

Uydu Görüntülerinden Uçak Tespit Etme

Aircraft Recognition from Satellite Images

Mehmet OTURAK^{1,2}, Seniha Esen YÜKSEL²

1. Uzay Teknolojileri Araştırma Enstitüsü
TÜBİTAK UZAY
Ankara, Türkiye
mehmet.oturak@tubitak.gov.tr

2. Elektrik ve Elektronik Mühendisliği Bölümü
Hacettepe Üniversitesi
Ankara, Türkiye
eyuksel@ee.hacettepe.edu.tr

Özetçe— Bu çalışmada uydu görüntülerinden hızlı ve doğruluk oranı yüksek olarak uçak tespit etme metodu geliştirilmiştir. Yöntem olarak AdaBoost algoritması kullanılmış ve Viola-Jones'un gerçek zamana yakın ve yüksek doğruluk oranı sağlayan haar benzeri öznitelikleri kullanan yüz tanımlama çalışması referans olarak alınmıştır. Mevcut çalışmalarda, bir resmin pozitif olarak değerlendirilmesi için, alt pencerenin kaskat bağlanan tüm güçlü sınıflandırıcılardan geçmesi gerekmektedir. Bu çalışmada ise bahsedilen yönteme ilave bir yenilik olarak, ardışık bağlanan güçlü sınıflandırıcı çıktı değerleri de toplanarak bir eşik değeri ile karşılaştırılmaktadır. Bu sayede hızlı ve yüksek doğruluk oranına sahip bir sınıflandırıcı elde edilmektedir.

Anahtar Kelimeler — AdaBoost; haar benzeri öznitelikler; sınıflandırıcı; uçak tespiti.

Abstract— In this work, rapid and high-accurate aircraft detection method in satellite images is developed. To this end, AdaBoost learning algorithm is used and Viola-Jones' near real time and high-accurate face detector utilizing haar-like features is taken as reference. In existing studies, for a sub window to be positive, it must pass through all the strong classifiers as positive. However, in this work the strong classifier output values are summed up and compared to a threshold value as well. Therefore, besides the cascade structure's ability to eliminate negative sub windows rapidly, more elaborate evaluation is made on the class of sub window, giving rise to a high performance classifier.

Keywords — Haar-like features; AdaBoost; Classifier; Aircraft Recognition.

I. GİRİŞ

Nesne tanımlamaya yönelik genel olarak iki yapısal sistem bulunmaktadır: Veriye dayalı aşağıdan yukarıya strateji ve bilgiye dayalı yukarıdan aşağıya strateji. İlk yöntemde, hangi nesne bulunacağına bağlı olmaksızın bir ön işleme gerçekleştirilmektedir. Bu işlemler bölütleme, etiketleme ve özellik çıkarma gibi işlemlerdir. Daha sonra, çıkartılan özellik vektörleri hedef model ile karşılaştırılarak sınıflandırma gerçekleştirilir. Burada nesne tanımlama yöntemi hem düşük seviye ön işlem hem de yüksek seviye

karşılaştırma işlemlerini içermektedir [3]. Bu yöntem geniş bir uygulama alanına sahip olup çoğu hedef tanıma uygulamalarında kullanılabilir; fakat düşük seviyede kullanılan ön işleme kısmı yüksek işlem gücü ve zaman gerektirir. [3] ve [7]'de bu yöntem ile yapılmış uygulamalar yer almaktadır. Ön işlem olarak bölütleme ve Gabor Filtreleme uygulanmış olup, sınıflandırıcı olarak SVM kullanılmıştır. Diğer stratejide, tespit edilecek nesneye yönelik olarak ön bilgi mevcuttur ve muhtemel özelliklerin bulunduğu varsayımı yer almaktadır. Düşük seviyede işleme bilgiye dayalı olduğu için, burada özellik çıkarma işlemi yapılmaz ve yüksek seviye eşleştirme işlemi gerçekleştirilir [4].

