

Destek Vektör Makineleri ve Yapay Sinir Ağları Kullanarak Türkiye'deki Tehlikeli Hava Durumlarının Uydu Görüntüleri ile Erken Tespiti Early Detection of Hazardous Weather Conditions in Turkey with Satellite Images Using Support Vector Machines and Artificial Neural Networks

Musa AYDIN
Elektrik Elektronik Mühendisliği Bölümü
İstanbul Aydın Üniversitesi, İSTANBUL
musaaydin@aydin.edu.tr

Enes ÇELİK
Bilgisayar Programcılığı Bölümü
Kırklareli Üniversitesi, KIRKLARELİ
enes.celik@kirkklareli.edu.tr

ÖZETÇE

Meteorolojik olaylar sonucunda ortaya çıkan yağışların önceden tahmin edilerek, zararlarının en aza indirilmesi önemli unsurlardan birisidir. Yerel Meteoroloji radarları bölgesel tabanlı çalıştığı için yağış gibi parametrelerin temsil edilmesinde yetersiz kalmaktadır. Bu radarların erken tespit için yetersiz kalmasından ötürü uydu görüntülerini kullanarak karar sistemleri oluşturulabilir. Bu noktada kızılötesi uydu görüntüleri önce sınıflandırılacak sonra test aşamasında karşılaştırılmalı sonuçları irdelenecektir. Çalışmamızda kızılötesi uydu görüntülerine Dalgacık Dönüşümü uygulanarak yaklaşım katsayıları elde edilmiştir. Bu katsayılar Temel Bileşenler Analizi ile boyutları indirgenmiştir ve kullanılan sınıflandırma algoritmaları ile sınıflandırmaya tabi tutulmuştur. Sınıflandırmada Yapay Sinir Ağları ve Destek Vektör Makineleri kullanılmıştır. Yapay Sinir Ağları ile sınıflandırma sonucunda %84 oranında erken tespit saptanmıştır. Destek Vektör Makineleri ile yapılan sınıflandırmada %93 oranında erken tespit saptanmıştır.

Anahtar Kelimeler : Destek Vektör Makineleri, Yapay Sinir Ağları, Uydu Görüntüleri, Erken Tespiti

ABSTRACT

The prediction of meteorological phenomena resulting from rainfall, is one of the most important elements of the minimization of the damages. Local meteorological radars works at regional base hence they cannot represent the parameters of precipitation. Because of insufficiency of the radar systems early detection, satellite images can be used to create decision systems. At this point firstly infrared satellite images will be classified and then comparative results will be discussed on experimental stage. In this work, we used Wavelet Transform applied to infrared satellite images to extract approximation coefficients. Size of these coefficients are reduced using Principal Component Analysis and classified through classification algorithms. Artificial Neural Network and Support Vector Machines are used for classification. As a result of the classification made with

Artificial Neural Networks, we accomplished 84% prediction rate. With the classification of Support Vector Machines, we reached 93% prediction rate.

Keywords: Support Vector Machines, Artificial Neural Networks, Satellite Images, Early Detection

1. GİRİŞ

Dünya ve Türkiye doğal afetlerle iç içe yaşamaktadır. Sebep oldukları can ve mal kayıplarından dolayı, afetlerin erkenden tespiti insanoğlunun üzerinde çalıştığı bir konudur.

İklim ve hava tahminleri, iklim değişimlerinin etki analizi, bulut ve yağış dağılımı, bulut kapsamı (içeriği), yağışla ilgili bilgi çıkarımı, hava akımları, yeryüzü ve deniz yüzeyi ısısının dağılımı, don ve taşkın alanı risk uyarısı çalışmaları gibi meteorolojik çalışmalar içinde yer alır.

Kısa süreli aşırı yağışlar önemli taşkınlara neden olmaktadır. Sel, fırtına kar ve dolu gibi meteorolojik karakterli afetler, en çok can ve mal kaybının gözlendiği doğal olaylardır [1].

Bu tür afetlerin önceden tespit edilerek gerekli uyarıların yapılması için yoğun çaba sarf edilmektedir. Ancak, ortada bulunan en önemli problem, alansal yağışın temsilliğinin zorluğudur. Bunun nedeni ise, noktasal ölçüm yapan radarların gerekli sıklıkta bulunmayışı ve yağış parametresinin uzaysal değişkenliğinin yüksek olmasıdır [2].

