هیستوگرام آن را محاسبه می کنیم که همان هیستوگرام شی مورد نظر ما است. سپس وارد حلقه `while` می شویم و عملیات ترکیب را آغاز می کنیم. برای اینکار ابتدا پس افکنش هیستوگرام بدست آمده را روی هر فریم فیلم بدست آورده و با اعمال تابع `meanShift` بر روی تصویر خروجی `BackProject` ، عملیات ترکیب را انجام می دهیم.

```

import cv2
import numpy as np

cap = cv2.VideoCapture ( "video.mp4")

_,frame = cap.read ()

window = ( 210 , 190 , 30 , 60)

roi = frame [190 : 250 , 210 : 240 ]
cv2.imshow ( " first frame object" , roi)
hsv = cv2.cvtColor ( roi , cv2.COLOR_BGR2HSV )
hist = cv2.calcHist ( [hsv] , [0] , None , [180] , [0,180] )
cv2.normalize ( hist , hist , 0, 255, cv2.NORM_MINMAX )
criteria = ( cv2.TERM_CRITERIA_COUNT | cv2.TERM_CRITERIA_EPS , 10 , 1)
cv2.imwrite ( " object.jpg", roi)

while (cap.isOpened()) :

    _,frame = cap.read ()
    hsv = cv2.cvtColor ( frame , cv2.COLOR_BGR2HSV )
    backProjrct = cv2.calcBackProject ( [hsv] , [0] , hist, [0,180] , 1)
    _,window = cv2.meanShift ( backProjrct , window , criteria )


    x,y,w,h = window

    cv2.rectangle ( frame , (x,y) , (x+w , y+h) , (255,0,0) , thickness=1)
    cv2.imshow ( " video" , frame )
    key=cv2.waitKey (5)

    if key == 27 :
        break

    elif key!=-1 :
        cv2.imwrite ( str(key)+ ".jpg" , frame)

```



الگوریتم CamShift

الگوریتم همانند الگوریتم meanShift می‌باشد با این تفاوت که در این الگوریتم، اندازه و زاویه پنجره جست و جو ثابت نبوده و مرتباً تغییر پیدا می‌کند و برای اهدافی که فاصله آنها از دوربین تغییر پیدا می‌کند و یا چرخش دارند مناسب است. این الگوریتم توسط تابع CamShift() پیاده سازی می‌شود. این تابع از نظر پارامتر ورودی همانند تابع meanShift() می‌باشد.

CamShift(src image , Windows , criteria) -> move count , window

src image: تصویر ورودی

Window: قاب یا پنجره ای اولیه که روی تصویر برای یافتن بیشتر محل احتمال، حرکت می‌کند.

windows = (x,y,wight,height).

Criteria: شرایط توقف جست و جو را معین می‌کند و همانند الگوریتم meanShift می‌باشد و شامل پارامترهای زیر است.

Criteria = (condition , Max number of move , epsilon Moving)

```
Condition= cv2.TERM_CRITERIA_EPS | cv2.TERM_CRITERIA_COUNT
```

این تابع همچنین دو خروجی دارد

retVal : این پارامتر پنجره جست و جو پس از پایان الگوریتم، به همراه زاویه آن می‌باشد که از پارامترهای، مختصات مرکز پنجره، طول و عرض پنجره، و زاویه پنجره تشکیل شده است که با استفاده از تابع **boxPoints()** این پارامتر را به مختصات چهار راس چهار ضلعی تبدیل کرده و سپس با استفاده از تابع **polylines()** آن را رسم می‌کنیم. در الگوریتم CamShift عموماً از این خروجی استفاده می‌شود. برای درک بهتر، به مثال توجه کنید.

Windoos : پنجره جست و جو خروجی بعد از پایان الگوریتم بدون زاویه، که پارامترهای آن همانند پنجره ورودی است

```

import numpy as np
import cv2

cap = cv2.VideoCapture('slow.flv')

# take first frame of the video
ret,frame = cap.read()

# setup initial location of window
r,h,c,w = 250,90,400,125 # simply hardcoded the values
track_window = (c,r,w,h)

# set up the ROI for tracking
roi = frame[r:r+h, c:c+w]
hsv_roi = cv2.cvtColor(roi, cv2.COLOR_BGR2HSV)

roi_hist = cv2.calcHist([hsv_roi],[0],None,[180],[0,180])
cv2.normalize(roi_hist,roi_hist,0,255,cv2.NORM_MINMAX)

# Setup the termination criteria, either 10 iteration or move by atleast 1 pt
term_crit = ( cv2.TERM_CRITERIA_EPS | cv2.TERM_CRITERIA_COUNT, 10, 1 )

while(1):
    ret ,frame = cap.read()

    if ret == True:
        hsv = cv2.cvtColor(frame, cv2.COLOR_BGR2HSV)
        dst = cv2.calcBackProject([hsv],[0],roi_hist,[0,180],1)
        # apply meanshift to get the new location
        ret, track_window = cv2.CamShift(dst, track_window, term_crit)
        # Draw it on image
        pts = cv2.boxPoints(ret)
        pts = np.int0(pts)
        img2 = cv2.polylines(frame,[pts],True, 255,2)
        cv2.imshow('img2',img2)

        k = cv2.waitKey(60) & 0xff
        if k == 27:
            break


    cv2.destroyAllWindows()
    cap.release()

```



الگوریتم Optical flow

یا جریان نوری الگوریتمی است برای آشکار سازی حرکت یک شی در تصویر در دو فریم متوالی که ناشی از حرکت دوربین یا شی باشد. این یک بردار دو بعدی است که هر بردار حرکت نقاط از فریم اول به فریم دوم را نشان می‌دهد. تصویر زیر را در نظر بگیرید.



در این تصویر یک توپ، در ۵ فریم متوالی نشان و فلش سفید رنگ بردار جابه‌جایی را نشان می‌دهد. Optical flow برای کار هایی نظیر ساختار حرکت، حذف لرزش دوربین، فشرده سازی فیلم و... کاربرد دارد.

Optical flow بر روی فرضیه‌های زیر کار می‌کند :

- شدت پیکسل‌های یک شی بین فریم‌های متوالی تغییر نمی‌کند.
- پیکسل‌های همسایه حرکت مشابه دارند

پیکسل $I(x, y, t)$ را در نظر بگیرید. دقت شود که چون ما با فیلم سر و کار داریم، بعد جدید t به مشخصه‌های پیکسل اضافه شده. در فریم بعدی با گذشت dt ، این پیکسل به مقدار (dx, dy) جابه‌جا می‌شود. چون شدت این پیکسل در این دو فریم تغییر نمی‌کند، خواهیم داشت $I(x, y, t) = I(x+dx, y+dy, t+dt)$ که با استفاده از سری تیلور و تقسیم طرفین بر dt خواهیم داشت $f_x u + f_y v + f_t = 0$ که

$$f_x = \frac{\partial f}{\partial x}; f_y = \frac{\partial f}{\partial y}$$

$$u = \frac{dx}{dt}; v = \frac{dy}{dt}$$

که با حل معادله فوق می‌توان dx , dy را بدست آورد. برای حل این معادله که دارای دو مجهول است، از روش لوکاس کاناد استفاده می‌شود. در `opencv` کلیه این عملیات توسط تابع `calcOpticalFlowPyrLK()` انجام می‌شود. این تابع به صورت زیر می‌باشد.

`calcOpticalFlowPyrLK ( prevImg , nextImg , prevPts , nextPts , status , err , winSize , Maxlvl , criteria ) -> nextPts , status , err`

- `prevImg` : تصویر یا فریم قبلی که باید در فضای رنگ خاکستری ۸ بیتی باشد.
- `nextImg` : تصویر یا فریم فعلی که باید در فضای رنگ خاکستری ۸ بیتی باشد.
- `prevPts` : بردار مختصات نقاط در فریم قبلی که می‌خواهیم دنبال کنیم. مختصات هر نقطه باید به صورت x,y مشخص شود.
- `nextPts` : مختصات جدید نقاط ورودی که در تصویر دوم، محاسبه شده. اگر پرچم `OPTFLOW_USE_INITIAL_FLOW` استفاده شود. تعداد نقاط ورودی و خروجی یا به عبارت دیگر، اندازه بردار ورودی و خروجی برابر خواهد بود.
- `Status` : بردار خروجی وضعیت است و برای هر ویژگی، عنصر یا نقطه، اگر روند ردیابی ادامه یابد و نقطه دنبال شود، مقدار ۱ و در غیر این صورت مقدار ۰ را برای آن نقطه در بردار وضعیت، بر می‌گرداند.
- `Err` : بردار خروجی خطاها است و برای هر ویژگی، عنصر یا نقطه، مقدار خطا را باز می‌گرداند. نوع اندازه‌گیری خطا را می‌توان در پارامتر `flags` تنظیم کرد. اگر برای نقطه‌ای روند ردیابی قطع شود، برای آن نقطه، خطا تعریف نمی‌شود. (از پارامتر `status` برای پیدا کردن چنین مواردی استفاده می‌شود).
- `WinSize` : اندازه پنجره جست و جو در هر مرحله، که هر چه سرعت حرکت شی مورد نظر بیشتر باشد، پنجره جست و جو نیز باید بزرگ تر شود.
- `Criteria` : شرط توقف جست و جو را معین می‌کند که به صورت یک سه‌تایی مشخص می‌شود. ورودی اول شروط توقف ، ورودی دوم ماکزیمم تعداد حرکت و ورودی سوم حداقل میزان حرکت بر اساس پیکسل را معین می‌کند.