Nesne tanımlamada, yapısal öznitelikler (feature) uygulamaya yönelik olarak belirli bilgileri kodladığı için, bu yöntemi kullanılan çalışmalarda sonuçların doğruluğu piksel tabanlı çalışmalarda sonuçların doğruluk oranlarından yüksektir. Bu sebeple doğruluk oranlarının yüksek olması ve hızlı çalışmaları sebebi ile bu çalışmada haar benzeri özniteliklere (haar-like features) dayalı, AdaBoost algoritması kullanılmıştır [5]. Buradaki çalışmada, mevcut AdaBoost algoritma yapılarındaki güçlü sınıflandırıcı kaskat bağlantı yapısına ilave olarak, her bir güçlü sınıflandırıcının üretmiş olduğu değerlerin ağırlıklandırılmış toplamının değerlendirilmesi yöntemi önerilmektedir. Pozitif ve negatif görüntülerden bu yöntem ile üretilen sayısal verilere ait histogramda, bu iki farklı sınıfı birbirinden ayıran olasılık yoğunluk dağılımı elde edilmiştir. Dağılımlara bağlı olarak seçilen bir eşik değeri ile düşük hata değerli bir sınıflandırıcı elde edilebilmektedir.

II. HAAR BENZERİ ÖZİNTELİKLERİN HESAPLANMASI

Tespit edeceğimiz uçak görüntüleri, uydu veya benzeri uzaktan algılama sistemleri tarafından elde edilmiş görüntüler üzerinde olacaktır. Bu görüntülerde uçaklar kendine has belli bir yapıya sahiptir. Bu belli yapıya sahip uçakları tespit etmek için haar-benzeri öznitelikleri kullanmak uygundur ve aşağıdaki beş farklı yapıdaki öznitelik bu amaçla kullanılmıştır.

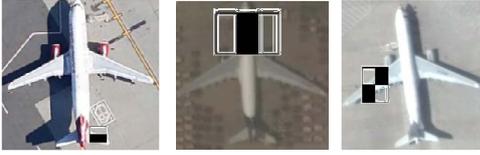
Bu haar-benzeri öznitelikler, beyaz bölgeye karşılık gelen piksel değerleri ile siyah bölgeye karşılık gelen

piksel değerleri arasındaki farkın belli bir eşik değerini aşması kuralına göre çalışmaktadır



Şekil 1 Uydü görüntülerinden uçak tespit etmek amacıyla AdaBoost algoritmasında kullanılan haar benzeri öznitelikler. (a) Kenar şekilleri, (b) Gövde şekilleri ve (c) Çapraz yapı şekilleri.

Hesaplanan değer eğer eşik değerinin üzerinde ise 1, değilse 0 değerinde sonuç üretilmektedir. Şekil 2’de üç farklı haar özniteliğinin farklı uçak görüntüleri üzerinde çeşitli konumlanmaları gösterilmiştir



Şekil 2 Farklı uçak görüntüleri üzerinde yer alan haar benzeri öznitelikler. Uçaklar, kendilerine has olan yapılarının haar benzeri öznitelikler ile öğrenilip, bu özniteliklerin birlikte çalışması ile tespit edilmektedir.

Haar değerlerini hızlıca hesaplayabilmek için Viola-Jones’un çalışmasındaki bütün görüntü (integral image) yöntemi kullanılmıştır.

III. ADABOOST SINIFLANDIRICI İLE HAAR EĞİTİMİ

AdaBoost algoritması İngilizce **Adaptive boosting** kelimelerinden türetilmiştir. Algoritmanın uyarlamalı olması, her bir aşamada yanlış sınıflandırılan örneklerin bir sonraki aşamada ağırlığının artırılmasından; algoritmanın yükselten olması da, çok sayıda zayıf sınıflandırıcının birlikte çalışarak güçlü sınıflandırıcıya dönüşmesinden kaynaklanır.

A. Zayıf Sınıflandırıcı

AdaBoost ile seçilen her bir haar özniteliği zayıf sınıflandırıcıdır. Her bir haar özniteliği, görüntü tespitinde hedef olarak seçilen nesnenin belirli bir özelliğini ayırt edecek şekilde öğrenmeyi gerçekleştirir. Şekil 3’te bir kenar haar özniteliği, uçağın kanat bölgesine yakın olan gövde kısmını öğrenmiş durumdadır. Öğrenme, seçilmiş olan bir haar özniteliğinin ürettiği değerlerin bir eşik değeri ile karşılaştırılmasıdır.



Şekil 3 Öğrenmeyi gerçekleştirmiş bir haar özniteliği, alt pencerede öğrenmiş olduğu bilginin yer alıp almadığına bakmaktadır. Soldaki görüntüde haar özniteliği uçağın olabileceği anlamına gelen 1 sonucunu dönerken sağdaki görüntüde uçağın olmadığı anlamına gelen 0 sonucunu döner.