Bu doğrultuda, yüksek çözünürlüklü uydu görüntüleri, gerçek zamanlı sistemler ve yapay zekâ teknikleri ile geliştirilerek afetlerin fiziksel yapısını anlamak için kullanılmıştır. Kaynakların doğru ve etkin kullanım kararlarının verilebilmesi için kaynak alanına ait verilerin gerçekçi, güvenilir, kontrole olanak tanıyan, çabuk elde edilebilir, zaman içindeki değişim ve gelişmeleri izlemeye olanak tanıyan bir kaynaktan elde edilmesi gerekir. Uzaktan algılama verisi olan hava fotoğrafları ve uydu görüntüleri bu kaynakları oluşturmaktadır. Uzaktan algılama verilerinden olan uydu

görüntüleri dünyada binlerce işe ve yüzlerce endüstriye değerli bilgiler sağlamaktadır.

Uydu görüntüleri üzerine bilgi katmanlarının girilmesi ve bu katmanların çakıştırma - birleştirme işlemi ile çakıştırılmasıyla çalışılan alana ait tüm bilgileri içeren temel sorgulama katmanı elde edilebilir. Uzaktan algılama verileri, alana bir anda geniş bir açıyla bakma ve değerlendirme imkânı sağlamakta, alana ait verilerin gösterimi ve sunumu kolaylıkla yapılmaktadır. Bunun yanında uzaktan algılama verileri çalışma şartlarının zorluğu nedeni ile girilemeyen sahaların araştırılmasına da imkân tanımaktadır [3].

Yağış, akışı meydana getiren en önemli değişkendir. Kısa süreli aşırı yağışlar önemli taşkınlara neden olmaktadır. Karmaşık bir fiziksel süreç sonucunda meydana gelen yağışın doğru tahmin edilmesi genellikle zordur. Özellikle yersel değişimlerden ve bölgesel özelliklerden oldukça etkilenmesi yağışın tahminini daha da zorlaştırmaktadır.


Doğrusal olmayan sistemlerin davranışında başarıyla kullanılabilen yapay sinir ağları, destek vektör makineleri böylesine karmaşık değişkenlerin tahmininde başarıyla kullanılmaktadır. Sınıflandırma aşamasında tahmindeki başarıyı arttırmak için yardımcı olarak dalgacık dönüşümü, temel bileşenler analizi ve bazı istatistiksel özellikler kullanılmıştır [4].

2. MATERYAL ve YÖNTEM

Yerel saat zamanı ile her 15 dakika da Avrupa için uydu görüntüsü veren Eumetsat verileri kullanılmıştır [5]. Meteosat İkinci Nesil (MSG) uydu programı, dört adet sabit yörüngeli uydu ve yer hizmetlerini içermekte ve 2020 yılına kadar hizmet vermesi planlanmaktadır. MSG uyduları, 12 kanal veri alabilen Spinning Enhanced Visible and InfraRed Imager (SEVIRI) enstrümanı ve iklim çalışmalarını destekleyen Geostationary Earth Radiation Budget (GERB) enstrümanına sahiptirler.

Temmuz 2012 tarihinde Meteosat İkinci Nesil uydu programının üçüncü uydusu olan Meteosat-10 uydusu fırlatılmıştır. Meteosat-10 uydusu, Meteosat-9 uydusu ile beraber hava tahmini ve çok kısa vadeli hava tahmini konularında hizmet vermeyi amaçlamıştır [6].

MSG Kanal 9-10 kızılötesi görüntüleri kullanılmıştır. Çalışmamızda bir gün için 96 adet kızıl ötesi uydu görüntüsü alınmış, toplamda ise bir ay için 2880 kızıl ötesi uydu görüntüsü ile çalışılmıştır. Alınan kızıl ötesi uydu görüntüleri kasım 2012 tarihine ait görüntülerdir. Şekil 1'de MSG uydusu kanal 9'dan alınan örnek bir uydu görüntüsü bulunmaktadır. Bu görüntü üzerinde çalışma bölgesi çıkartılarak görüntü ön işleme teknikleri ile gürültülerden arandırılır. Beyaz bölge yağmur yüklü bulutları göstermektedir.



Şekil 1: MSG uydusu kanal 9 örnek kızılötesi görüntüsü

2.1. Öznitelik Çıkarımı

Temel bir örüntü tanıma şu adımlar ile gerçekleştirilir: ön işleme, öznitelik çıkarma ve sınıflama. Öznitelik çıkarma şekil tanılama ve şeklin önemli özniteliklerinin çıkarılıp öznitelik vektörünün elde edilmesi işlemidir. Biz de çalışmamızda yaklaşım katsayılarını elde etmek için dalgacık dönüşümünden faydalandık. Sonraki aşamada ise dalgacık dönüşümü ile oluşan yaklaşım katsayılarına temel bileşenler analizi uygulayarak fazla olan öznitelik vektörlerimizin boyutunu küçülttük.