`Criteria = (condition , Max number of move , epsilon Moving)`

`Condition= cv2.TERM_CRITERIA_EPS | cv2.TERM_CRITERIA_COUNT`

Flags : پرچم های عملیاتی

`OPTFLOW_USE_INITIAL_FLOW` : اگر از این پرچم استفاده شود، از مقدار پارامتر `nextPts` که تحت ورودی به تابع دادیم، به عنوان تخمین اولیه استفاده می‌شود. در غیر این صورت مقدار `prevPts` در `nextPts` کپی شده و این مقدار به عنوان تخمین اولیه استفاده می‌شود

`min eigen` : اگر از این پرچم استفاده شود، برای محاسبه خطا از روش استفاده می‌شود که اگر از حداقل مقدار محاسبه شده کمتر باشد، آن نقطه به عنوان یک ویژگی ضعیف تلقی شده و حذف می‌شود و باعث بهبود عملکرد می‌شود. اما اگر این پرچم استفاده نشود، برای محاسبه خطا، از تقسیم فاصله بین نقاط ویژگی تقسیم بر تعداد پیکسل‌های یک پنجره، استفاده می‌شود.

مثال : در این مثال ما با استفاده از الگوریتم `shi-Tomasi` با تابع `goodFeaturesToTrack()` نقاط کلیدی را در اولین فریم پس از زدن کلید `space` پیدا کرده و با دادن مختصات این نقاط، به همراه فریم فعلی، قبلی و سایر پارامترها به تابع `calcOpticalFlowPyrLK()`، نقاط ویژگی را ردیابی می‌کنیم و نقاطی را که پارامتر `status`، آن‌ها ۱ است، یا به عبارت دیگر نقاطی را که ردیابیشان موفق بوده است را رسم می‌کنیم.

```

import cv2
import numpy as np

cap = cv2.VideoCapture(0)

shiTomasiParams = dict ( maxCorners = 100 , qualityLevel = 0.3 , minDistance = 5 , blockSize = 7
)
lkParams = dict( winSize = (15,15),maxLevel = 2, criteria = (cv2.TERM_CRITERIA_EPS |
cv2.TERM_CRITERIA_COUNT, 10, 0.03))

while 1:
    ret ,frame = cap.read ()
    frameGray = cv2.cvtColor ( frame , cv2.COLOR_BGR2GRAY )

    prevPts = cv2.goodFeaturesToTrack ( frameGray , **shiTomasiParams )

    for point in prevPts :

        frame = cv2.circle ( frame , tuple(point.ravel()) , 2 , (0,0,255) , thickness=-1)

    cv2.imshow ( " WebCam " , frame )
    key = cv2.waitKey (5)

    if key == 32 :
        break
#-----

oldgray = frameGray.copy()

while 1 :

    ret ,newFrame = cap.read ()
    newgray = cv2.cvtColor ( newFrame , cv2.COLOR_BGR2GRAY )

    newPts, status , err = cv2.calcOpticalFlowPyrLK ( oldgray , newgray , prevPts , None ,
**lkParams )

    correctPts = newPts [ status == 1 ]

    for point in correctPts :

        newFrame = cv2.circle ( newFrame , tuple(point.ravel()) , 2 , (0,100,255) , thickness=-1)

    cv2.imshow ( " WebCam " , newFrame )
    key = cv2.waitKey (30)

    oldgray = newgray.copy()

```

الگوریتم Background Subtraction

هدف در این بخش حذف پس‌زمینه از فیلم، می‌باشد. تشخیص پس‌زمینه یکی از مراحل اولیه در برنامه‌های بینایی است. حذف پس‌زمینه در برنامه‌هایی نظیر شمارش تعداد بازدیدکنندگان از یک محل، به وسیله شمارش تعداد افرادی که از آن وارد یا خارج می‌شوند و یا دوربین‌های ترافیکی که اطلاعاتی راجع به وسایل نقلیه بدست می‌آورند، کاربرد فراوان دارد. از نظر فنی باید بتوان پیش‌زمینه متحرک را از پس‌زمینه ثابت جدا کرد. اگر بتوان یک عکس خالی از پس‌زمینه مانند عکس اتاق بدون بازدید کننده یا جاده‌ی بدون وسیله نقلیه تهیه کرد، کار خیلی ساده است و کافی است که این تصویر را از هر فریم دوربین منها کنیم تا پیش‌زمینه بدست آید؛ اما در اقلب موارد ما چنین تصویری نخواهیم داشت و لازم است که پس‌زمینه را از با استفاده از همان تصویری که داریم استخراج کنیم. وجود سایه می‌تواند کار را پیچیده‌تر کند، زیرا سایه نیز حرکت می‌کند و به عنوان پیش‌زمینه تشخیص داده می‌شود. در `opencv` سه الگوریتم برای حذف پس‌زمینه ارائه شده که در زیر به معرفی آن‌ها می‌پردازیم.

الگوریتم BackgroundSubtractorMOG

این یک الگوریتم پیش‌زمینه، پس‌زمینه گاوسی است. این الگوریتم در سال ۲۰۰۱ معرفی شد. در این الگوریتم از مدل ترکیبی توزیعی گاوسی برای مدل‌سازی هر پیکسل استفاده می‌کند. وزن ترکیب گاوسی در این الگوریتم نشان دهنده میزان زمانی است که رنگ پیکسل مذکور، ثابت است. پیکسل‌های پس‌زمینه آن‌هایی هستند که زمان نسبت طولانی، ثابت هستند

در `opencv` برای استفاده از این الگوریتم، ابتدا لازم است که از کلاس `creatBackgrpundSubtractorMOG()` از ماژول `cv2.bgsegm` یک شی ایجاد نمود، سپس در حلقه اجرای فیلم با استفاده از تابع `apply` در کلاس فوق، فریم را در هر مرحله به تابع دهیم و یک ماسک به عنوان خروجی دریافت کنیم که این ماسک، ماسک `forceground` یا پیش‌زمینه است و بخش‌های پس‌زمینه در آن به رنگ مشکی هستند.

`mask = creatBackgrpundSubtractorMOG ( history , nmixturs , backgroundRatio , noiseSigma )`

history : طول حافظه را تعیین می‌کند که تا چند فریم را به عنوان **history** در نظر بگیرد که مقدار پیشفرض ۲۰۰ است.

nmixtur : تعداد مخلوط گاوسی را مشخص می‌کند. مقدار پیشفرض آن برابر ۵ است

BackgroundRatio : نسبت ابعاد پس‌زمینه که مقدار پیشفرضش ۰.۷ است

noiseSigma : قدرت نویز را مشخص می‌کند (انحراف استاندارد در فضاهاى رنگی) . مقدار ۰ به معنای انتخاب مقدار به صورت خود کار است.

مثال :

```
import cv2

cap = cv2.VideoCapture (0)
bgs = cv2.bgsegm.createBackgroundSubtractorMOG ( )

while True :

    ret,frame = cap.read ( )
    forcegroundMask = bgs.apply ( frame )

    result = cv2.bitwise_and ( frame , frame , mask = forcegroundMask )
    cv2.imshow ( "mask" , forcegroundMask )
    cv2.imshow ( "forceground" , result )
    cv2.imshow ( "original " , frame )

    cv2.waitKey (30)
```



الگوریتم BackgroundSubtractorMOG2

این یک الگوریتم توسعه یافته الگوریتم قبلی بوده. یکی از ویژگی‌های مهم این الگوریتم، انتخاب تعداد توزیعی گاوسی برای هر پیکسل به طور مجزا است که باعث بهبود تشخیص پس زمینه شده. برای استفاده از این الگوریتم، ابتدا باید از کلاس `creatBackgrpundSubtractorMOG2()` یک شی ایجاد نمود و سپس در حلقه اجرای فیلم با استفاده از تابع `apply` در کلاس فوق، فریم را در هر مرحله به تابع دهیم و یک ماسک به عنوان خروجی دریافت کنیم که این ماسک، ماسک `forceground` یا پیش زمینه است

`creatBackgrpundSubtractorMOG2( history , varThreshold , detectShadow ) -> mask`

- `history` : طول حافظه را تعیین می‌کند که تا چند فریم را به عنوان `history` در نظر بگیرد که مقدار پیشفرض ۵۰۰ است.
- `VarThreshold` : یک حد آستانه برای آنکه معین کند یک پیکسل آیا به درستی به عنوان `background` انتخاب شده است یا خیر.
- `detectShow` : اگر این پارامتر `true` باشد، الگوریتم سایه را نیز تشخیص می‌دهد و با رنگ خاکستری در `mask` نشان می‌دهد که این کار سرعت را کاهش می‌دهد. بنابراین در مواردی که نیازی به این مورد نیست، بهتر است `false` باشد که به طور پیشفرض `false` است.