Herhangi bir haar özniteliğinin değeri (f), formül (1) ile hesaplanır.

$$f = \sum (\text{beyazdaki pikseller}) - \sum (\text{siyahdaki pikseller}) \quad (1)$$

Öğrenilmiş olan bir haar özniteliğinin zayıf sınıflandırıcı olarak görev yapabilmesi için, algoritmada o haar özniteliğinin eşik değeri (θ) ve polaritesinin (p) belirlenmesi gerekir [5]. Formül (1) ile elde edilen f değeri kullanılarak, her bir x resmine ait zayıf sınıflandırıcı değeri (h), aşağıdaki gibi hesaplanır:

$$h(x, f, p, \theta) = \begin{cases} 1 & \text{pf}(x) < p\theta \\ 0 & \text{aksi taktirde} \end{cases} \quad (2)$$

Zayıf sınıflandırıcı seçimi için algoritmaya başlarken, her bir pozitif ve negatif resme kendi içinde ağırlıkların toplamı 0.5 olacak şekilde eşit ağırlıklar verilir. Pozitif görüntülerin sayısına m , negatif görüntülerin sayısına da l dersek, her bir resmin ağırlığı (w_i) pozitif ve negatif görüntüler için sırasıyla şu şekilde hesaplanır,

$$w_i = 1/2m \quad i = 1, 2, \dots, m \quad (3)$$

$$w_i = 1/2l \quad i = 1, 2, \dots, l \quad (4)$$

Birinci döngüde ($t = 1$) ağırlıklar ilk değerini aldıktan sonra sırası ile tüm olası haar öznitelikleri pozitif ve negatif görüntüler üzerinde (2) formülüne göre hesaplanır. Pozitif görüntülerin etiket değeri $y_i = 1$, negatif görüntülerin etiket değeri de $y_i = 0$ olacak şekilde her bir haar özniteliğinin hata değeri (ϵ_t) hesaplanır. Elde edilmiş olan hata değerleri arasından en küçük olanını veren haar özniteliği, en iyi zayıf sınıflandırıcı olarak seçilir. Burada kullanılan, hata değeri elde etme formülü şu şekildedir.

$$\epsilon_t = \min_{f, p, \theta} \sum_{i=1}^N w_i |h(x_i, f, p, \theta) - y_i| \quad (5)$$

Toplama işlemi N adet olan tüm pozitif ve negatif görüntüler kapsar. Mutlak değer içerisindeki ifade doğru sınıflandırmalar için 0, yanlış sınıflandırmalar için 1 çıkacağından, hata değeri matematiksel olarak yanlış sınıflandırılan görüntülerin ağırlıklarının toplamıdır.

AdaBoost algoritması yanlış sınıflandırılan görüntülerin ağırlıklarının artırılarak yeni zayıf sınıflandırıcıların bulunması esasına dayanmaktadır. Bir sonraki döngüye geçerken ($t = 1, 2, \dots, k$) yeni ağırlıklar şu şekilde elde edilir.

$$w_{t+1, i} = w_{t, i} \beta_t^{1 - e_i} \quad (6)$$

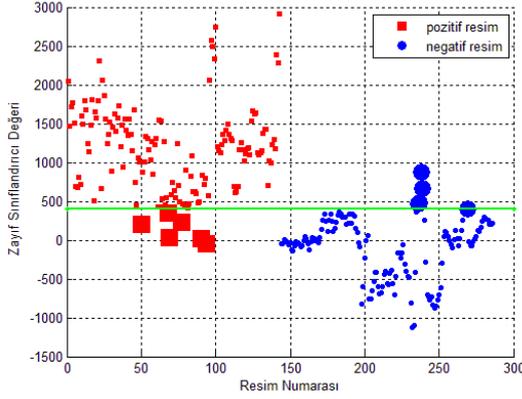
Eğer görüntü x_i doğru sınıflandırılmışsa $e_i = 0$, yanlış sınıflandırılmışsa $e_i = 1$ dir. Burada,

$$\beta_t = \frac{\epsilon_t}{1 - \epsilon_t} \quad (7)$$

olarak verilir. Bir sonraki sınıflandırıcı seçimine başlamadan önce ağırlıklar tekrar toplamı 0.5 olacak şekilde güncellenir.

$$w_{t,i} = \frac{w_{t,i}}{\sum_j w_{t,j}} \quad (8)$$

Şekil 4'te en iyi zayıf sınıflandırıcının, pozitif ve negatif test görüntüleri üzerindeki sınıflandırması gösterilmektedir.



