

Zambak yaprağı imgelerinde pas hastalıklarının GLCM tabanlı sınıflandırma yöntemleri ile tespiti

Mehmet Sıraç ÖZERDEM^{*1}, Emrullah ACAR²

¹ Dicle Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, 21280, Diyarbakır

² Batman Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, 72100, Batman

Özet

Bitkilerdeki hastalıklar, hasadı ve dolayısıyla verimi etkilemektedir. Hastalıkların önceden tespiti, çiftçilerin alacağı önlemler ile verimi artıracaktır. Verimi etkileyen önemli hastalıkların başında pas hastalığı gelmektedir. Bu çalışmada bitki örneği olarak zambak çiçeğine ilişkin yaprak imgeleri kullanılarak, bitkide pas hastalığının tespiti amaçlanmıştır. Çalışmada kullanılan imgeler, zirai uygulamalarla ilgili farklı zirai veri tabanlarından bir uzman yardımıyla elde edilmiştir. Bu çalışmada, GLCM tabanlı farklı sınıflandırıcı teknikleri kullanılarak, zambak yaprağında oluşan değişimin pas hastalığı olup olmadığını tespit eden bir sistem tasarlanmıştır.

Zambak yaprağına ilişkin imgelerin gri seviyeli eş-oluşum (GLCM) matrisleri elde edilip, matrislerin kontrast, korelasyon, enerji, homojenlik ve entropi değerleri hesaplanmıştır. İki boyutlu imgelere ilişkin matrislerden hesaplanan ortalama ve standart sapma değerleri öznitelik vektörüne eklenerek, her imge için toplamda 7 parametre içeren öznitelik vektörü oluşturulmuştur.

Elde edilen öznitelik vektörleri sınıflandırıcılar için giriş eğitim kümesi olarak kullanılmış ve test kümesi ile performansı en iyi olan sistem belirlenmeye çalışılmıştır. Bu sistemlerde sınıflandırıcı olarak Çok Katmanlı Algılayıcı, k-En Yakın Komşu (k-NN) ve en küçük kareler Destek Vektör Makinesi (LS-SVM) yöntemleri kullanılmıştır. Zambak çiçeği yaprak imgeleri, 32 sağlıklı (normal) imge ve 21 hastalıklı imge olmak üzere toplam 53 örnekten oluşur ve iki (1-Normal, 2-Hastalıklı) grupta sınıflandırılmıştır. Hastalığın tespiti amacıyla yapılan sınıflandırma çalışmaları sonucunda, en iyi performansa %88.9 başarı ile GLCM tabanlı k-NN ve çok katmanlı yapay sinir ağının (7-5-1) ulaştığı gözlemlenmiştir. Elde edilen sonuçlar önerilen yöntemin pas hastalığını tespit etmede doğru ve etkili çalıştığını göstermiştir.

Anahtar Kelimeler: Zambak, Pas hastalığı, Sınıflandırma, GLCM, MLP, k-NN, LS-SVM

The estimation of rust disease of daylily leaf images with GLCM based different classification methods

Extended abstract

Crop diseases can affect yield and/or quality of the harvested commodity. This can influence profitability and raise the risks of farming. When the diseases are estimated early, the yield will increase by taking measures thanks to farmers. The rust disease is one of the most major crop diseases that affect crop yield.

Rust disease can be defined as a fungus; it makes the crops weak by blocking food to the roots and leaves. It is named "rust" disease, since the spots on the leaves look like grain of rust which is coloured in the range of yellow to bright orange, to brown or red. Some spots have a planar surface, while others are raised. This disease is infectious amongst vegetations but not between flowers and vegetables. The rust firstly seems bright orange. Then, it turns to dark brown as it proceeds. The infected leaves drop off and the main stems will show diseased spots as it spreads. Finally, the crops will die (Dauber 2008).

In general, rust disease can be found in three types of planting areas. These are yellow rust, brown rust and black rust. The most common type, called a leaf or brown rust. This disease is usually seen in the wet type long leaves. Another common type of rust disease in plants is called stripe or yellow rust. It is seen most frequently in the leaves. The last common type of rust is called black rust and which is the most destructive kind of rust disease and it causes about 50 % losses per month of crop production efficiency (Çoklu2011).

In this paper, daylily leaf images are used as crop sample and derived from different agricultural sites under expert control and daylily rust disease is estimated by using GLCM based different classifier techniques.

Before classification process, the features are extracted from images with using Gray Level Co-Occurrence Matrix (GLCM) method and 7 parameters are derived by this method for each digital camera image. These parameters are contrast, correlation, energy, homogeneity, entropy, standard deviation and mean for first texture feature vector.

Then, the extracted feature vectors are applied to different type of classifiers and these vectors are used as inputs in classification systems. The Multilayer Perceptron neural network (MLP) , k-Nearest Neighbor (k -NN) and Least Squares Support Vector Machine (LS-SVM) classifiers have been chosen for learning and testing of 53 image data where 32 of them belongs to class I (normal), 21 of them belongs to class II (rust diseased). Different structures of networks are tested and the results are compared in terms of testing performance for each network model.

Artificial Neural Network (ANN) techniques are non-linear statistical data modeling or decision making tools. They can be used to model complex relationships between inputs and outputs or to find patterns in data. In pattern recognition, the k-nearest neighbor algorithm (k-NN) is a method for classifying objects based on closest training examples in the feature space. A Least Squares Support Vector Machine (LS-SVM) is a concept in computer science for a set of related supervised learning methods that analyze data and recognize patterns, used for classification and regression analysis .These methods were used for classification system in this paper.

Finally, the best performance was observed as 88.90% in the k-NN and MLP network with 7-5-1 structure. Our results suggest this method is an accurate and efficient means of estimating daylily rust disease.