مثال :

```
import cv2

cap = cv2.VideoCapture (0)
bgs = cv2.createBackgroundSubtractorMOG2 ( )

while True :

    ret,frame = cap.read ( )
    forcegroundMask = bgs.apply ( frame )

    result = cv2.bitwise_and ( frame , frame , mask = forcegroundMask )
    cv2.imshow ( "mask" , forcegroundMask )
    cv2.imshow ( "forceground" , result )
    cv2.imshow ( "originall " , frame )

    cv2.waitKey (30)
```

الگوریتم BackgroundSubtractorGMG

این الگوریتم ترکیبی است از تخمین آماری تصویر و تقسیم‌بندی بیزی برای هر پیکسل. این الگوریتم در سال ۲۰۱۲ معرفی شد. در این الگوریتم از چند فریم اول (به طور پیشفرض ۱۲۰) برای مدل سازی بک گراند استفاده می‌کند. سپس با استفاده از الگوریتم قطعه‌بندی احتمالی پیش زمینه که اشیا پیش‌زمینه را توسط استنتاج بیزی (Bayesian) استخراج نماید. تخمین‌ها به صورت انطباقی هستند. به این صورت که مشاهدات جدید، وزن بیشتری از مشاهدات قبلی دارند تا متناسب با نور متغیر باشد.

برای استفاده از این الگوریتم باید از کلاس `creatBackgrpundSubtractorMOG()` از ماژول `cv2.bgsegm` یک شی ایجاد نمود، سپس در حلقه اجرای فیلم با استفاده از تابع `apply` در کلاس فوق، فریم را در هر مرحله به تابع دهیم و یک ماسک به عنوان خروجی دریافت کنیم که این ماسک، ماسک `forceground` یا پیش زمینه است و بخش‌های پس زمینه در آن به رنگ مشکی هستند.

`creatBackgrpundSubtractorMOG ( initializationFrames , decisionThreshold ) -> mask`

- `initializationFrames`: تعداد فریمی که برای مدل سازی پس‌زمینه استفاده می‌شود.
- `decisionThreshold`: حد آستانه که برای بالاتر از آن پیش‌زمینه و کمتر از آن پس‌زمینه خواهد بود

مثال :

در مثال زیر برای حذف نویز عملیات `morphological` روی ماسک خروجی انجام می‌گیرد.

```
import cv2

cap = cv2.VideoCapture (0)


kernel = cv2.getStructuringElement(cv2.MORPH_ELLIPSE,(3,3))
fgbg = cv2.bgsegm.createBackgroundSubtractorGMG()

while(1):
    ret, frame = cap.read()
    fgmask = fgbg.apply(frame)
    fgmask = cv2.morphologyEx(fgmask, cv2.MORPH_OPEN, kernel)
    cv2.imshow('frame',fgmask)
    cv2.waitKey(30)
```

یادگیری ماشین

الگوریتم KNN (k nearest neighbour)

الگوریتم KNN یکی از ساده ترین الگوریتم های موجود برای یادگیری ماشین تحت نظارت است. ایده این الگوریتم پیدا کردن بیشترین تطابق ها در فضای ویژگی میان داده های مورد آزمون است. به تصویر زیر توجه نمایید



در تصویر بالا دو خانواده مثلث قرمز و مربع آبی وجود دارد که محل هر کدام در نقشه بالا نشان داده شده است که ما به آن فضای ویژگی می گوئیم (فضای ویژگی در واقع یک فضایی است که تمام داده ها و حالات را پیشبینی کند. مثلاً یک فضای ۲D را در نظر بگیرید. در این فضا هر داده دارای دو ویژگی است که همان مختصات X, Y است. حال اگر ما سه ویژگی داشته باشیم، به یک فضای ۳D نیاز داریم مانند یک رنگ RGB که میتوان تمام حالات آن را در یک فضای سه بعدی رسم کرد. همچنین مشخص است که اگر ما n ویژگی داشته باشیم، به یک فضای nD نیازمندیم) در تصویر بالا یک عضو جدید که با دایره سبز نشان داده شده، به این خانواده اضافه می شود که با دایره ی سبز رنگ نشان داده شده. حال ماشین باید تصمیم بگیرد که این عضو جدید متعلق به کدام خانواده باشد. در الگوریتم KNN ماشین نزدیک ترین همسایه ی این عضو جدید را بررسی میکند و آن را به همان خانواده نسبت می دهد. همان طور که مشخص است در تصویر بالا مثلث قرمز به دایره سبز نزدیکتر بوده و این عضو جدید به این خانواده تعلق می گیرد.

اما در اینجا یک مشکل وجود دارد، شاید نزدیک ترین همسایه به عضو جدید مثلث قرمز باشد، اما چي ميشه اگر اين عضو همسایه های آبی زیادی داشته باشد.. در این صورت مربع های آبی قدرت بیشتر در آن منطقه دارند. پس بررسی نزدیکترین همسایه شاید خیلی مناسب نباشد. به جای آن ما K تا از نزدیکترین همسایه های عضو جدید را بررسی می کنیم. برای مثال فرض کنید $K=3$ باشد در این صورت ۲ تا از نزدیک ترین همسایه ها مثلث قرمز و تنها یکی مربع آبی است. که در این صورت عضو جدید باز هم به خانواده مثلث قرمز تعلق می گیرد اما اگر $K=5$ باشد، عضو جدید دارای ۳ همسایه مربع آبی و ۲ همسایه مثلث قرمز است که در این صورت به خانواده مربع آبی تعلق می گیرد. اما اگر $K=4$ باشد تعداد همسایه های آبی و قرمز برابر است پس بهتر است که K همواره عددی فرد انتخاب شود. اما در این حالت یا به صورت کلی آیا صحیح است که ما دو همسایه مثلث قرمز را که خیلی

نزدیکتر هستند را هم ارزش با دو مربع آبی بدانیم؟ از این رو ما علاوه بر بررسی تعداد همسایگی، فاصله آن‌ها را هم از عضو جدید، به عنوان یک معیار در نظر می‌گیریم و بر اساس این فاصله‌ها الگوریتم تعدادی وزن به هر خانواده اختصاص می‌دهد. به این صورت که برای همسایه‌های نزدیک یک وزن بزرگ و برای همسایه‌های دورتر یک وزن کوچک در نظر می‌گیرد. سپس وزن‌های مختلف هر خانواده را باهم جمع می‌کنیم و خانواده‌ای که مجموع وزن‌هایش بیشتر باشد، عضو جدید به آن خانواده تعلق می‌گیرد. این تعمیم الگوریتم KNN است.

مثال :

در مثال زیر ما مانند تصویر بالا یک فضای ویژگی دوبعدی با دو خانواده ایجاد می‌کنیم خانواده اول را با مقدار ۰ مشخص می‌کنیم و آن‌ها را با مثلث قرمز و خانواده دوم را با مقدار ۱ مشخص می‌کنیم و آن‌ها را با مربع آبی رسم می‌کنیم. در این مثال ابتدا به کمک تابع `numpy.random.randint()` تعدادی داده به صورت رندوم ایجاد می‌کنیم. که ویژگی‌ها یا همان مختصات آن‌ها را در `trainData` و کلاس یا خانواده آن‌ها را در `responses` ذخیره می‌کنیم که نوع درایه‌های هردوی این آرایه‌ها برای استفاده در الگوریتم `knn` باید `float32` باشد. سپس مختصات داده‌های دو خانواده را جدا و در دو لیست جداگانه `red` و `blue` ذخیره می‌کنیم و آن‌ها را با تابع `plt.scatter()` رسم می‌کنیم.

`numpy.random.randint( low , high , size )`

`plt.scatter( x , y , Scaller , color , marker shape)`

```
import cv2
import numpy as np
from matplotlib import pyplot as plt

#set 25 numbers of (x,y)
trainData=np.random.randint (0 , 100 , (25,2)).astype (np.float32 )


#set 25 numbers of (class number)
responses=np.random.randint (0 , 2 , (25,1)).astype (np.float32 )

red=trainData [ responses.ravel()==0]
blue=trainData [ responses.ravel()==1]

plt.scatter ( red[:,0] , red[:,1], 80 , 'r' , '^')
plt.scatter ( blue[:,0] , blue[:,1], 80 , 'b' , 's')
plt.show ()
```

در

تابع `scatter`، رنگ‌ها و اشکال دارای نماد اختصاری هستند برای مثال '^' نماد اختصاری برای مثلث است



پس از انجام مراحل فوق، یک عضو جدید ایجاد میکنیم و می‌خواهیم با استفاده از الگوریتم بررسی کنیم که این عضو متعلق به کدام خانواده است. برای استفاده از الگوریتم Knn ابتدا یک شی از کلاس `cv2.ml.KNearest_creat()` تعریف میکنیم. سپس با استفاده از تابع `train()` داده‌های معلومی که داریم که در این مثال در بالا ساختیم را به شی `knn` می‌دهیم یا به اصطلاح به ماشین آموزش می‌دهیم.

`Train ( trainData , flage , responses)`

TrainData : آرایه از مختصات داده‌ها (مقدار ویژگی‌های داده مربوطه)

Flages : پرچم را مشخص میکند که در اینجا پرچم `ROW_SAMPLE` توصیه می‌شود

Response : آرایه که خانواده یا کلاس‌ها را مشخص میکند و با `trainData` نظیر به نظیر است. یعنی برای مثال درایه سوم از آرایه‌ی `TrainData` مختصه داده‌ای را معین می‌کند که عضو خانواده است که در درایه سوم `response` معین شده

پس از یاددهی به ماشین حال می‌خواهیم مشخص کنیم که نقطه جدید متعلق به کدام خانواده است. برای اینکار از تابع `findNearst()` استفاده می‌کنیم.

