

GABOR DALGACIK DÖNÜŞÜMÜ TABANLI YAPAY SİNİR AĞI MODELİ İLE ZAMBAK YAPRAĞI İMGELERİNDE PAS HASTALIKLARININ TESPİTİ

Emrullah Acar^{1*}, Abidin Çalışkan², Necmettin Sezgin¹

¹Batman Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği
Bölümü, Batman

²Batman Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü,
Batman

*e-mail: acar@batman.edu.tr

Özet: Bitkilerdeki hastalıklar, hasadı ve dolayısıyla verimi etkilemektedir. Hastalık-
ların önceden kestirilmesi, çiftçilerin alacağı önlemler ile verimi artıracaktır. Verimi
etkileyen önemli hastalıkların başında pas hastalığı gelmektedir. Bu çalışmada bitki
örneği olarak, zirai uygulamalarla ilgili farklı zirai sitelerden bir uzman yardımıyla
elde edilmiş zambak çiçeği yaprak imgeleri kullanılmış olup, Gabor dalgacık dönü-
şümü tabanlı yapay sinir ağları modeli ile pas hastalığını tespit eden bir sistem tasar-
lanmıştır.

İlk aşamada, imgelere ilişkin Gabor dalgacık dönüşümü kullanılarak her bir sayı-
sal imgeden ayrı bir özellik matrisi elde edilip, matrislerin ortalama, standart sapma
ve entropi gibi istatistiksel değerleri hesaplanmıştır. Bu değerler öznitelik vektörüne
eklenerek, her bir imgé için bir öznitelik vektörü oluşturulmuştur. İkinci aşamada,
Gabor dalgacık dönüşümü tabanlı öznitelik vektörleri yapay sinir ağları modelinin giri-
şine verilerek sınıflandırma için performansı en iyi ağ yapısı belirlenmeye çalışılmış-
tır. Zambak çiçeği yaprak imgeleri iki (1-sağlıklı, 2- hastalıklı) grupta sınıflandırılmış
olup sınıflandırma çalışmaları sonucunda, en iyi ortalama performansa %80,00 başarı
ile yapay sinir ağları modelinin (3-25-1) ağ yapısında ulaştığı gözlemlenmiştir.

Anahtar Kelimeler: Zambak, Sınıflandırma, İmge İşleme, Gabor Dalgacık Dönüşü-
mü, Yapay Sinir Ağları

The Estimation of Rust Diseases of Daylily Leaf Images with Gabor Wavelet Transform based a Neural Network Model

Abstract: Crop diseases can affect harvested commodity and thus quality of the yield. When the diseases are estimated early, the yield will increase by taking measures thanks to farmers. In this paper, daylily leaf images are used as crop sample, derived from different agricultural sites under expert control and a system is designed in order to estimate rust diseases on digital daylily leaf images by using Gabor wavelet based a neural network model. In the first stage, a feature matrix is extracted from each digital image with using Gabor Wavelet Transform (GWT) and the statistical parameters are derived from each feature matrix to form a texture feature vector for each digital image. These parameters are mean, standart deviation and entropy. In the second stage, GWT based texture feature vectors are applied to different network structures of neural network model as inputs for classification and the results are compared in terms of testing performance in order to determine the best network structure. Daylily leaf images are classified into two (1.Normal, 2.Diseased) groups and the best average performance is observed as 80.00 % in the (3-25-1) network structure of neural network model.

Key Words: Daylily, Classification, Image Processing, Gabor Wavelet Transform, Neural Network

1. GİRİŞ

“Pas hastalığı nedir?” sorusuna, hastalığın ne olduğu tanımlanarak cevap verilebilir. Pas hastalığı; bitkilerin köklerine ve yapraklarına gıda alımını durdurarak, bitkilerin zayıflamasına neden olan bir mantardır. Bu hastalık, bitkilerde bulaşıcıyken çiçekler ve sebzeler arasında bulaşıcı değildirler. Pas lekesi, ilk başlarda hafif turuncu rengindedir. Ancak zaman ilerledikçe, koyu kahverengi dönüşür ve hastalığın bulaştığı yapraklar yere düşer. Hastalık yayıldıktan sonra gövde üzerinde pas lekeleri görülecek, sonunda bitki ölmeye başlar [1-2].