Keywords: Daylily, Rust Disease, Classification, GLCM, MLP, k-NN, LS-SVM

Giriş

Bitkilerdeki hastalıklar, ekim sonrası verimi etkilemektedir. Hastalıkların önceden tespiti, çiftçilerin alacağı önlemler ile verimi artıracaktır. Verimi etkileyen önemli hastalıkların başında pas hastalığı gelmektedir. Pas hastalığı; bitkilerin köklerine ve yapraklarına gıda alımını durdurarak, bitkilerin zayıflamasına neden olan bir mantardır. Bu hastalığa “pas” hastalığı denmesinin sebebi, noktaların pas parçacıkları şeklinde görünerek sarı renkten parlak turuncuya, kırmızıya veya kahverengi rengine doğru değişen bir renk aralığında olmasıdır. Burada bazı lekeler düz olmalarına rağmen, bazıları da kabarık olabilirler. Bu hastalık, bitkilerde bulaşıcıyken çiçekler ve sebzeler arasında bulaşıcı değildirler. Pas lekesi, ilk başlarda hafif turuncu rengindedir. Ancak zaman ilerledikçe, koyu kahverengine dönüşür. Daha sonra, hastalığın bulaştığı yapraklar gövdeden ayrılır. Hastalık yayıldıkça, ana gövde üzerinde pas lekeleri görülür, sonunda bitki ölmeye başlar (Çoklu 2011; Dauber 2008).

Genel olarak ekim alanlarında 3 çeşit pas hastalığına rastlanır. Bunlar sırasıyla kahverengi pas, sarı pas ve siyah pastır. En sık görülen çeşidi, *yaprak veya kahverengi pas* olarak adlandırılır. Bu hastalık genellikle sulu tip uzun yapraklarda görülür. Bitkilerde görülen bir diğer pas hastalığı çeşidi, *şerit veya sarı pas* olarak adlandırılır. Sarı pas hastalığı, bitkilerde en erken görülen pas çeşididir. En sık yapraklarda görülür fakat hastalığın şiddetli olduğu dönemlerde ürünlerin başak kılıçları ve saplarında da görülebilir. Bitkilerde görülen diğer pas çeşidi *gövde pası* veya *siyah pas* olup, pas hastalıklarının en yıkıcı çeşididir. Hastalığın gelişimi için uygun koşullar sağlandığında bir ay içinde % 50'ye varan kayıplara sebep olurlar.

Bu çalışmanın amacı, sahaya gitmeden; tarımsal ürünlerde görülen pas hastalığının tespitini sağlamaktır. Tespitin sağlanması ve çiftçinin bilgilendirilmesi ile alınacak önlemlerin neticesinde ekonomik kayıpların önlenmesi mümkün olabilecektir. Bu çalışmada, uygulama olarak zambak çiçek yaprağının dijital imgeleri kullanılmış ve bitkinin pas hastalığına sahip

olup olmadığı sınıflandırılarak pas hastalığının tespiti sağlanmıştır.

Uygulamalarda, (i) dijital imgelerden elde edilen örneklerin önışlemeden geçirilerek öznelik verilerinin elde edilmesi ve (ii) farklı sınıflandırma yöntemleri ile elde edilen sonuçların değerlendirilmesi, genel olarak izlenen adımlardır. Bu çalışmada, birinci adım olarak imgelerin öznelik vektörlerinin çıkarılması için Gri Seviye Eş-Oluşum Matrisleri (GLCM) yöntemi kullanılmıştır.

İkinci adımda, hastalığın tespiti için kullanılan sınıflandırıcılar; Çok Katmanlı Algılayıcı (MLP), k-En Yakın Komşu (k-NN) ve en küçük kareler Destek Vektör Makinesi (LS-SVM) yöntemleridir. YSA'lar, ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem (nöron) biriminden oluşan matematiksel sistemlerdir. Aynı zamanda, giriş ve çıkışlar arasındaki karmaşık ilişkileri modellemek ve veri içindeki örüntüleri bulmak için kullanılabilir. Örüntü tanıma sistemlerinde k-NN yöntemi, sınıfları belli olan bir örnek kümesindeki gözlem değerlerinden yararlanarak, örneğe katılacak yeni gözlemin hangi sınıfa ait olduğunu belirlemek amacıyla kullanılır. LS-SVM ise, sınıflandırma ve regresyon analizi için kullanılan, verileri analiz etme ve örüntüleri tanımayla ilgili denetimli öğrenme yöntemlerini içeren yaklaşımdır.

Sonuçta, sayısal imge işleme teknikleri ile birlikte, GLCM özellik çıkartma metodu kullanılarak zambak çiçek yaprağından elde edilen özellik vektörleri pas hastalığının tespiti için farklı sınıflandırıcıların girişlerine uygulanmış olup, performansı en iyi sistem belirlenmeye çalışılmıştır. Çalışmada, 32 sağlıklı ve 21 hastalıklı olmak üzere toplam 53 zambak çiçek yaprağına ilişkin imgeler kullanılmıştır. 1-Sağlıklı (normal) ve 2-Hastalıklı olmak üzere iki grupta sınıflandırılmıştır.

Literatür tarama

Bu bölümde konuya ilişkin kaynaklar araştırılmış, genel olarak çalışmaların 3 grupta toplandığı saptanmıştır. Bu gruplar; fiziksel parametreler ve yapay zeka yöntemleriyle pas hastalığının tespiti (1.Grup), imge işleme ve yapay zeka yöntemleriyle pas hastalığının tespiti (2.Grup) ve istatistiksel yöntemlerle pas hastalığının tespitidir (3.Grup). Bu gruplara ilişkin yapılan çalışmalara örnekler aşağıda belirtilmiştir. Yapılan çalışmalar çoğunla buğday ve şeker pancarı gibi yemelik bitkisel ürünler üzerine yoğunlaşmış olup, pas hastalığının saptanması üzerine çalışılmıştır.