`findNearest ( sample , k) -> retVal , result , neighbors , dist`

sample : داده یا داده‌های جدید که می‌خواهیم بررسی کنیم

K : تعداد همسایه‌ها را مشخص می‌کند

این تابع ۴ خروجی دارد که خروجی `result` مشخص می‌کند نقطه جدید متعلق به کدام کلاس است، `neighbors` همسایه‌های یافت شده را بر اساس کلاسشان نشان می‌دهد و خروجی `dist` مقدار فاصله هر کدام از این همسایگی‌ها را مشخص می‌کند.

پس کد بالا با کد زیر تکمیل می‌شود

```


newcomer = np.random.randint(0,100,(1,2)).astype(np.float32)
plt.scatter(newcomer[:,0],newcomer[:,1],80,'g','o')

#creat knn and train & use
knn = cv2.ml.KNearest_create()
knn.train(trainData, cv2.ml.ROW_SAMPLE, responses)
_,result,neighbors , dist =knn.findNearest ( newcomer , 3 )

print( " result : " , result )
print( " neighbors : " , neighbors )
print( " dist : " , dist )

plt.show ()

```



```

===== RESTART: C:\Users\Amir_PC\Desktop\TrV.py =====
result : [[0.]]
neighbors : [[0. 1. 0.]]
dist : [[16. 61. 64.]]

```

اگر sample به جای یک نقطه، آرایه ای از نقاط باشد، خروجی های تابع `findNearest()` نیز به صورت آرایه خواهند بود. برای مثال درایه اول از خروجی های `neighbors` , `result` , `dist` نتیجه مربوط به نقطه ای است که در درایه اول `sample` است

```


# 10 new comers
newcomers = np.random.randint(0,100,(10,2)).astype(np.float32)
ret, results,neighbours,dist = knn.findNearest(newcomer, 3)
# The results also will contain 10 labels.

```

```
neighbors : [[1. 0. 1.]
[1. 0. 1.]
[0. 1. 1.]
[1. 0. 0.]
[0. 0. 0.]
[0. 1. 1.]
[1. 1. 0.]
[1. 0. 1.]
[0. 0. 1.]
[0. 1. 1.]]
```

ساخت برنامه OCR برای خواندن اعداد لاتین

در این بخش قصد داریم یک نرم افزار OCR برای خواندن دست خط حروف و اعداد انگلیسی بنویسیم. ابتدا با برنامه خواندن اعداد شروع میکنیم. در ابتدا لازم است تا ما با استفاده از تعداد داده و الگوریتم knn به ماشین آموزش دهیم برای اینکار یک تصویر آماده با نام digits.png موجود است که کلیه ارقام ۰ تا ۹ را با دست خط های مختلف دارد. این تصویر شامل ۵۰ ردیف است که هر ۵ ردیف برای یک رقم بوده. هر ردیف نیز به خودی خود دارای ۱۰۰ ستون است که در هر ستون شامل رقم مربوطه با دست خطی منحصر، می شود. هر کدام از ارقام 20×20 پیکسل است. برای شروع ما تصویر را به ۵۰ ردیف و ۱۰۰ ستون تقسیم میکنیم. از ۵۰۰ تصویری که برای هر رقم موجود است، ۲۵۰ عدد را برای آموزش و ۲۵۰ عدد را برای تست ماشین در نظر می گیریم. ویژگی استفاده شده در اینجا شدت روشنایی پیکسل های تشکیل دهنده است که با اندازه 20×20 ما ۴۰۰ پیکسل و در نتیجه ۴۰۰ ویژگی خواهیم داشت. برای ساخت آرایه response که برچسب و نام خانواده هر عضو را مشخص میکند، از آنجا که میدانیم برای هر ۱۰ رقم 5×50 دست خط داریم، با کمک تابع `arrange()` یک لیست از ۰ تا ۹ می سازیم و با کمک تابع `repeat()` هر عضو این لیست را ۲۵۰ با تکرار میکنیم و از آنجا که نام هر کلاس خود باید به صورت یک لیست باشد مثلاً برای عدد یک باید برچسب به صورت [۱] باشد و نه به صورت ۱، پس از اینرو دستور `[1, np.newaxis]` را در ادامه آن می آوریم تا هر برچسب به صورت یک لیست باشد عدد داده تست برای بررسی درصد یادگیری ماشین است که هرچه این درصد بالاتر باشد بهتر است. اما ۱۰۰ درصد یادگیری ممکن است همیشه خوب نباشد و ماشین تنها داده های آموزش دیده را درست تشخیص دهد و داده ای خارج از داده های آموزشی را اشتباه تشخیص دهد پس در بسیاری مواقع، ۹۸ درصد صحت میتواند بهتر از ۱۰۰ درصد باشد. نکته دیگر آن که داده هایی که ماشین در تست درست تشخیص ندهد را میتوان به آن آموزش داد تا یادگیری ماشین بهتر شود.



```

import cv2
from matplotlib import pyplot as plt
import numpy as np

img=cv2.imread ("digits.png")
gray=cv2.cvtColor (img,cv2.COLOR_BGR2GRAY)

#split image to 50*100 picture
cells = np.array ([np.hsplit(row , 100 ) for row in np.vsplit (gray,50)])

#divide data to train and test and reshape
train=cells[:, 0:50].reshape (-1,400).astype(np.float32)
test =cells[:,50:100].reshape (-1,400).astype(np.float32)

#creat lable for train and test data
k = np.arange(10)
train_labels = np.repeat(k,250)[: ,np.newaxis]
test_labels = train_labels.copy()

#trian and test machin
knn=cv2.ml.KNearest_create()
knn.train (train ,cv2.ml.ROW_SAMPLE , train_labels)
retval , result , neighbors , dist= knn.findNearest( test , k=5)

#calc accuracy of machin learning
matches= ( result==test_labels)
correstNum=np.count_nonzero(matches)
testNum=len(test)
accuracy = (correstNum/testNum)*100
print ( " accuracy of machin learning " , accuracy)

#Accuary is 91.7%

```

در اینجا کد پایه برنامه مورد نظر ما آماده شده است. که یادگیری ۹۱.۷ درصد را نتیجه داده است. همچنین میتوان داده های Knn را با کد زیر ذخیره کرد و هرگاه نیاز بود از آنها استفاده نمود

```

np.savez('knn_data.npz',train=train, train_labels=train_labels)

# Now load the data
with np.load('knn_data.npz') as data:
    print( data.files )
    train = data['train']
    train_labels = data['train_labels']

```

برای بهینه سازی میتوان داده ها را قبل از ذخیره به نوع uint۸ تبدیل کرد و سپس ذخیره نمود و برای استفاده داده ها را لود کرده و دوباره به نوع float۳۲ تبدیل کرد.

ساخت برنامه OCR برای خواندن حروف لاتین

در اینجا به جای استفاده از یک تصویر، از یک فایل داده آماده به نام letter-recognition که توسط opencv ارایه شده استفاده میکنیم. اگر این فایل را به صورت متنی باز کنید ۲۰۰۰۰ خط را مشاهده خواهید کرد. در هر ردیف، ستون اول نام یک حرف لاتین است که همان برچسب ما است و بعد از آن ۱۶ شماره آمده که همان ویژگی های ما است. این ویژگی ها از یادگیری ماشین UCI بدست آمده. ما از این ۲۰۰۰۰ دستخط، ۱۰۰۰۰ تای اول را برای یادگیری و ۱۰۰۰۰ تای دوم را برای تست ماشین استفاده می کنیم. همچنین ستون اول را از سایر داده ها جدا می کنیم که برچسب های کلاس ها را می سازد و بقیه داده ها بردار ویژگی ها است. نتیجه یادگیری در این آزمون ۹۳ درصد بود. در رابطه با این دیتاست و ویژگی های استفاده شده در آن می توانید در لینک زیر بیشتر بخوانید <http://archive.ics.uci.edu/ml/datasets/Letter+Recognition>

```
T,2,8,3,5,1,8,13,0,6,6,10,8,0,8,0,8
I,5,12,3,7,2,10,5,5,4,13,3,9,2,8,4,10
D,4,11,6,8,6,10,6,2,6,10,3,7,3,7,3,9
N,7,11,6,6,3,5,9,4,6,4,4,10,6,10,2,8
G,2,1,3,1,1,8,6,6,6,6,5,9,1,7,5,10
S,4,11,5,8,3,8,8,6,9,5,6,6,0,8,9,7
B,4,2,5,4,4,8,7,6,6,7,6,6,2,8,7,10
A,1,1,3,2,1,8,2,2,2,8,2,8,1,6,2,7
J,2,2,4,4,2,10,6,2,6,12,4,8,1,6,1,7
M,11,15,13,9,7,13,2,6,2,12,1,9,8,1,1,8
.
.
```


```

import cv2 as cv
import numpy as np
import matplotlib.pyplot as plt
# Load the data, converters convert the letter to a number
data= np.loadtxt('letter-recognition.data', dtype= 'float32', delimiter = ',',
                 converters= {0: lambda ch: ord(ch)-ord('A')})
# split the data to two, 10000 each for train and test
train, test = np.vsplit(data,2)
# split trainData and testData to features and responses
responses, trainData = np.hsplit(train,[1])
labels, testData = np.hsplit(test,[1])
# Initiate the knn, classify, measure accuracy.
knn = cv.ml.KNearest_create()
knn.train(trainData, cv.ml.ROW_SAMPLE, responses)
ret, result, neighbours, dist = knn.findNearest(testData, k=5)
correct = np.count_nonzero(result == labels)
accuracy = correct*100.0/10000
print( accuracy )