Genel olarak ekim alanlarında 3 çeşit pas hastalığına rastlanır. Bunlar sırasıyla kahverengi pas, sarı pas ve siyah pasdır. En sık görülen çeşidi, *yaprak veya kahverengi pas* olarak adlandırılır. Bu hastalık genellikle sulu tip uzun yapraklarda görülür. Etmenin yazlık ve kişilik sporları sarı pasla benzerlik gösterir. Bitkilerde görülen bir diğer pas hastalığı çeşidi, *şerit veya sarı pas* olarak adlandırılır. Bu hastalık türü, bitkilerde en erken görülen pas çeşididir. En sık yapraklarda görülür fakat hastalığın şiddetli olduğu dönemlerde ürünlerin başak kılçıkları ve saplarında da görülebilir. Püstüler yaprak yüzeyinde sarı renkte ve bir şerit şeklinde dizilirler. Bu yüzden şerit pas olarak ta adlandırılırlar. Bitkilerde görülen diğer pas çeşidi gövde pası olup sezon sonunda veya elverişsiz koşullarda yazlık sporlar şeklinde parlak siyah kişilik sporların aşırı üretiminden dolayı *siyah pas veya yaz pası* olarak adlandırılır. Siyah pas, pas hastalıklarının en yıkıcı çeşidi olup hastalığın gelişimi için uygun koşullar sağlandığında bir ay içinde %50'ye varan kayıplara sebep olurlar[1-3].

Bu çalışmanın amacı, sahaya gitmeden; imge işleme tabanlı sınıflandırıcı modelini kullanarak tarımsal ürünlerde görülen pas hastalığının tespitini sağlamaktır. Tespitin sağlanması ve çiftçinin bilgilendirilmesi ile alınacak önlemlerin neticesinde ekonomik kayıpların önlenmesi mümkün olabilecektir.

Uygulamalarda, sayısal imgelerin önişleminden geçirilerek öznitelik verilisinin elde edilmesi (i) ve farklı sınıflandırma yöntemleri ile elde edilen sonuçların değerlendirilmesi (ii), genel olarak izlenilen aşamalardır. İlk aşama olarak, imgelerin öznitelik vektörlerinin çıkarılması için Gabor Dalgacık Dönüşümü (GDD) yöntemi kullanılmıştır. İkinci aşamada ise, hastalığın tespiti için Çok Katmanlı Algılayıcı (ÇKA) yapay sinir ağları modeli kullanılmıştır. ÇKA'lar, ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem (nöron) biriminden oluşan matematiksel sistemlerdir.

Özetle, sayısal imge işleme teknikleri ile birlikte, GDD öznitelik çıkartma yöntemi kullanılarak zambak yaprağı imgelerinden elde edilen öznitelik vektörleri, yapay sinir ağı modelinin girişlerine uygulanmış olup, performansı en iyi sistem belirlenmeye çalışılmıştır.

2. Materyal ve Metot

2.1. Veri Toplama

Yapılan çalışmada, kayda alınan toplam 53 imge farklı zirai sitelerinin veri tabanlarından elde edilmiş [4-5], Dicle Üniversitesi Ziraat Fakültesinden çeşitli öğretim üyelerinden destek alınarak imgelerde yer alan ürünlerin hastalık ve sağlık durumu (1-Sağlıklı veya normal, 2- Hastalıklı) değerlendirilmiştir. Bu imgelerin 32 tanesi sağlıklı, 21 tanesi hastalıklı imgelerden oluşmaktadır. İki gruba ilişkin hastalık örnek imgeler Şekil 1'de, sağlıklı örnek imgeler ise Şekil 2'de gösterilmiştir.