1.Grup çalışmalarına ilişkin örnek çalışmalar

Lei ve Shu-qin (2010), Çin'in Han Zhong bölgesinde sarı pas hastalığını tespit etmek için bir model önermişlerdir. Bu modelde, temel bileşenler analizi (PCA) yöntemi kullanılarak 1974 ve 1997 yılları arasındaki bölgedeki veriler analiz edilip sarı pas hastalığını etkileyen ana faktörler belirlenmiştir. PCA ile elde edilen ana parametreler yapay sinir ağının girişine uygulanarak Han Zhong bölgesinde 1994 ve 1997 yılları arasındaki sarı pas hastalığı başarılı bir şekilde tahmin edilmiştir.

Rumpf vd. (2010), şeker pancarı yapraklarındaki yaprak benek patojeni *Cercospora beticola*, pas patojeni *Uromyces betae* veya tozlu küf patojeni *Erysiphe betae* hastalıklarının tespiti için Kernel radyal tabanlı destek vektör makineleri modelini ve spektral bitki indisleri (spectral vegetation indices) yöntemini kullanmışlardır. Fiziksel parametrelere bağlı oluşturulan 9 bitki indisi bir özellik vektörü oluşturularak sınıflandırma için sistemin girişine verilmiştir. Sonuç olarak, şeker pancarı yapraklarındaki hastalıklı ve sağlıklı bitkilerin ayrıştırılmasında %97 performans sağlanmıştır. Yapraklardaki hastalıklara sebep veren üç hastalığın semptomlarının belirlenmesinde ise çoklu sınıflandırma yöntemi kullanılarak %86 doğruluk değeri hesaplanmıştır.

Wang ve Ma (2011), Çin'de buğday bitkilerinde en çok görülen hastalık türü olan sarı pas hastalığının destek vektör makineleri ve regresyon analizi modelleriyle tahmini için bir

çalışma yapmışlardır. Bu çalışmada, hastalığın epidemisini ve hastalığı etkileyen diğer faktörleri içeren toplam 3 veri kümesi için yapılan tahminler sonucunda, destek vektör makinelerinin regresyon analizi modeline göre daha yüksek tahmin ile çalıştığı ve her bir veri kümesi için %100 performansa ulaşmıştır.

Bauer vd. (2011), şeker pancarı yapraklarındaki yaprak benek patojeni *Cercospora beticola* veya pas patojeni *Uromyces betae* adında farklı iki hastalığın tespiti için üç farklı sınıflandırma modeli kullanmışlardır. Bu modeller sırasıyla k-NN, Gauss karma model tabanlı Bayes sınıflandırma ve Koşullu Rastgele Alanlar (Conditional Random Field) sınıflandırıcılarından oluşmaktadır. Sonuç olarak sınıflandırma performansı *Cercospora beticola* hastalığı için %91 ve *Uromyces betae* hastalığı için %86 olarak saptanmıştır.

2.Grup çalışmalarına ilişkin örnek çalışmalar

Moshou vd. (2004), buğday bitkilerinde sarı pas hastalığının otomatik uzaktan algılanması için sağlıklı ve hastalıklı buğday bitkileri arasındaki spektral yansıma farklarını dikkate alarak, bir algoritma önermişlerdir. Bu çalışmada temel alınan yöntemler, öz-örgütlenme sistemleri (self-organizing systems) ve çok katmanlı YSA olup sınıflandırma performansı %99 bulunmuştur.

Li vd. (2010), Çin'de tozlu küf, sarı pas ve kuşgözü lekesi gibi üç farklı hastalığı otomatik tanımak için imgelere ilişkin bazı morfolojik özellikler çıkarmışlardır. Morfolojik veriler, temel bileşenler analizi (PCA) ve diskriminant analiz yöntemleriyle analiz edilip toplamda 14 adet morfolojik özellik çıkarılmıştır. Bu parametrelerden 5 tanesi tanıma faktörü olarak seçilmiştir. Üç farklı hastalık örnekleri arasındaki tanınabilirlik oranı sırasıyla %96.7, %93.3 ve %86.7 olarak hesaplanmıştır.

Römer vd. (2011), buğday yapraklarında pas hastalığına sebep olan patojen enfeksiyonu önceden tahmini için imge işleme ve sınıflandırma yöntemleri kullanmışlardır. Bu çalışmada imgelerden elde edilen özellik vektörleri, SVM ile %93 başarı oranında sınıflandırılmıştır.

3. Grup çalışmalarına ilişkin örnek çalışmalar

Coakley vd. (1982), Amerika'da kış buğdayları üzerinde görülen sarı pas hastalığını tespit etmek için istatistiksel yöntemlerden faydalanmıştır.

Eddy (2009), Amerika'da buğday bitkilerinde sarı pas hastalığını tahmin etmek için Lojistik Regresyon modelini kullanmıştır.


Luaces vd. (2011), dünyadaki kahve bitkileri hastalığının başında gelen kahve pası hastalığına karşı alarm veren bir model önermişlerdir. Bu modelde, belirli bir eşik değeri aşıldığında sistemin alarm vererek çiftçileri uyarması amaçlanmıştır. Bunun için, bir regresyon ve iki deterministik olmayan sınıflandırıcı yöntemleri kullanılmıştır. Regresyon modeli olarak SVM regresyon, sınıflandırıcı olarak ta SVM çoklu sınıf sınıflandırıcı ve Lojistik Regresyon sınıflandırıcıları kullanılmıştır. Sonuç olarak, regresyon değeri 0.95 bulunup, sınıflandırıcı performansları sırasıyla %90 ve %78 olarak saptanmıştır.