Şekil 4 En İyi Sınıflandırma ve Ağırlık Güncelleme. Formül (1)'e göre elde edilen haar özneliklerinin değerleri pozitif görüntüler kare (kırmızı) negatif görüntüler nokta (mavi) olacak şekilde gösterildiğinde bu şekilde ortaya çıkmaktadır. Sembol büyüklükleri ağırlıkları göstermektedir. İlk döngüde (3) ve (4) denklemleri ile belirlenen ve eşit olan ağırlıklar sonraki döngüde (6) ve (8) denklemlerine göre güncellenecektir. Eşik değerini (θ) gösteren çizginin diğer tarafında kalan görüntülerin (yanlış sınıflandırılan görüntülerin) ağırlıkları sonraki döngüde artmaktadır.

B. Güçlü Sınıflandırıcı

Tek bir zayıf sınıflandırıcı ile istenilen oranlarda pozitif görüntüleri tespit etmek ve negatif görüntüleri elemek mümkün değildir. Bu yüzden birden fazla zayıf sınıflandırıcının birlikte çalışması ile güçlendirilmiş bir sınıflandırıcı elde edilir. Burada her bir zayıf sınıflandırıcı güçlü sınıflandırıcıyı oluştururken bir ağırlık değerine sahip olmaktadır. Bu ağırlık da aşağıdaki gibi hesaplanır [5]:

$$\alpha_i = \log(1/\beta_i) \quad (9)$$

Böylece her bir zayıf sınıflandırıcı sınıflandırma sonucuna göre çıkan hata ile ters orantılı olacak şekilde bir ağırlığa sahip olmuş olur.

Her bir zayıf sınıflandırıcı ilavesi ile ortaya çıkan yeni güçlü sınıflandırıcı formül 10'a göre teste tabi tutulur

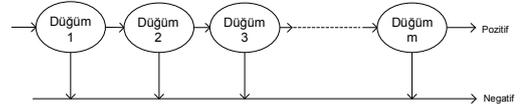
$$C(x_i) = \begin{cases} 1 & \sum_{i=1}^k h_i(x)\alpha_i \geq \theta_j \\ 0 & \text{aksi takdirde} \end{cases} \quad (10)$$

Buradaki θ_j eşik değeri için güçlü sınıflandırıcının performansını artıracak herhangi bir değer seçilebilir. Güçlü sınıflandırıcı için doğru pozitif oranı ve doğru negatif oranı hedef olarak belirlenir. Formül (10)

kullanılarak, hedeflenen oranlara ulaşmaya kadar zayıf sınıflandırıcı eklenerek güçlü sınıflandırıcı elde edilir. Bu çalışmada güçlü sınıflandırıcı eşik değeri belirlenirken, %100 doğru pozitif oranı ve %30 doğru negatif oranı hedef olarak seçilmiştir. Bu oranlar Viola-Jones'un çalışmasında verilen oranlara yakındır.

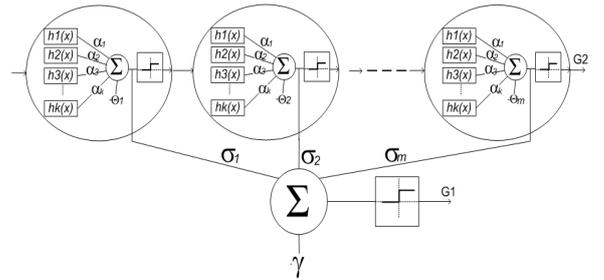
C. Kaskat Sınıflandırıcı

Bu şekilde oluşturulan güçlü sınıflandırıcı yüksek doğru pozitif ve yanlış pozitif oranına sahip olacaktır. Bu sebeple, çok sayıda güçlü sınıflandırıcı kaskat olarak bağlanırsa yanlış pozitif görüntü oranı da üstel olarak azalacaktır. Örneğin, eğer 10 adet güçlü sınıflandırıcı kaskat bağlanır ve her bir güçlü sınıflandırıcıda %30 doğru negatif oranı (= 0.7 yanlış pozitif oranı) hedeflenirse sonuç olarak ortaya çıkan yapıda $0.7^{10} \approx 0.03$ değerinde bir yanlış pozitif oranına ulaşılabilecektir. Yani her 100 negatif görüntüden 3 tanesi pozitif olarak değerlendirilecektir.