Şekil 1. Zambak çiçeğine ait hastalıklı örnek yaprak görüntüleri



Şekil 2. Zambak çiçeğine ait sağlıklı örnek yaprak görüntüleri

2.2. Öznitelik Çıkarma

Bu çalışmada, kullanılan imgeler 3 boyutlu JPEG formatında olduğundan imgeler MATLAB programı yardımıyla 2 boyutlu gri tonlu imge formatına dönüştürülmüştür. Uygulamada kullanılan imgelerin ölçekleri 320x480 piksellidir. İmgeler 'bicubic' interpolasyon yöntemi ile ölçeklendirilerek 64x64 piksellik imgelere dönüştürülmüş ve tüm imgelerde histogram eşlemesi yapılmıştır.

2.2.1. Gabor Dalgacık Dönüşümü (GDD)

Gabor dalgacık dönüşümü, ana dalgacığı Gabor fonksiyonu olan dalgacık dönüşümü olarak ifade edilebilir. Frekans ve yönelim karakteristiklerine göre insan görsel sistemiyle büyük benzerlik gösteren Gabor dalgacıkları bilgisayar vizyon uygulamalarında ve biyolojik vizyonların modellenmesinde, özellikle doku betimlemeleri, yüz tanıma, parmak izi tanıma ve ayırma algoritmalarında kullanılmaktadır [6]. Gabor dalgacıkları gerek yönelim gerekse uzaysal lokalizasyon için mükemmel bir filtre oluşturur [7]. Karmaşık bir Gabor Dalgacığı (filtresi), Gauss Kernel ile karmaşık bir sinüsoidin çarpımı şeklinde tanımlanır. 2 boyutlu bir Gabor dalgacık dönüşümü $I(x,y)$ imgesinin konvolusyonuyla ifade edilir [6]:

$$J(x,y) = \iint I(x',y')g(x-x',y-y')dx'dy' \quad (1)$$

Burada, $g(x,y)$ fonksiyonu Gabor filtresini ifade eder:

$$g(x,y;\lambda,\varphi,\psi,\sigma,\gamma) = \exp\left(-\frac{x_1^2 + \gamma^2 y_1^2}{2\sigma^2}\right) \exp\left(i\left(2\pi \frac{x_1}{\lambda} + \psi\right)\right) \quad (2)$$

$$x_1 = x \cos \varphi + y \sin \varphi \quad (3)$$

$$y_1 = -x \sin \varphi + y \cos \varphi \quad (4)$$

Yukarıda tanımlanan λ ve φ parametreleri sırasıyla kosinusun dalga boyu faktörünü (ölçek) ve Gabor fonksiyonunun yönünü (açısal yönelimi) ifade etmektedir. ψ fazın ofset değerini, ve γ ise de uzamsal görüş açısını belirtir.

GDD'den hesaplanan parametreler:

Gri tonlamalı imgelere ilişkin her bir GDD matrisinden elde edilen matris MxN boyutlu $I(i,j)$ matrisi olsun. Buna göre:

i) Ortalama

$$o_{ij} = \frac{1}{MN} \sum_i^N \sum_j^M I_{ij} \quad (5)$$

ii) Standart Sapma

$$s_{ij} = \frac{1}{MN} \sum_i^M \sum_j^N (I_{ij} - m_{ij})^2 I_{ij} \quad (6)$$

iii) Entropi

$$e_{ij} = - \sum_{i,j} I(i, j) \cdot \log(I_{ij}) \quad (7)$$

Bu çalışmada, imgelerden elde edilen GDD matrislerinin istatistiksel değerleri hesaplanarak öznitelik vektörleri elde edilmiştir. Gabor öznitelik vektörleri, imgenin 8 dalgacık (2 ölçek ve 4 yönelim) matrislerinin her birine ait istatistiksel değişkenlerinin bir vektör oluşturacak şekilde art arda eklenmesiyle oluşturulmuştur. Her bir dalgacık dönüşümü matrisinden sırasıyla standart sapma, ortalama ve entropi değerleri hesaplanmıştır. Sonuç olarak her bir imgeye ait 8 dalgacık dönüşümü matrisinin istatistiksel değerleri art arda eklenerek toplamda $8 \times 3 = 24$ uzunluğunda öznitelik vektörü oluşturulmuştur. Elde edilen öznitelik vektörleri sınıflandırıcı için giriş örüntüleri olarak kullanılmıştır.