```


یادگیری ماشین با الگوریتم SVM

تصویر زیر دارای دو خانواده قرمز و آبی است. در الگوریتم knn برای هر داده آزمایشی، فاصله آن از همه داده ها را اندازه می‌گیرد و حداقل فاصله را انتخاب می‌کند که اینکار زمان صرف می‌کند همچنین ذخیره همه داده های آموزشی نیز حافظه زیادی را مصرف می‌کند. اما باتوجه به اطلاعات داده شده در تصویر اینکار واقعا نیاز است؟



ایده دیگری را در نظر بگیرید. ما خطی را پیدا می‌کنیم $f(x) = ax_1 + bx_2 + c$ که داده ها را به دو ناحیه تقسیم کند حال داده جدید X وارد می‌شود. اگر $f(X) > 0$ باشد این داده متعلق به خانواده آبی و در غیر این صورت به خانواده قرمزها تعلق دارد. ما می‌توانیم این خط را به عنوان مرز تصمیم در نظر گرفت که بسیار ساده و کار آمد خواهد بود. داده هایی را که بتوان با یک خط (یا هایپر پلین در ابعاد بالاتر) تقسیم کرد را تفکیک پذیر خطی می‌گویند.

همانطور که از تصویر بالا مشخص است، خطوط زیادی، داده‌ها را ناحیه بندی می‌کنند اما کدام یک را باید در نظر گرفت، پاسخ خطی است که بیشترین فاصله را از همه نقاط داشته باشد. زیرا در داده های ورودی نویز وجود دارد و این نویز ها نباید دقت طبقه بندی را تحت تاثیر قرار دهند بنابراین دورترین خط ، حاشیه اطمینان بالاتری را دارد. به تصویر زیر دقت نمایید




بنابراین ما برای پیدا کردن این خط به داده های آموزشی نیاز داریم. اما آیا به همه آن‌ها نیازمندیم؟ خیر، ما تنها به داده‌هایی نیاز داریم که در نزدیک و همسایگی گروه مخالف هستند که در شکل بالا به صورت توپر رسم شده اند. این داده ها را ما بردار پشتیبانی و خطوط که از میان آن‌ها می‌گذرند را صفحه پشتیبانی، می‌نامیم. این موضوع در کاهش اطلاعات و حافظه بسیار موثر است.

برنامه خواندن دست خط (OCR) با الگوریتم SVM :

در بخش قبل ما از شدت پیکسل‌ها به طور مستقیم به عنوان بردار ویژگی استفاده کردیم اما در این بخش از HOG یا هیستوگرام گرادیان جهت دار استفاده میکنیم

HOG : HOG (Histogram of Oriented Gradients) یا همان هیستوگرام گرادیان جهت‌دار یک بردار ویژگی (Feature Vector) است که در پردازش تصویر برای تشخیص اشیاء مورد استفاده قرار می‌گیرد. مفهوم اصلی HOG این است که شکل یک شیء در تصویر را می‌توان با توزیع شدت گرادیان‌ها یا جهت‌گیری لبه‌ها توصیف کرد. به عبارت دیگر، با بررسی چگونگی تغییرات روشنایی و جهت لبه‌ها در بخش‌های مختلف تصویر، می‌توان مشخصه‌ای ساخت که ساختار و شکل شیء را به صورت عددی و قابل مقایسه بیان کند.


این ویژگی‌ها سپس برای شناسایی اشیاء، تشخیص انسان، یا طبقه‌بندی تصاویر در الگوریتم‌های یادگیری ماشین و بینایی ماشین استفاده می‌شوند.



برای بهره از HOG ابتدا لازم است که پیش از **warp** تصویر را تصحیح نموده و تصویر را صاف نماییم. اینکار توسط تابع زیر انجام می‌گیرد.

```
def deskew(img):
    SZ=20
    m = cv2.moments(img)
    if abs(m['mu02']) < 1e-2:
        return img.copy()
    skew = m['mu11']/m['mu02']
    M = np.float32([[1, skew, -0.5*SZ*skew], [0, 1, 0]])
    img = cv2.warpAffine(img,M,(SZ, SZ),flags=affine_flags)
    return img
```

تصویر زیر، تصویر از عدد صفر است که در آن تصویر سمت چپ تصویر ورودی ما است که دارای پیچش بوده و تصویر سمت راست تصویر خروجی است که پیچش آن رفع شده.



پس از این مرحله نوبت به محاسبه HOG برای هر سلول (تصویر هر رقم) می‌رسد که در تابع **hog()** انجام می‌گیرد برای درک این تابع، ابتدا به توضیح توابع استفاده شده در آن می‌پردازیم.

تابع **cartToPolar()**: این تابع یک بردار دوبعدی یا لیستی از آن‌ها را بر اساس (X,Y) دریافت نموده و اندازه و زاویه آن‌ها را محاسبه می‌کند که زاویه خروجی بر اساس رادیان است

Magnitude , angle = cv2.cartToPolar(x , y)

تابع zip() : این تابع دو لیست میگیرد و درایه های آنها را نظیر به نظیر ترکیب می کند

List3=zip (list1 , list2)

List1= [۱ , ۳ , ۵ , ۷] list2=[۲ , ۴ , ۶ , ۸] -> list3= [(۱,۲) , (۳,۴) , (۵,۶) , (۷,۸)]

تابع bincount() : این تابع در حالت عادی یک آرایه با درایه های مثبت دریافت میکند و تعداد هر مقدار موجود در آرایه ورودی را می شمارد و تعداد آنها را در یک آرایه خروجی قرار می دهد . به این صورت که درایه صفرم آرایه خروجی ، تعداد صفرها در آرایه ورودی ، درایه یکم تعداد یک ها در آرایه ورودی و ... را نشان می دهد

Bincount (array , weights , min_len)

Array : آرایه ورودی

Weight : آرایه وزن ها که طول آن باید برابر طول آرایه خروجی باشد. در این حالت به جای شمردن تعداد هر رقم، وزن های موجود در درایه های نظیر در آرایه weights را باهم جمع می کند.

Min_len : حداقل طول آرایه خروجی را مشخص می کند

مثال :

```
>>> arr = [ 2,1,3,1,0,2,2]
>>> Bin = np.bincount ( arr )
>>> Bin
array([1, 2, 3, 1], dtype=int32)
```

در لیست بالا ما یک صفر داریم، پس مقدار درایه صفرم برابر ۱ ، همچنین دو عدد یک داریم پس درایه یکم برابر ۲ و الی آخر

```
>>> arr = [ 1,3,4,1,3,0,3]
>>> wei = [ 5,10,8,12,9,6,11]
>>> Bin =np.bincount( arr ,wei)
>>> Bin
array([ 6., 17.,  0., 30.,  8.] )
```

در لیست بالا ما علاوه بر آرایه یکسری وزن به تابع دادیم اما عملکرد به چه صورت خواهد بود در اینجا به جای تعداد، مجموع وزن های هم درایه در نظر گرفته می شود. برای مثال ما یک صفر داریم که درایه پنجم است که درایه پنجم در لیست wei برابر ۶ است، پس درایه صفرم Bin برابر ۶ خواهد بود. همچنین ما دو عدد ۱ در خانه های صفرم و سوم داریم که مقدار این خانه ها در لیست wei برابر ۵ و ۱۲ است که مجموع آن ها برابر ۱۷ است پس درایه یکم در bin برابر ۱۷ می گردد و الی آخر.

```
>>> arr = [ 1,3,4,1,3,0,3]
>>> wei = [ 5,10,8,12,9,6,11]
>>> Bin =np.bincount( arr ,wei , 8)
>>> Bin
array([ 6., 17.,  0., 30.,  8.,  0.,  0.,  0.] )
```

در بالا چون ما حداقل طول را ۸ قرار دادیم پس تابع حداقل تا درایه هفتم را مقدار دهی میکند که چون ما ارقام ۵ و ۶ و ۷ در آرایه ورودی نداریم، مقدار آن ها صفر می باشد