Bu çalışmada, dijital yaprak imgelerinin özneliktik vektörleri yapay zeka yöntemleri ile sınıflandırılarak, bitki yapraklarında görülen pas hastalıklarının tespiti üzerine çalışılmıştır. Dolayısıyla, yapılan çalışma kapsam olarak 2. grup çalışmaları arasında yer almaktadır.


Materyal ve metod

Veri toplama

Bu çalışmada zambak çiçek yaprağına ilişkin gerçek-renkli imgeler, uzman kontrolünde farklı zirai araştırma veri tabanlarından elde edilmiştir (Anonim 2008; Bergeron 2009). Uygulamada kullanılan imgelerin ölçükleri 320x480 pikseldir. İmgeler 'bicubic' interpolasyon yöntemi ile ölçeklendirilerek, 16x16 piksellik imgelere dönüştürülmüştür. Kayda alınan 32 sağlıklı ve 21 hastalıklı imge olmak üzere toplam 53 örnek bu çalışmada kullanılmıştır. Bitki sağlık durumuna göre iki farklı (1-Normal ve 2-Hastalıklı) sınıfta değerlendirilmiştir. Hastalıklı ve normal zambak çiçek yaprağına ilişkin örnek imgeler Şekil 1 de gösterilmiştir.



a) Hastalıklı Zambak çiçek yapraklarına ilişkin örnekler



b) Sağlıklı Zambak çiçek yapraklarına ilişkin örnekler

Şekil 1. Zambak çiçek yaprağına ilişkin örnek imgeler

Özellik çıkartma

Bu çalışmada kullanılan imgeler 3 boyutlu JPEG formatında olduğundan, imgeler önişlem olarak 2 boyutlu imge formatına dönüştürülerek MATLAB ortamında kullanılması mümkün hale getirilmiştir. Önişlemeden geçmiş imgelere ilişkin GLCM matrisleri elde edilip, matrislerin kontrast, korelasyon, enerji, homojenlik ve entropi değerleri hesaplanmıştır. İki boyutlu imgelere ilişkin matrislerden hesaplanan ortalama ve standart sapma değerleri özneliktik vektörüne eklenerek, her imge için toplamda 7 parametre içeren özneliktik vektörü oluşturulmuştur.

GLCM, M.Haralick tarafından ortaya atılmış bir özellik çıkarma yöntemi olup, gri tonlu bir imajın özneliktliğini çıkarmaya yarar. GLCM, iki komşu piksel arasındaki ilişkiyi tanımlar. Bu

piksellerden birincisi referans pikseli, ikincisi de komşu piksel olarak biliniyor (Horng vd., 2003). GLCM, bir imgede ard arda gelen iki piksel arasındaki frekans matrisini oluşturur. Matristeki dağılım, pikseller arasındaki mesafe ve açığa göre ayarlanır. Bu matris, N_g boyutlu bir kare matris olup, matrisin her bir elemanı d mesafesindeki i ve j piksel değerli çiftin oluşum sayısını belirtir (Roumi 2009). GLCM nin satır ve sütunlarına ilişkin ortalama ve standart sapma eşitlikleri sırasıyla (1) ve (2) nolu bağıntılarda gösterilmiştir. Bu değerler, olasılık yoğunluk fonksiyonu $p(i,j)$ 'nin satır ve sütunlarının ortalama ve standart sapma değerlerini ifade eder.

$$\mu_x = \sum_i \sum_j i.p(i, j), \quad \mu_y = \sum_i \sum_j j.p(i, j) \quad (1)$$

$$\sigma_x = \sum_{i,j} (i - \mu_x)^2 . p(i, j) \quad (2)$$

$$\sigma_y = \sum_{i,j} (j - \mu_y)^2 . p(i, j)$$

Bu matrislerden imgenin doku karakteristiğini içeren kontrast, korelasyon, enerji, homojenlik ve entropi olmak üzere 5 adet özellik hesaplanmıştır. Diğer iki özellik olan ortalama ve standart sapma değerleri, Gri tonlama imgesinden elde edilen matris kullanılarak hesaplanmıştır (Roumi 2009).

GLCM den hesaplanan dokusal özellikler

i) Kontrast

$$\sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \mid |i - j| = n \right\} \quad (3)$$

ii) Homojenlik

$$\sum_{i,j} \frac{p(i, j)}{1 + (i - j)^2} \quad (4)$$

iii) Korelasyon

$$\sum_{i,j} \frac{(i - \mu_i)(j - \mu_j) p(i, j)}{\sigma_i \sigma_j} \quad (5)$$

iv) Enerji

$$\sum_i \sum_j p(i, j)^2 \quad (6)$$

v) Entropi

$$- \sum_{i,j} p(i, j) . \log(p(i, j)) \quad (7)$$

İki boyutlu imgeden hesaplanan özellikler

İki boyutlu imgelerden elde edilen matrix MxN boyutlu I(i,j) matrisi olması durumunda, buna göre:

vi) Ortalama

$$m_{ij} = \frac{1}{MN} \sum_i \sum_j I(i, j) \quad (8)$$

vii) Standart Sapma

$$s_{ij} = \frac{1}{MN} \sum_i \sum_j (I_{ij} - m_{ij})^2 I_{ij} \quad (9)$$

Sınıflandırma yöntemleri


Yapay sinir ağları (YSA)

YSA, insan beyninin çalışma prensibini örnek olarak oluşturulmuş bir veri işleme yöntemidir. YSA çevre şartlarına göre davranışlarını şekillendirebilir. Girişler ve istenen çıkışların sisteme verilmesi ile kendisini farklı cevaplar verebilecek şekilde ayarlayabilir. Ancak son derece karmaşık bir içyapısı vardır. Onun için bugüne kadar gerçekleştirilen YSA; biyolojik fonksiyonların temel nöronlarını örnek olarak yerine getiren kompozite elemanlar olmuştur. Bu ağların en önemli özelliği, problemin çözümünde “programlama” yerine “örneklerle öğrenme” yöntemini izlemesidir (Öztemel 1996).