Şekil 5 Literatürdeki AdaBoost sezimci yapısı. En soldan sınıflandırıcıya giren görüntü, herhangi bir güçlü sınıflandırıcıda negatif olarak değerlendirilirse, negatif olarak işaretlenir. Tüm sınıflandırıcılardan pozitif olarak geçen görüntüler pozitif olarak işaretlenir[2].

Verilen örnek hesaplama için yaklaşık 1000 pozitif görüntü ve 2000 civarında negatif görüntü gerekmektedir. Bu hesaplanan 0.03 oranını daha da düşürmek için Viola-Jones çalışmalarında çok daha yüksek sayıda eğitim verisi ile çalışmışlardır. Burada önerilen yapı ile daha az eğitim verisi kullanarak yüksek doğruluk oranına sahip hızlı bir sınıflandırıcı elde edilebilmektedir.



Şekil 6 Önerilen sezimci yapısı. Bir resmin pozitif olarak değerlendirilebilmesi için tüm sınıflandırıcılardan pozitif olarak geçmesi yeterli değildir. Güçlü sınıflandırıcıların çıktılarında elde edilen ağırlıklandırılmış toplam değer de bir eşik değerini (γ) geçmesi gerekmektedir. Herhangi bir sınıflandırıcıda negatif olarak değerlendirilen görüntü sonuç olarak sezimcide negatif olarak işaretlenir.

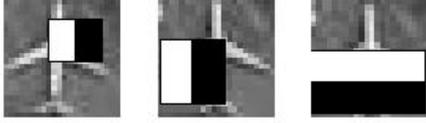
Burada G2 çıktısı ile elde edilen sonuç önceki yöntemlerdeki ile aynıdır. G1 ile elde edilen yeni sonuç ise şu şekilde verilebilir.

$$GI(x) = \begin{cases} 1 & \sum_{j=1}^m \sigma_j \sum_{i=1}^k h_i(x) \alpha_i \geq \gamma \\ 0 & \text{aksi takdirde} \end{cases} \quad (11)$$

Burada iç toplama indeksi zayıf sınıflandırıcılara, dış toplama indeksi de güçlü sınıflandırıcılara karşılık gelmektedir.

IV. SONUÇLAR

AdaBoost sınıflandırıcıyı, 800 pozitif ve 1600 negatif test resmi ile eğitime tabi tutunca, 7 güçlü sınıflandırıcı ortaya çıktı. Bu sınıflandırıcılar 3 ile 12 arasında zayıf sınıflandırıcı içermektedir. Örneğin birinci güçlü sınıflandırıcı için elde edilen zayıf sınıflandırıcılar aşağıda Şekil 7 'de yer almaktadır.



Şekil 7 Eğitim sonrası ortaya çıkan 7 katlı AdaBoost sezimcinin ilk güçlü sınıflandırıcısında yer alan zayıf sınıflandırıcıları.

Bu zayıf sınıflandırıcılara ait nümerik değerler aşağıda Tablo 1 'de verilmektedir.

	1.Zayıf Sınıflandırıcı	2.Zayıf Sınıflandırıcı	3.Zayıf Sınıflandırıcı
x-koordinatı	10	2	1
y-koordinatı	5	9	11
Genislik	10	12	22
Yükseklik	8	12	12
Haar Tipi	2	2	1
θ	398	-266	5294
p	-1	1	1
α	3.3178	3.4386	2.7946

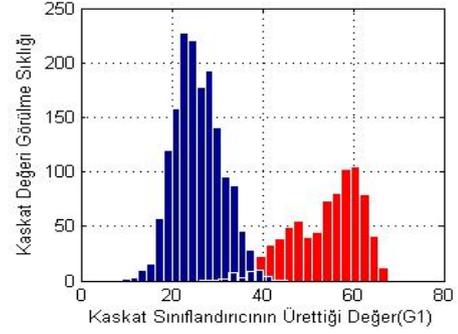
Tablo 1 Şekil 7 de verilen zayıf sınıflandırıcılara ait sayısal değerler. İlk 4 değer haar özneliğinin alt penceredeki konumunu ve ölçüsünü gösterir. Haar tipi, şekil 1 de verilen 5 farklı tiplerden hangisinin kullanıldığını belirtir. Son üç değer (2) ve (9) formülleri ile belirlenen parametrelerdir.