2.3. Sınıflandırma

Sınıflandırma basamağında, örüntülerin özellik uzaylarına göre kendilerine en yakın sınıflara en az hata ile eşleştirilmesi hedeflenir. Sınıflandırıcının performansı iyi belirlenmiş özelliklere bağlıdır.

2.3.1. Yapay Sinir Ağları (YSA)

YSA paralel dağılmış bir bilgi işleme sistemidir. "YSA, insan beyninin çalışma prensibini örnek olarak oluşturulmuş bir veri işleme yöntemidir. YSA'yı diğer yöntemlerden farklı kılan en önemli özelliklerden biri programlama yerine ör-

neklerle öğrenme yöntemini izlemesidir. Bu özellik sayesinde diğer programların sahip olduğu çoğu olumsuzluk YSA da yoktur. YSA'nın çalışma prensibi ile insan beyinin çalışma prensibi arasında ortak yönler vardır [8].

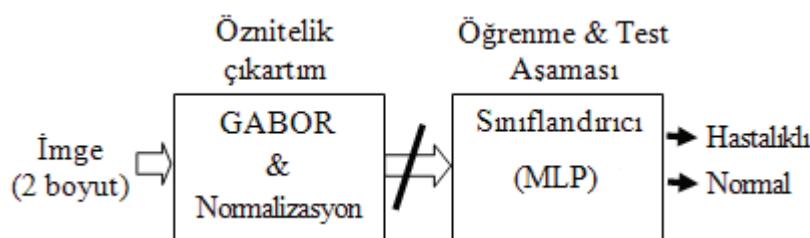
2.3.1.1. Çok Katmanlı Algılayıcılar (ÇKA)

Yapılan çalışmalar sonucu çok katmanlı algılayıcı modeli Rumelhard ve arkadaşları tarafından geliştirilmiş ve XOR problemini çözmeyi başarmıştır. Temel amaç, ağıın hedeflenen çıktısı ile üretilen çıktıları arasındaki hata farkını sıfıra indirmektir. Bunu hatayı ağa yayarak gerçekleştirdiği için bu modele hata yayma modeli ya da geriye yayım modeli de denmektedir [9].

ÇKA, birçok tespit ve tahmin işlemlerini yerine getiren parametrik olmayan bir yapay sinir ağı teknigidir. YSA uygulamalarında en popüler öğrenme algoritması olan geriye yayılma (BP) öğrenme algoritması, ÇKA'nın eğitilmesi sürecinde kullanılmıştır. BP algoritması, ağı parametrelerinin ayarlanması ile kuadratik maliyet fonksiyonunun (cost function) mimimizasyonuna dayanmaktadır. Ortalama karesel hata (MSE) ağıın performansı olduğundan, eğitme işlemi ile maliyet fonksiyonunu minimize eden parametreler belirlenir [10].

2.4. Tespit Sisteminin Yapılandırılması

Sınıflandırma için tasarlanan sistem model yapısı şekil 3'te gösterilmiştir. Ürün imgelerini sınıflandırmak için oluşturulan sistemin giriş parametreleri imgelere ilişkin öznitelik vektörleri olup, her bir imgenin GDD matrisinin istatistiksel (ortalama, standart sapma ve entropi) değerlerini içermektedir. Sistemin girişine uygulanan parametreler, sınıflandırıcı türüne göre normalizasyona tabi tutularak, [0,1] değer aralığına dönüştürülmüştür. Sistemin çıkışında, ürün imgeleri iki farklı grupta sınıflandırılmış ve 1-Hastalıklı, 2-Sağlıklı olarak adlandırılmıştır.