پس از درک توابع بالا به سراغ تابع hog() می رویم. برای محاسبه هیستوگرام گرادیان جهت دار ما ابتدا مشتقات سوبل را در دو جهت x و y محاسبه می کنیم. سپس اندازه و زاویه گرادیان هر پیکسل را محاسبه می کنیم. سپس مقدار زاویه را به ۱۶ کوانتیزه می کنیم. یعنی زاویه، عددی بین ۰ تا ۱۶ می شود. سپس تصویر را به ۴ بخش تقسیم کرده و در هر بخش هیستوگرام گرادیان جهت را با وزن خودش محاسبه می شود. یعنی برای هر زاویه از پیکسل ها، مجموع اندازه آن پیکسل ها را در نظر می گیریم. برای مثال اگر ما ۴ پیکسل با زاویه ۳۰ درجه داشته باشیم که اندازه آن ها مثلا ۴ و ۶ و ۷ و ۲ باشد، در هیستوگرام HOG طول bin زاویه ۳۰ درجه برابر جمع این مقادیر می باشد که برابر ۱۹ است. به عبارتی دیگر در هیستوگرام HOG محور افقی زاویه پیکسل ها و محور عمودی مجموع اندازه پیکسل های موجود با آن زاویه می باشد. از این رو ما برای هر یک از چهار قسمت تصویر چون ۱۶ زاویه داریم در نتیجه بردار ویژگی آن ۱۶ بعدی است که یک لیست بوده و شماره درایه آن نشان دهنده زاویه و مقدار هر درایه نشان دهنده مجموع اندازه پیکسل های موجود با آن زاویه است که برای کل تصویر یعنی هر چهار قسمت، ۶۴ ویژگی داریم. کلیه این مراحل در تابع hog() انجام می شود.

```
def hog(img):
    gx = cv2.Sobel(img, cv2.CV_32F, 1, 0)
    gy = cv2.Sobel(img, cv2.CV_32F, 0, 1)
    mag, ang = cv2.cartToPolar(gx, gy)
    bins = np.int32(bin_n*ang/(2*np.pi))    # quantizing binvalues in (0...16)
    bin_cells = bins[:10,:10], bins[10:,:10], bins[:10,10:], bins[10:,10:]
    mag_cells = mag[:10,:10], mag[10:,:10], mag[:10,10:], mag[10:,10:]
    hists = [np.bincount(b.ravel(), m.ravel(), bin_n) for b, m in zip(bin_cells, mag_cells)]
    hist = np.hstack(hists)         # hist is a 64 bit vector
    return hist
```

پس از تعرف توابع `deskew()` و `hog()` همانند قبل عمل می‌کنیم. ابتدا تصویر `digits.png` را فرا خوانده و آن را به ۵۰۰۰ بخش تقسیم می‌کنیم که شامل ۵۰۰ نمونه برای هر رقم است که ۲۵۰ تای آن را برای آموزش و مابقی را برای تست استفاده می‌کنیم. برای استفاده از الگوریتم SVM ابتدا یک شی از کلاس `SVM()` از ماژول `cv۲.ml` تعریف می‌کنیم. و سپس آن را به صورت زیر تنظیم می‌کنیم

```
Svm.setKernel ( cv۲.ml.SVM_LINEAR)
```

```
Svm.setType ( cv۲.ml.SVM_C_SVC)
```

```
Svm.setC ( ۲.۶۷)
```

```
Svm.setGamma (۵,۳۸۳
```

-برای آموزش از تابع `train()` همانند الگوریتم Knn استفاده می‌کنیم

```
train( trainData , flag , response )
```

- `TrainData` : آرایه از مختصات داده ها (مقدار ویژگی های داده مربوطه)
- `Flages` : پرچم را مشخص میکند که در اینجا پرچم `ROW_SAMPLE` توصیه می‌شود
- `Response` : آرایه که خانواده یا کلاس ها را مشخص میکند و با `trainData` نظیر به نظیر است. یعنی برای مثال درایه سوم از آرایه‌ی `TrainData` مختصه داده‌ای را معین می‌کند که عضو خانواده است که در درایه سوم `response` معین شده

برای تشخیص کلاس یک عضو جدید از تابع `predict()` استفاده می‌کنیم

```
predict ( test Data ) -> retVal , result
```

- `testData` : بردار ویژگی داده یا داده های جدید

خروجی این تابع هم خانواده داده یا داده‌های ورودی است.

-همچنین برای ذخیره کردن میتوانیم از تابع `save()` استفاده کنیم و آن را با پسوند `.dat` و نامی دلخواه ذخیره نماییم

```
Smv.save ( 'myName.dat' )
```

نتیجه ای که ما در اینجا بدست آوردیم ۹۴ درصد بود که نتیجه قابل قبولی است و می توان با دادن داده های آموزشی جدید آن را بهبود بخشید

```

import cv2
import numpy as np

SZ=20
bin_n = 16

# _____

def deskew(img):
    m = cv2.moments(img)
    if abs(m['mu02']) < 1e-2:
        return img.copy()
    skew = m['mu11']/m['mu02']
    M = np.float32([[1, skew, -0.5*SZ*skew], [0, 1, 0]])
    img = cv2.warpAffine(img,M,(SZ, SZ),flags=cv2.WARP_INVERSE_MAP|cv2.INTER_LINEAR)
    return img

# _____

def hog(img):
    gx = cv2.Sobel(img, cv2.CV_32F , 1, 0)
    gy = cv2.Sobel(img, cv2.CV_32F , 0, 1)
    mag, ang = cv2.cartToPolar(gx, gy)
    bins = np.int32(bin_n*ang/(2*np.pi))    # quantizing binvalues in (0...16)
    bin_cells = bins[:10,:10], bins[10:,:10], bins[:10,10:], bins[10:,10:]
    mag_cells = mag[:10,:10], mag[10:,:10], mag[:10,10:], mag[10:,10:]
    hists = [np.bincount(b.ravel(), m.ravel(), bin_n) for b, m in zip(bin_cells, mag_cells)]
    hist = np.hstack(hists)         # hist is a 64 bit vector
    return hist

# _____

img = cv2.imread( "digits.png" ,0)
cells = np.array([np.hsplit(row,100) for row in np.vsplit(img,50)])

train_cells=cells[:,0:50]
test_cells =cells[:,50:100]

deskewed = [list(map(deskew,row)) for row in train_cells]
hogdata   = [list(map(hog,row)) for row in deskewed]

trainData = np.float32(hogdata).reshape(-1,64)
responses = np.repeat(np.arange(10),250)[: ,np.newaxis]

# _____

svm = cv2.ml.SVM_create()
svm.setKernel(cv2.ml.SVM_LINEAR)
svm.setType(cv2.ml.SVM_C_SVC)
svm.setC(2.67)
svm.setGamma(5.383)
svm.train(trainData, cv2.ml.ROW_SAMPLE, responses)
svm.save('svm_data.dat')

# _____

deskewed = [list(map(deskew,row)) for row in test_cells]
hogdata =  [list(map(hog,row)) for row in deskewed]
testData = np.float32(hogdata).reshape(-1,bin_n*4)


_,result = svm.predict(testData)

mask = result==responses
correct = np.count_nonzero(mask)
print(correct*100.0/result.size)


```

الگوریتم خوشه‌بندی K-Means

یک شرکت را در نظر بگیرید که قرار است تی‌شرت جدیدی را به بازار عرضه کند. بدیهی است که این شرکت باید تی‌شرت‌هایی با سایزهای مختلف تولید کند که همه مردم با سایزهای مختلف بتوانند از آن‌ها استفاده کنند. بنابراین این شرکت اطلاعاتی از قد و وزن افرادی را بر روی گرافی، مانند زیر قرار می‌دهند.




مشخصاً شرکت نمی‌تواند در تمامی سایزها لباس تولید کند. در عوض داده‌ها را به چند دسته‌ی مثلاً کوچک، متوسط و بزرگ تقسیم می‌کند و تنها این ۳ مدل را تولید می‌کند که برای همه مردم مناسب است. این تقسیم‌بندی افراد به سه گروه، می‌تواند با الگوریتم خوشه‌بندی K-Means انجام شود و الگوریتم، ۳ سایز را که برای همه مردم راضی‌کننده است، ارایه دهد و اگر این گونه نبود؛ شرکت می‌تواند تعداد گروه‌ها را افزایش دهد. برای درک بهتر به تصاویر زیر نگاه کنید.




اما روش کارکرد این الگوریتم چگونه است؟


این الگوریتم، یک فرایند تکراری است. برای درک این فرایند، ابتدا داده‌های زیر را در نظر بگیرید. ما می‌خواهیم این داده‌ها را به دو گروه تقسیم کنیم.




در مرحله اول، الگوریتم ابتدا دو نقطه C_1 و C_2 را به عنوان مرکز این گروه‌ها در نظر می‌گیرد که ممکن است C_1 ، C_2 خود جزوه داده باشند یا نباشند. سپس در مرحله دوم، الگوریتم فاصله داده‌ها را از هر دو نقطه محاسبه می‌کند. اگر داده تست به C_1 نزدیک‌تر باشد با برچسب ۰ و اگر به C_2 نزدیک‌تر باشد با برچسب ۱ مشخص می‌کند. (اگر گروه‌ها و مراکز بیشتر وجود داشته باشد، با برچسب‌های ۲، ۳ و... معین می‌شود). در تصویر زیر، داده‌ها با برچسب ۰ را با رنگ قرمز و داده‌ها با برچسب ۱ را با رنگ آبی مشخص نموده‌ایم.



در مرحله سوم، میانگین کلیه نقاط آبی و قرمز را به صورت جداگانه محاسبه می‌کنیم و نقاط به دست آمده را به عنوان مراکز جدید در نظر می‌گیریم که نقاط مرکزی C۱ و C۲ جدید را می‌سازند. پس از این مرحله دوباره مرحله دوم، یعنی برچسب گذاری داده‌ها نسبت به مراکز جدید تکرار می‌شود. برای درک بهتر به تصویر زیر توجه فرمایید.



در نهایت مراحل دوم و سوم را آنقدر تکرار می‌کنیم که نقاط مرکزی ثابت شوند و یا ممکن است براساس معیارهایی که ما ارائه می‌دهیم متوقف شوند که این معیارها ماکزیم تعداد حرکت و حداقل میزان حرکت برای مراکز است. این درکی کلی برای الگوریتم خوشه بندی k-means بود.