2.2. Dalgacık Dönüşümü

Dalgacık dönüşümü, Fourier dönüşümünün durağan olmayan sinyallerdeki eksiklerini gidermek için geliştirilmiş farklı bir dönüşüm yöntemidir [7]. Bu analiz yöntemi gürültüye karşı daha az hassasiyet göstermekte ve durağan olmayan sinyallere rahatlıkla uygulanabilmektedir. Sürekli dalgacık dönüşümünde hesap yükü çok fazladır. Hesap yükünü azaltmak için ayrık dalgacık dönüşümü kullanılır. ADD'de öteleme ve ölçeklerin ikili kuvvetleri alınır.

$$f(x) = \frac{1}{\sqrt{M}} \sum_k W_{\phi}(j_0, k) \phi_{j_0, k}(x) + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_{\psi}(j, k) \psi_{j, k}(x) \quad (1)$$

Burada $f(x)$, $\phi_{j_0, k}(x)$ ve $\psi_{j, k}(x)$, $x = 0, 1, 2, \dots, M-1$ noktalarında örneklenmiş fonksiyonları göstermektedir. M sayısı genellikle $M=2^J$ şeklinde seçilir. Buradaki $W_{\phi}(j_0, k)$

ve $W_{\psi}(j, k)$ katsayıları bir önceki seri dönüşümdeki $c_{j_0}(k)$

ve $d_j(k)$ katsayılarına karşılık gelmektedir [8]. Sistemimizdeki imgelere uyguladığımız dalgacık dönüşüm filtresi Daubechies 5 (Db5) olarak seçtik [9].

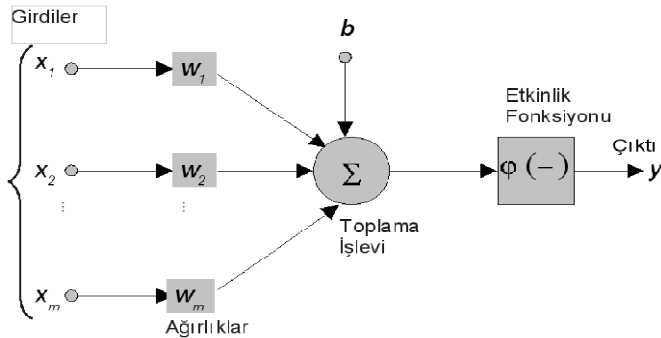
2.3. Temel Bileşenler Analizi

Temel Bileşen Analizi çok sayıda birbiri ile ilişkili değişkenler içeren veri setinin boyutlarını veri içerisinde varolan değişimlerin mümkün olduğunca korunarak daha az boyuta

indirgenmesini sağlayan bir dönüşüm tekniğidir. Analiz, elde edilen veriyi daha az sayıda değişkenle ifade edebilecek en iyi dönüşümü belirlemeyi amaçlar. Dönüşüm sonrasında elde edilen değişkenler ilk değişkenlerin temel bileşenleri olarak adlandırılır. İlk temel bileşen varyans değeri en büyük olandır ve diğer temel bileşenler varyans değerleri azalacak şekilde sıralanır [10]. Çalışmamızda her bir imge için TBA uygulayarak öznelik sayısını ayırt edicilikten taviz vermeden en aza indirdik. Böylece özneliklerin karmaşıklığını azaltarak görselleştirilebilir hale getirmiş olduk. İndirgenmiş özneliklerimizi YSA ve DVM yoluyla sınıflandırarak tehlikeli hava koşullarını tespit etmeye çalıştık. Temel bileşen analizi sonucunda elde edilen matrizenin min, max, ortalama, varyans, standart sapma bilgileri alınarak öznelik vektörü oluşturulmuştur.

2.4. Yapay Sinir Ağları

İnsan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemlerine Yapay Sinir Ağları denir. Yapay sinir ağları günümüzde birçok probleme çözüm üretebilecek yeteneğe sahiptir. Yapay Sinir Ağının birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden oluşmaktadır. Bu hücrelerin birbirlerine bağlandıkları ve her bağlantının bir değerinin olduğu kabul edilmektedir. Hücre elemanlarının birbirleri ile bağlanmaları sonucu oluşan ağa Yapay Sinir Ağı denmektedir. Yapay Sinir Ağının en temel görevi, kendisine gösterilen bir girdi setine karşılık gelebilecek bir çıktı seti belirlemektir [11].