Çok katmanlı algılayıcı (MLP): Yapılan çalışmalar sonucu MLP modeli Rumelhard ve arkadaşları tarafından geliştirilmiştir. Temel amaç, ağın hedeflenen çıktısı ile üretilen çıktıları arasındaki hata farkını sıfıra indirmektir. Hatayı ağı yayarak gerçekleştirdiği için bu

modele hata yayma modeli ya da geriye yayım modeli (backpropagation network) de denmektedir.

Bu modelin yaygın kullanılmasındaki en önemli faktör, ağ eğitiminin birçok öğrenme algoritması ile sağlanabilmesidir. Çok katmanlı algılayıcı ağ yapısında, nöronlar Şekil 2’te görüldüğü gibi farklı katmanlarda gruplanmıştır. Her bir katmanın çıkışı bağlı bulunduğu diğer katmanın giriş düğümlerine bağlıdır. Bu nedenle, giriş katmanının çıkışları aynı zamanda gizli katmanında girişlerini oluştururken, son katmanın çıkışları da ağın çıkışlarını oluşturur (Orhan vd., 2010).



Şekil 2. MLP için örnek ağ yapısı

MLP birçok tespit ve tahmin işlemlerini yerine getiren parametrik olmayan bir yapay sinir ağı tekniğidir. MLP’ de gizli katmandaki her bir j nöronu, w_{ji} bağlantı ağırlığıyla giriş işaretlerinin çarpımlarının toplamını alır ve y_j çıkışını bu toplamın bir fonksiyonu olarak hesaplar (Acar vd., 2011).

$$y_j = f\left(\sum w_{ji}x_i\right) \quad (10)$$

Burada f bir nörona etki eden işaretlerin ağırlıklı toplamını çıkış değerine dönüştüren bir aktivasyon fonksiyonudur. Aktivasyon fonksiyonu basit bir eşik fonksiyonu olup, sigmoidal veya hiperbolik tanjant fonksiyonu olabilir. Bu çalışmada, aktivasyon fonksiyonu olarak logsig fonksiyonu kullanılmıştır. YSA uygulamalarında en popüler öğrenme algoritması olan geriye yayılma (BP) öğrenme algoritması, MLP’nin eğitilmesi sürecinde kullanılmıştır. BP algoritması, ağ parametrelerinin

ayarlanması ile kuadratik maliyet fonksiyonunun (cost function) mimimizasyonuna dayanmaktadır. Ortalama karesel hata (MSE) ağın performansı olduğundan, eğitime işlemi ile maliyet fonksiyonunu minimize eden parametreler belirlenir. Ortalama karesel hata (MSE) işlemleri Eşitlik (11) ve (12)’de gösterilmiştir.

$$e_j(n) = d_j(n) - y_j(n) \quad (11)$$

$$\varepsilon(n) = \frac{1}{2P} \sum_{j \in C} \sum_{n=1}^P e_j^2(n) \quad (12)$$

Denklemlerde yer alan e , n , d , y ve P sırasıyla çıkıştaki hata işaretini, iterasyon sayısını, istenilen çıkışı, ağ tarafından üretilen çıkışı ve eğitim setinde kullanılan toplam örüntü sayısını göstermektedir.

Sinaptik ağırlıkların ayarlanması (13)

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \eta \delta_j(n) y_i(n) \quad (13)$$

Gizli ve çıkış katmanları arasındaki ağırlıklar için (14)

$$\delta_j(n) = e_j(n) \varphi' \left(\sum_{i=0}^m w_{ji}(n) y_i(n) \right) \quad (14)$$

Giriş ve gizli katmanları arasındaki ağırlıklar için (15)

$$\delta_j(n) = \varphi' \left(\sum_{i=0}^m w_{ji}(n) y_i(n) \right) \sum_k \delta_k(n) w_{kj}(n) \quad (15)$$

bağıntıları kullanılır. Bağıntılarda yer alan η ve α sırasıyla öğrenme oranını ve momentum katsayısını ifade etmektedir.

En Yakın k - Komşu Algoritması (k -NN)

k -NN yöntemi denetimli öğrenme yöntemleri arasında yer alıp, sınıflandırma problemlerini çözmeye yaran bir modeldir. Bu yöntemde, sınıflandırma yapılacak verilerin öğrenme kümesindeki normal veri kümelerine benzerlikleri hesaplanarak; en yakın olduğu düşünülen n tane verinin ortalamasının alınmasıyla elde edilen eşik değere göre sınıflandırma yapılır. Burada esas olan sınıflandırma yapılmadan önce, her bir sınıfın özelliklerinin önceden net bir şekilde belirtilmiş olmasıdır (Kaymaz 2007).

En yakın komşu algoritmasında öğrenilen fonksiyon ayrık ve reel değerli olabilir. Ayrık değerli fonksiyonlarda x_r sınıflandırılmak istenen örnek ve x_s değeri öğrenme noktaları olarak adlandırılması durumunda, $k=1$ seçilir ise "1-NN" (1 En yakın komşu algoritması), eğiten örnek x_r için $f(x_s)$ hesaplanır ve $f(x_r)$ 'ye değer ataması yapılır.