Burada x ve y koordinatları, özneliklerin sol üst köşesine ait koordinatlardır. Bu zayıf sınıflandırıcıların oluşturmuş olduğu güçlü sınıflandırıcıya ait eşik değeri de $\Theta = 4.7755$ olarak elde edilmiştir.

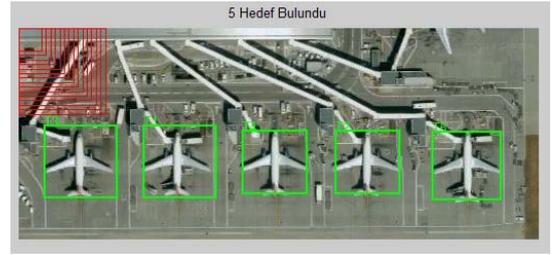
V. YORUMLAR

E. Polat ve C. Yıldız, SVM tabanlı bir sınıflandırıcı kullanarak uydu görüntülerinden durağan uçakları tespit etme çalışması gerçekleştirmiş [7] ve elde edilen sezimci sonuçlarını şu şekilde vermiştir: 54 uçak içeren 58 uydu görüntüsünde 49 uçak tespit edilmiş, 4 tane yanlış pozitif elde edilmiştir. Bir diğer uydu görüntüleri üzerinden uçak tespit etme metodunda W. Li ve diğerleri, görsel belirginlik hesaplaması ve simetri tespiti metodunu [6] kullanmış ve sezimci sonuçlarını şu şekilde vermiştir: 14 uçak içeren 2 uydu görüntüsünde 13 uçak tespit edilmiş ve yanlış pozitif elde edilmemiştir. Burada yapılan çalışmada ise 800

pozitif, 1600 negatif görüntü ile AdaBoost çalıştırılmış ve 7 katlı 62 zayıf sınıflandırıcılı bir sezimci elde edilmiştir. Bu sezimci ile 73 uçak resmi içeren 14 görüntü üzerinde yapılan test sonucuna göre 72 uçak tespit edilmiş ve 5 tane yanlış pozitif elde edilmiştir.



Şekil 8 Kaskat sınıflandırıcı çıktısı histogramı. (11) formülü tüm görüntülere uygulandığında (σ 'lar 1 seçilerek) solda (mavi) negatif görüntülere ait ve sağda (kırmızı) pozitif görüntülere ait olasılık yoğunluk dağılımları elde edilmiştir. Seçilecek bir eşik değeri (γ) ile hata az olacak şekilde iki sınıf birbirinden ayrılabilir.



Şekil 9 Londra havalimanından alınan bir görüntü üzerinde algoritmanın çalıştırılması ile elde edilen sonuç.

KAYNAKÇA

- [1] Y. Freund and R. E. Shapire, "A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting", *Journal of Computer and System Sciences*, vol. 55, No. 1, pp. 119-139, 1997.
- [2] S.-K.Pavani, D. Delgado, A. F. Frangi, "Haar-like features with optimally weighted rectangles for rapid object detection", *Pattern Recognition*, Vol. 43, issue 1, pp. 160-172, January 2010
- [3] G. Liu, X. Sun, K. Fu, and H. Wang, "Aircraft Recognition in High-Resolution Satellite Images Using Coarse-to-Fine Shape Prior", *IEEE Geoscience And Remote Sensing Letters*, Vol. 10, No. 3, pp. 573-577, may 2013
- [4] Y. Ke, J. Zhao*, Z. Yuan, C. Qu, S. Han, Z. Zhang, X. Jiang, G. Liang, "A Rapid Object Detection Method for Satellite Image with Large Size", *2009 Int. Conf. on Multimedia Inf. Networking and Security*. Vol. 1, pp. 637-641, 18-20 Nov. 2009, Hubei
- [5] P. Viola, M. J. Jones, "Robust Real-Time Face Detection", *International Journal of Computer Vision*, Vol. 57 (2), pp. 137-154, 2004
- [6] W. Li, S. Xiang, H. Wang, C.Pan, "Robust Airplane Detection in Satellite Images", *18th IEEE International Conference on Image Processing*, 2011
- [7] E. Polat, C. Yıldız, "Stationary Aircraft Detection From Satellite Images", *IU-JEEE*, Vol. 12 (2), pp. 1523-1528, 2012