Şekil 3. GDD tabanlı sınıflandırma sisteminin yapısı

2.4. Performans Hesabı

Ürün imgelerinin sınıflandırılması için; ÇKA yapay sinir ağı yöntemi kullanılmıştır. Her bir yapının en iyi performansa erişimi için gerekli eğitim işlemleri yapılmıştır. Sınıflandırıcı modellerinin performansları; doğru tespit edilen imge sayısının toplam imge sayısına oranı ile hesaplanmıştır.

Bu çalışmada toplam 53 imge kullanılmış olup, çapraz doğrulama yapılarak 53 örneğin dönüşümlü olarak eğitim ve test veri setinde yer olması sağlanmıştır. Çapraz doğrulama sonucu elde edilen veri setinin $3/4$ oranı eğitim seti, geriye kalan oran ise test seti için rastgele oluşturulmuştur. Farklı sınıflandırma yöntemleri ile elde edilen tüm ortalama performans sonuçları 3. bölümde sunulmuştur.

Performans hesabı, sınıflandırıcının test sonuçları ile elde edilmesi gerek sonuçların eşleşmesi oranına göre yapılır. Diğer bir delegele,

$$\text{Performans} = (\text{Doğru}_\text{saptanan}_\text{örüntü}_\text{sayısı} / \text{Toplam}_\text{test}_\text{örüntü-sayısı}) \times 100 \quad (8)$$

bağıntısı ile hesaplanmıştır. Öğrenme ve test aşamalarında ortaya çıkan hatalar, Ortalama Karesel Hata Karekökü (RMS) ;

$$RMS = (1/p) \sum_j |t_j - o_j|^2)^{1/2} \quad (9)$$

bağıntısı ile hesaplanmıştır. Bu bağıntıda yer alan p , t ve o sırasıyla toplam örüntü sayısını, istenilen çıkışını ve model tarafından üretilen çıkışını ifade etmektedir. Her modelin performans ve RMS değerleri hesaplanarak, modellerin performansları karşılaştırılmıştır.

3. SONUÇLAR VE TARTIŞMA

3.1. Sonuçlar

GDD tabanlı ÇKA sınıflandırıcısının farklı topolojileri için performans bilgileri Tablo 1'de verilmiştir. ÇKA uygulamaları tek gizli katman üzerinden yapılmıştır. ÇKA ağ yapısı $24-n-1$ olup, en iyi performansı sağlayacak yapıının bulunabilmesi için n değeri değişken olarak ve [5-50] değer aralığında alınmıştır. Çapraz sinama yapılarak tesadüfi hatalar minimize edilmeye çalışılmış ve performans değerleri ortalama olarak hesaplanmıştır. ÇKA performans değerlerine bakıldığındá, Tablo 2'de görüldüğü gibi ortalama perfor-

mans başarısı [76.15-80.00] aralığında gözlemlenmiş ve en yüksek performans ortalaması değerinin 24-25-1 ağ topolojisi tarafından sağlandığı saptanmıştır. Elde edilen %80.00 ortalama performans başarısı ise modeller içerisinde en yüksek değeri teşkil etmiştir. Ağırlıklar (0,1) aralığında rastgele belirlenmiş, öğrenme faktörü 0.7, momentum katsayısı 0.3 ve tüm katmanlarda aktivasyon fonksiyonu olarak logsig kullanılmıştır.