Bu algoritmada kullanılan farklı parametrelerden biri de uzaklık ölçme yöntemidir. Yapılan çalışmada, verilen noktaya göre en yakın komşular Öklid (Euclidean) uzaklığı kullanılarak hesaplanmıştır (Hilavin vd., 2011). İki örnek nokta arasındaki öklid mesafesi Eşitlik (16)'da gösterilmiştir.

$$d(x_r, x_s) = \left[\sum_{i=1}^p c_i (x_{ri} - x_{si})^2 \right]^{1/2} \quad (16)$$

Sıradan bir öklid mesafesinde ağırlıklar 1'e eşittir ($c_i = 1, i = 1, 2, \dots, p$).

En Küçük Kareler Destek Vektör Makinesi (LS-SVM)

LS-SVM, Suykens vd. (2002) tarafından önerilmiştir. Bu SVM çeşidi, standart SVM sınıflandırıcılarında olduğu gibi iki sınıf etiketli sınıflandırma işlemi düşünülerek oluşturulmuştur. SVM ikinci dereceden denklemlerin programlanması problemini ifade ederken, LS-SVM sınıflandırıcıları doğrusal bir takım denklemlerin çözülmesiyle elde edilir. Standart SVM sınıflandırıcılardaki optimizasyon işleminin çözümü amacıyla kullanılan ikinci dereceden programlama metotları bu teknikte kullanılmaz. Onun yerine doğrusal eşitlik kümesi (17) kullanılır. Bu eşitlikte; $\|w\|$ Euclid formunu, n eğitim veri seti sayısını, γ regülarizasyon parametresini ve e_i hata miktarını ifade eder.

$$\frac{1}{2} \|w\|^2 + \frac{\gamma}{2} \sum_{i=1}^n e_i^2 \quad (17)$$

Bu eşitlik daha sonra (18) koşuluna bağlı olarak minimize edilir. Eşitlik (18)'de yer alan y_i çıkış

değerini, x_i giriş değerini, w ağırlık vektörünü, $\varphi(\cdot)$ daha büyük boyuttaki özellik uzayına taşıma fonksiyonunu ve b bias değerini ifade eder.

$$y_i = w^T \varphi(x_i) + b + e_i, \quad i = 1, 2, \dots, n \quad (18)$$

Optimizasyon probleminin çözümünden sonra standart SVM sınıflandırıcılarda olduğu gibi optimizasyon eşitlikleri, Eşitlik (19) gibi ikili problem yapısına dönüştürülür. Bu eşitlikte α Lagrange çarpanlarını ifade eder.

$$L(w, b, e, \alpha) = \frac{1}{2} \|w\|^2 + \frac{\gamma}{2} \sum_{i=1}^n e_i^2 - \sum_{i=1}^n \alpha_i \{w^T \varphi(x_i) + b + e_i - y_i\} \quad (19)$$

Eşitlikte yer alan α çarpanları standart SVM sınıflandırıcılarında pozitif olması gerekirken, LS-SVM sınıflandırıcılarında pozitif veya negatif olabilmektedir. LS-SVM'deki bu farklılık ve daha az eğitime zamanı gerektirmesi, LS-SVM'yi standart SVM sınıflandırıcılarından ayırır. Sınıflandırma performansı ise, bazı uygulamalarda standart SVM öğrenme metoduna yakın da olsa düşük çıkabilmektedir. Bunun sebebi de eğitime aşamasında daha kuvvetli ama zaman alan ikinci dereceden programlama yerine daha basit ama kısa sürede uygulanabilen doğrusal programlamayı kullanmasındandır (Li vd., 2011).

Eşitlik (19)'un optimizasyonundan sonra ve w, e parametrelerinin elenmesiyle; LS-SVM modeli için fonksiyon tahmini eşitlik (20) ile ifade edilir.

$$y(x) = \sum_{i=1}^n \alpha_i K(x_i, x_j) + b \quad (20)$$

Burada $K(\cdot)$ fonksiyonu kerneli ifade ederek, x giriş uzayının lineer olmayan bir şekilde çok boyutlu özellik uzayına haritalanmasını sağlar. LS-SVM; fonksiyonu Eşitlik (20)'deki ifadeyi kullanarak benzetmeye çalışır ve Radyal temel fonksiyonunu (RBF) kernel fonksiyonu olarak kullanır. RBF kernel, Eşitlik (21)'de gösterilmiştir.


$$K(x, x_i) = \exp(-|x - x_i|^2 / \sigma^2) \quad (21)$$

Burada σ pozitif reel bir sabittir. RBF kernel varlığında, Eşitlik (17)'deki γ parametresi ve eşitlik (22)'deki σ parametresi olmak üzere iki tane ayarlanmalı parametreye ihtiyaç vardır.

LS-SVM probleminin eğitiminde iki tane bağımsız parametre bulunmaktadır. Bu parametreler sırasıyla kernel genişlik parametresi sigma (σ) ve regülarizasyon parametresi (γ) olup LS-SVM sınıflandırıcısının genelleme performansını etkilemektedir. Bu nedenle, bu parametreler genelleme hatasını en aza indirecek şekilde ayarlanmalıdır (Sheng vd., 2011).

Sınıflandırma sisteminin mimarisi

Tasarlanan GLCM tabanlı sınıflandırma sistem yapısı şekil 3'te gösterilmiştir. GLCM tabanlı sınıflandırmada kullanılan parametreler sırasıyla kontrast, korelasyon, enerji, homojenlik, entropi, standart sapma ve ortalama değerleridir. Hastalığın tespiti için tasarlanan sınıflandırma sisteminin giriş parametreleri imgelere ilişkin öznelik vektörü olup, sınıflandırıcı türüne göre normalizasyona tabi tutularak, [0,1] değer aralığına dönüştürülmüştür. Bu eğitim örüntüleri ile MLP, k-NN ve LS-SVM sınıflandırıcıları eğitilip, test örüntüleri ile sistemin performans değerleri karşılaştırılmıştır.