Şekil 2: Yapay Sinir Ağı Genel Yapısı [12]

Şekil 2'deki yapay sinir ağı hücresi temel olarak girdilerden, ağırlıklardan, toplama işlevinden, bias (b) değerinden ve hedeflerden oluşur. Genelde, verilen bir girdi setine karşılık çıktı değerleri verilerek belirtilen öğrenme kuralına göre ağırlık değerleri otomatik olarak değiştirilmektedir. Eğitim verisinin tamamlanmasından sonra eğitilmiş olan ağ, ağırlık değerlerinin son durumuna göre, verilen herhangi bir veri setinin sonucunu tahmin edebilmektedir [13].

2.5. Destek Vektör Makineleri

Çalışmamızda yanlış sınıflandırma riskini minimize etmek amacıyla ikinci olarak Destek Vektör Makineleri ile sınıflandırma yöntemini denedik. Tek sınıf DVM durumunda veri öncelikle uygun bir çekirdek fonksiyon kullanılarak öznelik uzayına taşınır ve daha sonra bir hiperdüzlem

vasıtasıyla iki sınıf birbirinden ayrılır. Bu hiperdüzlem parametreleri normal DVM'dekine benzer bir kuadratik problemin çözülmesi ile elde edilir [14,15]. Çalışmamızda tehlikeli hava koşul imgelerinin etiketi +1, tehlikesiz hava koşul imgelerinin etiketini -1 ile gösterilmiştir. Test kümesindeki veriler için karar çıktıları şu şekilde hesaplanmaktadır.

$$\min \left(\frac{1}{2} \|w\|^2 + \frac{1}{v} \sum_{i=1}^l \xi_i - p \right) \quad (2)$$

$$(w\phi(x_i)) \geq p - \xi_i = 1, 2, \dots, l, \xi_i \geq 0 \quad (3)$$


$$f(x) = \text{sgn}(w\phi_x - p) \quad (4)$$

Burada w ve p hiperdüzlem parametreleri, ϕ çekirdek fonksiyon, v yanlış sınıflandırılan değerlerin (outlier) izin verilen oranı, l eğitim kümesindeki nesnelere sayısı ve ξ ise hata parametresidir. Çalışmamızda DVM sınıflandırmasını yapmadan önce öznelik vektörümüzün boyutunu temel bileşen analizi kullanarak küçülttük ve DVM'e giriş olarak uyguladık. DVM sonuçları detaylı olarak deneysel çalışma bölümünde yer almaktadır.

3. DENEYSEL ÇALIŞMALAR


2012 Kasım ayına ait 2880 adet Eumetsat kızılötesi uydu görüntüleri kullanılmıştır. Öncelikli olarak veritabanındaki görüntüleri Dalgacık Dönüşümü ile yaklaşım katsayılarını elde ettik. Sonra Temel Bileşen Analizi yardımıyla katsayıların boyutu azaltılmıştır. Bu değerlerin minimum, maksimum, ortalama, varyans, standart sapma değerleri öznelik değerleri olarak kullanılmıştır. 2160 adet görüntü eğitim aşamasında 720 adet görüntü test aşamasında kullanılmıştır. Tehlikeli hava koşullarını belirlemek için yapay sinir ağlarında hedef matrisi oluşturmada, Türkiye'ye ait son hava durumu ölçümleri kullanılmıştır.

İlk olarak özneliklerimizi gizli katmanında 20 nöron yer alan İleri Beslemeli Geri Yayılımlı Yapay Sinir Ağı ile sınıflandırılmıştır. Çıktısında tehlikeli ve tehlikesiz şeklinde sonuç aldığımız bu yapay sinir ağı Şekil 3'de %84 başarımla tehlikeli hava koşullarını tanımlayabilmiştir.



Şekil 3: Yapay Sinir Ağı ile Eğitim Sonucu

Başarım oranını artırmak amacıyla farklı bir sınıflandırma yöntemi olarak Destek Vektör Makineleri kullandık. DVM ile elde ettiğimiz sınıflandırmada %93'lük tanımlama ile başarımlı elde ettik. Erken tespitin önemli olduğu Kasım ayında % 93 doğrulukla tespit odaklı bir sonuç karşımıza çıkmaktadır. Destek vektör makineleri için elde edilen özneliklerin dağılımı Şekil 4'te verilmiştir.