Tablo 1. GDD tabanlı farklı MLP ağ sınıflandırıcısının performans değerleri

MLP Yapısı	Ortalama Performans (%)	Ortalama RMS
24-5-1	76.15	0.4660
24-10-1	79.23	0.4407
24-15-1	77.69	0.4546
24-20-1	78.46	0.4481
24-25-1	80.00	0.4318
24-30-1	76.92	0.4606
24-35-1	77.69	0.4546
24-40-1	76.92	0.4606
24-45-1	78.46	0.4481
24-50-1	76.92	0.4606

3.2. Daha Önce Yapılan Çalışmaların Sonuçlarıyla Kıyaslaması

Sonuç olarak, elde edilen %80.0 ortalama performans başarısı ile modeller içerisinde en yüksek performans 24-25-1 ağ yapısında gözlemlenmiştir. Farklı bitkilerin yapraklarına bakılarak hastalıkların saptanması niteliğinde literatürde birçok çalışma yapılmış olup, başarı oranı %86-%100 arasında olduğu gözlenmektedir.

Bu çalışmalardan bazıları aşağıda özetlenmiştir.

Rumpf ve ark. (2010) yaptıkları çalışmada; kernel tabanlı SVM modelini kullanmış olup şeker pancarı yapraklarındaki hastalıklı ve sağlıklı bitkilerin ayırtılmasında % 97 performans sağlanmıştır [11].

Bauer ve ark. (2011) yaptıkları çalışmada; k-NN, GKMTBS ve CRF yöntemleri kullanılmış olup şeker pancarı yapraklarındaki hastalıklı bitkilerin ayırtılmasında sırasıyla % 86 ve % 91 performans sağlanmıştır [12].

Li ve ark. (2010) yaptıkları çalışmada; PCA ve DA yöntemleri kullanılmış olup üç farklı yaprak hastalığının ayrıştırılmasında sırasıyla %96.7, %93.3 ve %86.7 performans sağlanmıştır [13].

Luaces ve ark. (2011) yaptıkları çalışmada; SVM ve LR yöntemleri kullanılmış olup kahve bitkilerindeki pas hastalığının tespitinde sırasıyla %90 ve %78 performans sağlanmıştır [14].

Römer ve ark. (2011) yaptıkları çalışmada; SVM modeli kullanılmış olup buğday yapraklarındaki pas hastalığının tahmininde %93 performans sağlanmıştır [15].

Yapılan bu çalışmada ise zambak çiçeği yaprağındaki pas hastalıklarının tespiti için bir sistem tasarlanmıştır. Sistemin sağladığı en yüksek ortalama performans (%80.0) daha önce yapılan çalışmaların başarıları (%78-%97) ile kıyaslandığında başarı oranının kabül edilebilir aralıkta olduğu düşünülmektedir. Doğrudan zambak çiçeği üzerine yapılmış bir tespit sistemi bulunmadığından ve ayrıca değerlendirilecek ortak bir veri tabanı olmadığından sistemin başarı performansı kıyaslanamamaktadır.

3.3. Tartışma

Bu çalışmada, zambak çiçeğine ilişkin sağlıklı ve hastalıklı dijital yaprak imgelerinin, Gabor özellik çıkartma ve ÇKA yapay sinir ağı yöntemleri kullanılarak, pas hastalığının tespiti için 2 farklı (normal, hastalıklı) grupta sınıflandırılması amaçlanmıştır.

Yapılan çalışmada elde edilen sınıflandırma sonuçlarıyla, daha önce yapılan çalışmalar kıyaslandığında başarı oranının kabül edilebilir aralıkta olduğu düşünülmektedir. Ayrıca önerilen modelin test sonucunda elde edilen toplam sınıflama doğruluğu, modelin pas hastalığının tespit edilmesinde kullanılabileceğini göstermiştir. Pas hastalığının tespiti için oluşturulan sistemin geliştirilmesi ve başarım oranının arttırılmasıyla çiftçilerin bitki pataloğuna ihtiyaç duymadan, hastalığın ilk aşamasından itibaren tespit edebileceği düşünülmektedir. Bu durum, bitki hastalıklarıyla mücadelede çiftçilere destek olma noktasında büyük bir aşama niteliğindedir.