Şekil 3. GLCM tabanlı sınıflandırma sisteminin yapısı

Toplam 53 örüntüden, 35 adet örüntü (21 adet normal, 14 adet hastalıklı) eğitim seti için kullanılmıştır. Kalan 18 adet örüntü ise (11 adet normal, 7 adet hastalıklı) test seti olarak kullanılmıştır. Eğitim ve test setlerinin örüntüleri rastgele seçilerek belirlenmiştir.

Performans Hesabı

MLP, k-NN ve LS-SVM modellerinin eğitiminde, normalize edilmiş veriler sistemin girişine uygulanıp her bir modelde hedeflenen en küçük hata değerine ulaşılması ile eğitime işlemi sonlandırılmıştır. Sınıflandırıcı modellerinin performansları

$$\text{Performans} = \frac{\text{Doğru tahmin edilen örüntü sayısı}}{\text{Toplam test edilen örüntü sayısı}} \cdot 100 \quad (22)$$

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

$$\text{RMS} = ((1/p) \sum_j |t_j - o_j|^2)^{1/2} \quad (23)$$

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

Deneysel Sonuçlar

GLCM tabanlı MLP sınıflandırıcısının farklı topolojileri için performans bilgileri Tablo 1'de verilmiştir. Kolmogorov'un 1957 yılında yaptığı çalışmada, tek gizli katmanlı bir ağız her türlü problemi sonlu adımda çözebileceğini matematiksel olarak kanıtlamış, ancak gizli katmanda bulunması gereken nöron sayısı belirsizliğini korumuştur. Bundan dolayı, MLP uygulamaları tek gizli katman üzerinden yapılmıştır. MLP ağ yapısı 7-n-1 olup, en iyi performansı sağlayacak yapının bulunabilmesi için n değeri değişken olarak ve [5 50] değer aralığında alınmıştır. MLP performans değerlerine bakıldığında, Tablo 1'de görüldüğü gibi performans başarısı [72.2 88.9] aralığında gözlemlenmiş ve en yüksek performans değerinin 7-5-1 ağ topolojisi tarafından sağlandığı saptanmıştır. Ağırlıklar (0,1) aralığında rastgele belirlenmiş, öğrenme faktörü 0.8, momentum katsayısı 0.1 ve tüm katmanlarda aktivasyon fonksiyonu olarak *logsig* kullanılmıştır.

Tablo 1. GLCM tabanlı farklı MLP ağ sınıflandırıcısı ile tespit performans değerleri

MLP Yapısı	Performans (%)	RMS
7-5-1	88.9	0.3333
7-10-1	83.3	0.4082
7-15-1	72.2	0.5270
7-20-1	83.3	0.4082
7-25-1	77.8	0.4714
7-30-1	77.8	0.4714
7-35-1	77.8	0.4714
7-40-1	72.2	0.5270
7-45-1	83.3	0.4082
7-50-1	78.8	0.4714

GLCM tabanlı k -NN sınıflandırıcısının farklı komşu (k) sayıları için performans bilgileri Tablo 2’de verilmiştir. Bu sınıflandırıcıda, en yakın komşu sayısı (k), [2:2:20] değer aralığında alınarak, her bir k sayısı için performans değeri hesaplanmıştır. k -NN yapısına bakıldığında Tablo 2’de görüldüğü gibi performans başarısı [72.2 88.9] aralığında gözlemlenmiştir.


Tablo 2. GLCM tabanlı k -NN sınıflandırıcı ile tespit performans değerleri

Komşu sayısı (k)	Eşlenmeyen örüntü oranı	Performans (%)	RMS
2	0.222	77.8	0.4714
4	0.222	77.8	0.4714
6	0.222	77.8	0.4714
8	0.222	77.8	0.4714
10	0.278	72.2	0.5270
12	0.167	83.3	0.4082
14	0.101	88.9	0.3333
16	0.101	88.9	0.3333
18	0.222	77.8	0.4714
20	0.222	77.8	0.4714

GLCM tabanlı LS-SVM sınıflandırıcısının performansı Tablo 3’de verilmiştir. LS-SVM probleminin eğitiminde kernel genişlik parametresi sigma ($\sigma=71$) ve regülasyon parametresi ($\gamma=19.8$) olarak seçilmiştir. Tablodan görüldüğü üzere sistemin performansı %83.3 olarak gözlemlenmiş ve ROC eğrisi şekil 4’te gösterilmiştir.

Tablo 3. GLCM tabanlı LS-SVM sınıflandırıcısı ile tespit performans değerleri

Kernel Tipi	Eşlenmeyen örüntü oranı	Performans	RMS
RBF	0.167	%83.3	0.4082
Lineer	0.222	%77.8	0.4714



Şekil 4. GLCM tabanlı LS-SVM sınıflandırıcısının ROC eğrisi.

Sonuçlar

Bu çalışmada, zambak çiçeğine ilişkin sağlıklı ve hastalıklı dijital yaprak imgelerinin, GLCM özellik çıkartma yöntemi ve sınıflandırma (MLP, k -NN, LS-SVM) teknikleri kullanılarak, pas hastalığının tespiti için 2 farklı (normal, hastalıklı) grupta sınıflandırılması amaçlanmıştır.

k -NN ve MLP sınıflandırıcılarının %88.9 ile en yüksek tespit performansına sahip oldukları gözlemlenmiştir. Elde edilen sistem performansları ile kıyaslandığında, başarı oranı kabul edilebilir aralıkta olduğu görülmüştür.