برای پیاده سازی این الگوریتم از تابع `kmeans()` استفاده می کنیم

`Kmeans (samples, nclusters, bestLables, criteria, attempts, flags)-> compactness, labels, centers`

- **Samples** : داده های نمونه هستند که باید از نوع `float32` باشند و هر ستون متعلق به یک ویژگی باشد.
- **Nclusters** : تعداد خوشه بندی ها را مشخص می کند.
- **bestLables** : آرایه ورودی - خروجی که برچسب خوشه ها را برای هر داده ذخیره می کند.
- **Criteria** : شرط متوقف شدن الگوریتم را مشخص می کند که به صورت یک سه تایی مشخص میشود. ورودی اول شروط توقف ، ورودی دوم ماکزیمم تعداد حرکت و ورودی سوم حداقل میزان حرکت بر اساس پیکسل را معین می کند.

Criteria = (condition , Max number of move , epsilon Moving)

```
Condition= cv2.TERM_CRITERIA_EPS | cv2.TERM_CRITERIA_COUNT
```

- **Attempts** : این پارامتر، تعداد دفعاتی را که الگوریتم مراکز اولیه را محاسبه می کند، مشخص می کند. در این بین مراکزی انتخاب می شوند که با برچسب گذاری داده ها، داده هایی که هم گروه هستند، بیشترین فشردگی را داشته باشند. پس از انتخاب مراکز اولیه، فرایند تکرار برای رسیدن به بهترین گروه بندی، آغاز می شود.
- **Flags** : پارامتر پرچم روش بدست آوردن مراکز اولیه را مشخص میکند که می تواند یکی از حالات زیر باشد
 - ۱ **KMEANS_RANDOM_CENTERS**
 - ۲ **KMEANS_PP_CENTERS**

خروجی های این تابع نیز به صورت زیر می باشد

- **Compotness** : این پارامتر برابر است با مجموع مربعات فاصله نقاط هر خوشه نسبت به مرکزشان که میزان فشردگی هر خوشه را نشان می دهد.
- **Lables** : آرایه ای است که برچسب داده ها را نشان می دهد. این برچسب ها به صورت ۰، ۱، ۲ و... است
- **Centers** : آرایه ای است که مراکز خوشه ها را نشان می دهد.

مثال : در مثال زیر می خواهیم مجموعه ای از داده ها تنها با یک ویژگی را خوشه بندی کنیم. برای این که داده ها در دو گروه پراکنده باشند، ابتدا دو مجموعه `X` و `Y` در بازه دلخواه تولید کرده و سپس باهم ادغام می کنیم و مجموعه `Z` را ایجاد می کنیم که داده های آن در بازه ۰، تا ۲۵۵ قرار دارد. در نهایت، الگوریتم `kmeans` را روی آن اعمال کرده و داده ها را خوشه بندی می کنیم.

```

import cv2
import numpy as np
from matplotlib import pyplot as plt

# creat sample data-----
x = np.random .randint ( 25,100 , 25)
y = np.random .randint ( 175,255 , 25)

z = np.hstack ((x,y))
z = z.reshape ( (50,1) )
z = np.float32(z)
#-----



plt.hist ( z , 256 , [0,256] )
plt.show ()

# Kmean algorithm-----
criteria = ( cv2.TERM_CRITERIA_COUNT | cv2.TERM_CRITERIA_EPS , 10 , 0.1 )

compactness,labels,centers = cv2.kmeans ( z , 2 , None , criteria , 10 ,
cv2.KMEANS_RANDOM_CENTERS)
#-----

A = z [ labels==0 ]
B = z [ labels==1 ]
plt.hist ( A , 256 , [0,256] , color = 'red' )
plt.hist ( B , 256 , [0,256] , color = 'blue' )
plt.hist ( centers , 256 , [0,256] , color = 'y')
plt.show ()

```



مثال : در مثال قبل داده‌های ما تنها دارای یک ویژگی بودند اما در این مثال می‌خواهیم از داده‌ها با دو ویژگی مثلا قد و وزن استفاده کنیم. همان طور که پیش از این گفتیم هر ویژگی باید در یک ستون باشد، پس ما برای ۵۰ داده نیازمند آرایه‌ای با ابعاد 50×2 نیازمندیم که ستون اول آن متعلق به ویژگی قد و ستون دوم آن متعلق به ویژگی وزن است. و مثلا برای نفر اول، درایه $(0,0)$ قد آن، و درایه $(0,1)$ وزن آن را نشان می‌دهد. به شکل زیر توجه فرمایید.

Features		
	Height	Weight
Person 1	H1	W1
Person 2	H2	W2
.	.	.
.	.	.
.	.	.
.	.	.
.	.	.
Person 50	H50	W50

```
import numpy as np
import cv2 as cv


from matplotlib import pyplot as plt
X = np.random.randint(25,50,(25,2))
Y = np.random.randint(60,85,(25,2))

Z = np.vstack((X,Y))
Z = np.float32(Z)

criteria = (cv.TERM_CRITERIA_EPS + cv.TERM_CRITERIA_MAX_ITER, 10, 1.0)
ret,label,center=cv.kmeans(Z,2,None,criteria,10,cv.KMEANS_RANDOM_CENTERS)

A = Z[label.ravel()==0]
B = Z[label.ravel()==1]

plt.scatter(A[:,0],A[:,1],c = 'b')
plt.scatter(B[:,0],B[:,1],c = 'r')
plt.scatter(center[:,0],center[:,1],s = 80,c = 'y', marker = 's')
plt.xlabel('Height'),plt.ylabel('Weight')
plt.show()
```



مثال : در مثال زیر می‌خواهیم تعداد رنگ‌های یک تصویر را کاهش دهیم به این کار **color Quantization** یا کوانتیزاسیون رنگ می‌گویند. این کار برای موارد نظیر کاهش حجم تصویر کاربرد دارد یا در بعضی موارد بعضی دستگاه‌ها تنها می‌توانند رنگ‌های محدودی را نشان دهند. از این رو نیاز است تا رنگ‌های یک تصویر را کوانتیزه کنیم. در این مثال ما سه کانال رنگی سبز و قرمز و آبی را به عنوان سه ویژگی در نظر می‌گیریم و مانند قبل عملیات خوشه بندی را دنبال می‌کنیم.

```

import numpy as np
import cv2

img = cv2.imread('dragon.jpg')
Z = img.reshape((-1,3))
Z = np.float32(Z)

criteria = (cv2.TERM_CRITERIA_EPS + cv2.TERM_CRITERIA_MAX_ITER, 10, 1.0)
K = 2
components,label=center=cv2.kmeans(Z,K,None,criteria,10,cv2.KMEANS_RANDOM_CENTERS)

center = np.uint8(center)

result=[]
for l in label :
    result.append (center[l])
result = np.array ( result)

result = result.reshape((img.shape))

cv2.imshow('res2',result)
cv2.waitKey(0)
cv2.imwrite ( "image" + str(K) + ".jpg" , result )
cv2.destroyAllWindows()

```


در زیر تصویر اصلی را به همراه تصاویر کوانتیزه شده با $k = 2, 3, 8$ را آورده ایم.




تشخیص شی در opencv (تشخیص چهره با haar-cascades)

تشخیص شی با استفاده از طبقه بندی آبشاری ها یک روش موثر برای تشخیص چهره است. این روش مبتنی بر یادگیری ماشین است که در آن یک تابع آبشاری با استفاده از تعداد زیادی تصاویر مثبت و منفی، برای تشخیص شی در تصاویر دیگر آموزش می‌بیند. در اینجا ما با تشخیص چهره کار خواهیم کرد. ابتدا الگوریتم به تعداد زیادی تصاویر مثبت (دارای چهره) و تصاویر منفی (بدون چهره) برای آموزش طبقه بندی، نیاز دارد. سپس باید ویژگی‌های آن را استخراج کنیم. برای اینکار از ویژگی‌های haar که برخی از آن‌ها تصویر زیر نشان داده شده‌اند استفاده می‌کنیم که هر ویژگی یک مقدار ثابت است و برابر است با:

مقدار Haar = مجموع پیکسل‌های زیر مستطیل مشکی - مجموع پیکسل‌های زیر مستطیل سفید



در این بخش تمام اندازه‌ها و محل‌های ممکن برای تمامی هسته‌ها برای محاسبه ویژگی‌های مورد استفاده واقع می‌شود. این موضوع حجم محاسبات را بسیار گسترده می‌کند و حتی برای پنجره‌ای 24×24 از یک تصویر بیش از ۱۶۰۰۰۰ ویژگی بدست می‌آید. و برای هر ویژگی باید مجموع پیکسل‌های زیر مستطیل‌های سیاه و سفید محاسبه شود. برای حل این مشکل از انتگرال تصویر بهره می‌بریم. اما از طرفی همه این ویژگی‌ها هم کارآمد نیستند. برای مثال در تصویر زیر در ردیف بالا دو پنجره در نظر گرفته شده است که ویژگی‌های خوبی را در تصویر نشان می‌دهند. برای مثال در تصویر اول روی این ویژگی تمرکز دارد که چشم‌ها اغلب تیره از بینی هستند و یا در تصویر دوم بر این ویژگی تمرکز دارد که چشم‌ها معمولاً از گونه و بینی تیره تر هستند. اما برای مثال همین هسته اگر بر روی قسمت‌های دیگر نظیر پیشانی یا گونه اعمال شود، بی‌فایده هستند. اما چگونه ویژگی‌های کارآمد را پیدا کنیم