4. TEŞEKKÜR

Bu çalışma, Dicle Üniversitesi DÜBAP:11-MF-24 nolu proje kapsamında yapılmıştır.

5. KAYNAKLAR

- [1] Çoklu, O., (2011). Buğday Pas Hastalıkları. Erişim: [<http://www.bahcebitkileri.org/bugday-pas-hastaliklari.html>]. Erişim Tarihi: 21.12.2011.
- [2] Dauber, R. (2008). Rust Disease on Tomato Plants. Erişim: [http://www.ehow.com/about_6514767_rust-disease-tomato-plants.html]. Erişim Tarihi: 21.12.2011.
- [3] McIntosh, RA., Wellings, CR. ve Park, RF. 1995. Wheat Rusts. CSIRO Publications, Yayın No: 45, Sayfa: 1-87. Sydney.
- [4] Anonim, (2008). Daylily Rust. Erişim: [<http://massnrc.org/pests/pestFAQsheets/daylily-rust.html>] Erişim Tarihi: 21.12.2011.
- [5] Bergeron, S., (2009). Daylily Rust Information Page. Erişim: [<http://web.ncf.ca/ah748/rust.html>]. Erişim: Tarihi: 21.12.2011.
- [6] Ioan Buciu, A. Gacsadi, "Gabor Wavelet Based Features for Medical Image Analysis and Classification". Applied Sciences in Biomedical and Communication Technologies, 2009. ISABEL 2009. 2nd International Symposium on 2009 pp. 1-4.
- [7] Vidyut Ghosal, Paras Tikmani, Phalguni Gupta, "Face Classification Using Gabor Wavelets and Random Forest". 2009 Canadian Conference on Computer and Robot Vision. Publication Year: 2009, pp. 68 - 73.
- [8] Öztemel, E. 1996. Bilgisayarda Öğrenme ve Yapay Nöral Ağları. Otomasyon, Yayın No:45, Sayfa: 134-140. İstanbul.
- [9] Orhan, U., Hekim, M. ve Özer, M. 2010. EEG İşaretlerinin Çok-katmanlı Algılayıçı Yapay Sinir Ağları Modeli ile Sınıflandırılmasında Ayırıldırma Yaklaşımı. 15. Biyomedikal Mühendisliği Ulusal Sempozyumu - BİYOMÜT 2010, 21-24 Nisan 2010, Antalya. S, 1-3.
- [10] Acar, E., Özerdem, M.S. ve Akpolat, V. 2011. Forecasting Diabetes Mellitus with Biometric Measurements, International Archives of Medical Research, 1, 1, 28-42.
- [11] Rumpf, T., Mahlein, A.-K., Steiner, U., Oerke, E.-C., Dehne, H.-W. ve Plümer, L. 2010. Early detection and classification of plant diseases with Support Vector Machines based on hyper spectral. Computers and Electronics in Agriculture, 74(1): 91-99.
- [12] Bauer, S., Korc, F. ve Förstner W. 2011. The potential of automatic methods of classification to identify leaf diseases from multispectral images. Precision Agriculture, 12(3): 361-377.
- [13] Li, J., Gao, L. ve Shen, Z. 2010. Extraction and analysis of digital images feature of three kinds of wheat diseases. 2010 3rd International Congress on Image and Signal Processing (CISP2010), 16-18 Oct. 2010, Yantai. 2543-2548.
- [14] Luaces, O., Rodrigues, L., Meira, C. ve Bahomende, A. 2011. Using nondeterministic learners to alert on coffee rust disease. Expert Systems with Applications, 38 (2011): 14276-14283.
- [15] Römer, C., Bürling, K., Hunsche, M., Rumpf, T., Noga, G. ve Plümer, L. Robust fitting of fluorescence spectra for pre-symptomatic wheat leaf rust detection with Support Vector Machines. Computers and Electronics in Agriculture 79 (2011): 180-188.