Şekil 4: DVM ile Özneliklerin Dağılım Sonucu

4. SONUÇLAR

Yerel hava tahmin radarlarının yetersiz kaldığı bölgelerde tehlikeli hava koşulların erken tespit için karar kontrol sistemi oluşturmaya çalıştık. Bu amaçla dalgacık dönüşümü ve temel bileşen analizi kullanarak elde ettiğimiz öznelikleri iki farklı sınıflandırma yöntemine tabi tuttuk. İlk yöntemimiz olan Yapay Sinir Ağı ile %84 başarımlı erken tanı sağlayabildik. Destek Vektör Makineleri kullanarak yaptığımız sınıflandırmada ise bu başarımlı %93 seviyesine kadar çıkarabildik. Gerçekleştirdiğimiz örüntü tanıma sistemi yağmur yüklü bulutları erken tanımda önemli bir araç olarak kullanılabilir. Elimizde yer alan veritabanı sadece 1 aya ait sonuçları gösterdiği için 12 aya genelleme yapılamamaktadır. Daha fazla veri ile sınıflandırma sistemlerimizi daha başarılı bir şekilde eğitebilir ve daha yüksek başarımlı sonuçlar da elde edebiliriz. Tahminlerin daha güvenilir ve kararlı olması için yerin sıcaklığı, nem oranı, rüzgâr değerlerindeki içine alan bir sistem gerçekleştirilebilir.

5. KAYNAKÇA

- [1] Rosenfeld, J. (1997), 'The day of Judgement'. Weatherwise, June/July, Vol. 50, Issue:3, ss. 22-24. 2. Stipp D. (1997) 'A New Way to Bet on Disasters'. Fortune, Vol. 136, Issue:5, ss.124-131.
- [2] Jackson, I. J. (1972), Mean daily rainfall intensity and number of rain days over Tanzania, Geogr. Ann. A.54 : 369 – 375.
- [3] Burak ARICAK, Korhan ENEZ, Ömer KÜÇÜK,"Uydu Görüntüsü Kullanarak Yangın Potansiyelinin Belirlenmesi 1. Ulusal Akdeniz Orman ve Çevre Sempozyumu, 26-28 Ekim 2011, Kahramanmaraş.
- [4] İstanbullu M., Aydın M., Benveniste R., Uçan O.N., Jennane R., "Yapay Sinir Ağları ve Destek Vektör Makineleri Kullanarak Kemik Erimesi Hastalığının Erken Teşhisi", 20. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Muğla, 2012.
- [5] <http://www.eumetsat.int/Home/Main/DataAccess/EUMETSAT/DataCentre/index.htm?l=en> (12.01.2013)
- [6] <http://www.mgm.gov.tr/kurumsal/haberler.aspx?y=2013&f=msg3> (02.01.2013)
- [7] Hasioglu A., "Dalgacık Dönüşümü ve Yapay Sinir Ağları ile Döndürmeye Duyarsız Doku Analizi ve Sınıflandırma", Atatürk Üniversitesi, Mühendislik Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü, Erzurum, 1999.
- [8] Çelik E., "Görüntü İşlemeye Dayalı Avuç İçi İzinin Yapay Sinir Ağı ile Tanınması", Y.Lisans Tezi, Fen Bilimleri Enstitüsü, Marmara Üniversitesi, İstanbul, 2011.
- [9] Weeks M., Digital Signal Processing Using MATLAB and Wavelets, Georgia State University.
- [10] Yazar I., Yavuz H.S., Çay M.A., "Temel Bileşen Analizi Yönteminin ve Bazı Klasik ve Robust Uyarlamalarının Yüz Tanıma Uygulamaları", Eskişehir Osmangazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi Cilt: XXII, Sayı:1, 2009.
- [11] Huang D.S., Du J.X.: "A Constructive Hybrid Structure Optimization Methodology for Radial Basis Probabilistic Neural Networks", IEEE Transactions on Neural Networks, Vol:19, No:12, 2008.
- [12] Uğur A., KINACI A.C., "Yapay Zeka Teknikleri ve Yapay Sinir Ağları Kullanılarak Web Sayfalarının Sınıflandırılması", 11.İnternet Konferansları, 2006.
- [13] Şahin E., Mutlu B., Yıldız O., Öztürk E.A., "Yapay Zeka Tabanlı Trafik Planlama Uygulaması", 20. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Muğla, 2012.
- [14] Vapnik V.N., "An overview of statistical learning theory", IEEE Transactions on Neural Networks, 1999.
- [15] Gardner A.B., Krieger A.M., Vachtsevanos G., Litt B., "One-Class Novelty Detection for Seizure Analysis from Intracranial EEG", Journal of Machine Learning Research, vol. 7, pp. 1025-1044, 2006.