برای این موضوع ما تک تک ویژگی‌ها را روی تصاویر آموزشی اعمال می‌کنیم و برای هر ویژگی بهترین حد آستانه را که تصاویر آموزشی را به مثبت و منفی (در اینجا چهره و غیر چهره) تقسیم می‌کند را می‌یابیم. مشخصاً در این بخش اشتباهات و خطاها پدیدار می‌شوند. ما ویژگی‌هایی را انتخاب می‌کنیم که حداقل خطا را داشته باشند یعنی ویژگی‌هایی که به طرز دقیق‌تر تصاویر مثبت و منفی را تقسیم بندی می‌کند. این یک فرایند پیچیده است. در نهایت ما مجموعه از ویژگی‌های ضعیف داریم. ضعیف به این منظور که هیچکدام از این ویژگی‌ها نمی‌توانند تقسیم بندی خوبی ارائه دهند اما این ویژگی‌ها در کنار هم یک طبقه بندی قوی ارائه می‌دهند. در یک مقاله حتی با ۲۰۰ ویژگی به دقت درصد دست یافته بودند و نسخه نهایی شامل ۶۰۰۰ ویژگی بود که نسبت به ۱۶۰۰۰۰ ویژگی یک کاهش چشمگیر است.

پس حال باید مثلاً با استفاده از یک پنجره 24×24 و ۶۰۰۰ ویژگی را روی یک تصویر اعمال کنیم تا ببینیم که آیا تصویر شامل شی مورد نظر هست یا خیر. اما این نیز زمان بر است. راه حل مشکل در در نظر گرفتن این موضوع است که عموماً همه تصویر شامل شی مورد نظر نیست پس این ایده خوبی است که بررسی کنیم اگر یک پنجره چهره نیست، آن را کنار گذاشته و از پردازش دوباره آن پرهیز کنیم. در عوض تمرکز را بر روی بخش هایی از تصویر بگذاریم که احتمالاً چهره هستند و زمان بیشتری را صرف مناطق ممکن می کنیم. برای این موضوع از طبقه آشنایی استفاده می کنیم. به این صورت که به جای آنکه هر ۶۰۰۰ ویژگی را روی یک پنجره اعمال کنیم، ویژگی ها را دسته بندی کرده و در مراحل مختلف اعمال کنیم و اگر یک پنجره در یک مرحله مردود شود در مراحل بعدی آن را در نظر نمی گیریم. و پنجره هایی در هر مرحله کنار گذاشته می شوند و پنجره ای که در آخر می ماند شامل شی مورد نظر ما است. مشخصاً در مراحل اولیه ویژگی های کمتری را بررسی می شود. برای مثال در مقاله مذکور، ۶۰۰۰ ویژگی در ۳۸ مرحله بررسی می شوند که در ۵ مرحله اول به ترتیب ۵۰، ۲۵، ۱۰، ۱۰ و ویژگی بررسی می گردد

کتابخانه opencv شامل یکسری پیش آموزش های آماده برای آبجکت هایی نظیر، صورت، چشم، لبخند و... است که این پیش آموزش ها با پسوند xml. در مسیر opencv / sources / data / haarcascades موجود است. در زیر یک مثال برای استفاده از این دیتاهای آماده آورده شده است

مثال : در این مثال با استفاده از پیش آموزش های طبقه بندی شدی opencv برای تشخیص چهره و چشم استفاده می کنیم. در ابتدا با لود کردن این فایل ها با استفاده از تابع detectMultiScale() چهره های موجود در تصویر را تشخیص می دهیم و در چهره ها با استفاده از همین تابع چشم ها را تشخیص می دهیم.

`detectMultiScale ( image , scaleFactor , minNeighbors ) -> X, Y, W, H`

- image: تصویر ورودی که می خواهیم شی را در آن تشخیص دهیم که نوع آن باید خاکستری باشد.
- scaleFactor: مشخص می کند که اندازه تصویر به چه میزان کاهش یابد.
- minNeighbors: حداقل تعداد قابل قبول همسایه ها را مشخص میکند.

خروجی این تابع نیز یک قاب مستطیلی است که محل شی مورد نظر را نشان می دهد و به فرمت x, y, w, h می باشد.

```

import numpy as np
import cv2
face_cascade = cv2.CascadeClassifier('haarcascade_frontalface_default.xml')
eye_cascade = cv2.CascadeClassifier('haarcascade_eye.xml')


img = cv2.imread('sachin.jpg')
gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)

faces = face_cascade.detectMultiScale(gray, 1.3, 5)

for (x,y,w,h) in faces:
    cv2.rectangle(img,(x,y),(x+w,y+h),(255,0,0),2)
    roi_gray = gray[y:y+h, x:x+w]
    roi_color = img[y:y+h, x:x+w]
    eyes = eye_cascade.detectMultiScale(roi_gray)

    for (ex,ey,ew,eh) in eyes:
        cv2.rectangle(roi_color,(ex,ey),(ex+ew,ey+eh),(0,255,0),2)
cv2.imshow('img',img)

```



شناسایی چهره (face recognize) (اختیاری)

برای شناسایی یک چهره ما نیازمند به یادگیری متریک عمیق هستیم. در یادگیری و یادگیری عمیق ما یک تصویر به سیستم می‌دادیم و سیستم آن تصویر را کلاس‌بندی می‌کرد. اما در یادگیری متریک عمیق به جای برچسب گذاری، هدف دریافت یک بردار ویژگی قوی است. برای شبکه عصبی dlib، این بردار ویژگی یک بردار یا ۱۲۸ مقدار عددی می‌باشد که ویژگی‌های تصویر را ارائه می‌دهد. این شبکه عصبی عمیق با معماری VAE توصیه یافته است که در آن شبکه عصبی با فشرده سازی تصویر و بازنمایی مجدد آن، آموزش می‌بیند.

Picture of
Chad Smith



Test picture of
Will Ferrell



Another picture of
Will Ferrell



برای مثال تصویر بالا را در نظر بگیرید که دو تا متعلق به ویل فرل و یکی متعلق به چاد اسمیت است. شبکه ما یک بردار شامل ۱۲۸ داده ۸ بیتی، برای هر تصویر ارائه می‌دهد و ما وزن‌ها را طوری اصلاح می‌کنیم که بردار ویژگی دو تصویر ویل فرل نزدیک به هم و متفاوت از بردار ویژگی تصویر چاد اسمیت باشند. لازم به ذکر است که خود این شبکه عصبی بر پایه دیتابسی شامل ۳ میلیون عکس آموزش دیده است.

مقالات مفصلی برای نحوه شناسایی چهره در الگوریتم تشخیص چهره با کیفیت بالا با یادگیری عمیق متریک (ارایه شده توسط دیویس کینگ) و تشخیص چهره مدرن با یادگیری عمیق (ارایه شده توسط آدام گیتگی) ارائه شده است که می‌توانید برای درک بهتر به آن‌ها مراجعه کنید.

برای شروع لازم است که کتابخانه‌های face_recognition و dlib را نصب نموده. برای نصب کافی است دستورات زیر را در محیط cmd خود اجرا نمایید. لازم به ذکر است که پیش از این دو پکیج لازم است cmake را به همین روش نصب نمایید

```
pip install dlib
```

در صورتی که با دستور بالا نصب نشد دستور زیر را امتحان نمایید.

```
pip install https://pypi.python.org/packages/da/06/bd3e241c4eb0a662914b3b4875fc52dd176a9db0d4a2c915ac2ad8800e9e/dlib-19.7.0-cp36-cp36m-win_amd64.whl#md5=b7330a5b2d46420343fbed5df69e6a3f
```

```
pip install face_recognition
```

```

import face_recognition

picture_of_me = face_recognition.load_image_file("me.jpg")
my_face_encoding = face_recognition.face_encodings(picture_of_me)[0]

# my_face_encoding now contains a universal 'encoding' of my facial features that can be
# compared to any other picture of a face!

unknown_picture = face_recognition.load_image_file("unknown.jpg")
unknown_face_encoding = face_recognition.face_encodings(unknown_picture)[0]

# Now we can see the two face encodings are of the same person with `compare_faces`!

results = face_recognition.compare_faces([my_face_encoding], unknown_face_encoding)

if results[0] == True:
    print("It's a picture of me!")
else:
    print("It's not a picture of me!")

#face_locations = face_recognition.face_locations(image)
# boxes = face_recognition.face_locations(rgb, model=args["detection_method"])
#encodings = face_recognition.face_encodings(rgb, boxes)

```

همانطور که مشخص است ابتدا یک تصویر از فرد مورد نظر لود میکنیم و بردار ویژگی آن را استخراج می‌کنیم، سپس یک تصویر ناشناخته را لود کرده و بردار ویژگی‌های آن را هم استخراج می‌کنیم و در نهایت بردار ویژگی دو تصویر را باهم مقایسه می‌کنیم. بخش آخر که به صورت کامنت درآمده است برای استخراج صورت در یک تصویر است. نکته مهمی که باید بدان اشاره کرد در opencv تصاویر به صورت bgr هستند ولی در dlib تصاویر rgb بوده و باید در کار کردن با این دو کتابخانه این موارد را در نظر گرفت.