Zira imge işleme çalışmalarında aynı veri tabanlarının kullanılmaması ve her çalışmada ilgili ürüne ilişkin imgelerin kullanılması, yapılan çalışmaların karşılaştırılmasının önüne geçmektedir. Ancak aynı grupta yer alan çalışmaların performansları karşılaştırılabilmektedir.

Teşekkür

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

Kaynaklar

- Acar, E., Özerdem, M.S. ve Akpolat, V., (2011). Forecasting Diabetes Mellitus with Biometric Measurements, International Archives of Medical Research, 1, 1, 28-42.
- Anonim, (2008). *Daylıly Rust*. Erişim: [http://massnc.org/pests/pestFAQsheets/daylilyr ust.html] Erişim Tarihi: 21.12.2011.
- 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.
- Bergeron, S., (2009). *Daylıly Rust Information Page*. Erişim:[http://web.ncf.ca/ah748/rust.html]. Erişim Tarihi: 21.12.2011.
- Coakley, S. M., Boyd, W. S. ve Line, R. F., (1982). Statistical Models for Prediction of Stripe Rust on Winter Wheat in the Pacific Northwest. *Phytopathology*, 72, 539-1542.
- Çoklu, O., (2011). *Buğday Pas Hastalıkları*. Erişim: [http://www.bahcebitkileri.org/bugday-pas hastaliklari.html]. Erişim Tarihi: 21.12.2011.
- 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.
- Eddy,R.,(2009). Logistic Regression Models to Predict Stripe Rust Infections on Wheat and Yield Response to Foliar Fungicide Application on Wheat in Kansas. Master thesis, Kansas State University, Department of Plant Pathology College of Agriculture, Kansas. 53-67.
- Hilavin,İ., Kuntalp, M. ve Kuntalp, D., (2011). Aritmilerin Spektral Özellikler Kullanılarak En Yakın K Komşu Metoduyla Sınıflandırılması. *2011 IEEE 19th Signal Processing and Communications Applications Conference (SIU)*, 20-22 Nisan 2011, Antalya. S,411-414.
- Hornig, M. H. , Huang, X. J. ve Zhuang, J.H., (2003).Texture Feature Coding Method for Texture Analysis and It's Application. *Journal of Optical Engineering*, 42 ,1, 228-238.
- Kaymaz, E.2007. Yapay bağışıklık sistemi tabanlı k-NN sınıflandırma algoritması ile protein örüntülerinin hücredeki yerleşim yerlerinin belirlenmesi. Yüksek Lisans tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.45.
- Lei, Y.ve Shuqin, L., (2010). App. of principal component analysis of wheat stripe rust. [http://en.cnki.com.cn/Article_en/CJFDTOTAL-SJSJ201002061.htm]. Erişim Tarihi: 21.12.2011.
- Li, J., Gao, L. ve Shen, Z.,(2010). Extraction and analysis of digital images feature of three kinds of wheat diseases. *2010 3rd Int Congress on Image and Signal Processing (CISP2010)*, 16-18 Oct. 2010,Yantai. 2543 – 2548.
- Li, X., Nie, P., Jun,Z. and He,Y., (2011). Using wavelet transform and multi-class least square support vector machine in multi-spectral imaging classification of Chinese famous tea. *Expert Systems with Applications* 38,9,11149-11159.
- Luaces,O., Rodrigues, L., Meira, C. ve Bahomende, A.,(2011). Using nondeterministic learners to alert on coffee rust disease. *Expert Systems with Applications* ,38,14276-14283.
- Moshou, D., Bravo, C., West, J., Wahlen, S., McCartney, A. ve Ramon, H., (2004). Automatic detection of 'yellow rust' in wheat using reflectance measurements and neural Networks. *Computers and Electronics in Agriculture*, 44, 2004, 173–188.
- Orhan, U., Hekim, M., Özer, M., 2010. EEG İşaretlerinin Çok-katmanlı Algılayıcı YSA Modeli ile Sınıflandırılmasında Aynıklaştırma Yaklaşımı. 15. BİYOMUT 2010,21-24 Nisan 2010, Antalya. sl-3.
- Özmetel, E. 1996. Bilgisayarda Öğrenme ve Yapay Nöral Ağları. *Otomasyon*, Yayın No:45, s134-140.
- Roumi, M.2009. Implementing Texture Feature Extraction Algorithms on FPGA. *Master thesis*, Delft University of Technology, Faculty of Electrical Engineering, Mathematics and Computer Science,Delfth,Netherlands.15.
- Römer, C., Bürling,K., Hunsche, M., Rumpf,T., Nogave Plümer, L. Robust fitting of fluorescence spectra for pre-symptomatic wheat leaf rust detection with SVMs. *Computers and Electronics in Agriculture*, 79, 2011, 180–188.
- 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 SVMs based on hyperspectral. *Computers and Electronics in Agriculture*, 74, 1, 91-99.
- Sheng, H., Zhang,L., Tang,J.,Sun,Y. Ve Zhao,L .2011.*Quality, Reliability, Risk, Maintenance, and Safety Engineering (ICQR2MSE)*, 17-19 June 2011,Xi-an.673-677.
- Suyskens,J., Gestel,T., Brabender,J., Moor, B. ve Vandewalle J.2002. Least Squares Support Vector Machines. World Sci Publishing Co. Pte. Ltd, Yayın No: (ISBN 981-238-151-1), s71. Leuven.
- Wang, H. ve Ma, Z.2011. Prediction of Wheat Stripe Rust Based on SVM. *2011 Seventh International Conference on Natural Computation*, 26-28 July 2011, Shanghai.378-382.

mühendislik dergisi

