

Biber Bitkisinden Alınan Spektral Yansımaların Yapay Sinir Ağları Kullanarak Hastalık Tespiti

Kerim Karadağ^{*1}, Ramazan Taşaltın¹

¹ Harran Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Şanlıurfa/Türkiye

ÖZET

Bu çalışmada, Toprakтан bibere verilmiş Zararlı Fungusların ve herhangi bir işlem yapılmamış Biber yapraklarından alınan spektral yansımaların sınıflandırılması gerçekleştirilmiştir. Hastalıklı ve sağlıklı biber yapraklarının Spektrometre ile kaydın tespiti bu çalışmanın amacını oluşturmaktadır. Çalışmada kullanılan veri seti iki gruba ayrılmaktadır. Birinci grup (A), Negatif kontrol grubu herhangi bir şey içermeyen sağlıklı biber bitkisi. İkinci grup (B), Pozitif kontrol grubu zararlı Fungus içeren hastalıklı biber bitkisi. Biber ile ilgili durum tespiti iki aşamadan oluşmaktadır. Birinci aşama öznelik vektörünün temini, ikinci aşamada ise verilere ilişkin öznelik vektörlerinin sınıflandırılması yapılmıştır. Öznelik çıkarma işlemi olarak Dalgacık Analizi ve birkaç istatistiksel yöntem kullanılmıştır. Sınıflandırma yöntemi olarak ise Yapay Sinir Ağları yöntemi kullanılarak, biber ile ilgili durum tespitinde elde edilen performansların yüksek olduğu gözlemlenmiştir.

Anahtar Kelimeler: Spektrometre, Dalgacık Analizi, Yapay Sinir Ağları, Sınıflandırma

Detection of Spectral Reflections from Pepper Plants Using Artificial Neural Networks

ABSTRACT

In this study, given the harmful fungi from the soil pepper and there was no operation is implemented classification of spectral reflectance of pepper leaves. The determination of the spectral reflection of diseased and healthy leaf pepper is the aim of this study. Data sets used in this study were divided in to two groups. The first group (A), Negative control group, healthy pepper plant that does not contain anything and second group (B), Positive control group, diseased pepper plant contains harmful fungi. Due diligence related to the pepper consists of two stages. First stage, obtaining a feature vector. Second stage, Classification of vector attributes of the data is made. Wavelet analysis is used as a feature extraction process and several statistical methods are used. The methods used for classification of artificial neural networks. And Pepper has been observed that the due diligence related to a high level of performance is achieved.

Keywords: Spectroradiometer, Wavelet Analysis, Artificial neural networks, Classification

* Sorumlu yazar e-posta: k.karadag@harran.edu.tr

1. Giriş

Spektroradyometrik cihazlar, spektrometrik ölçümlerin radyometrik kalibrasyonlarının sağlandığı aygıtlardır. Spektroradyometreler uydu ve diğer uzaktan algılama sensörlerinde olduğu gibi radyans, irradyans, reflektans ya da transmisyona kantitatif ölçümlerine dayanırlar. Spektroradyometrik Yöntemlerde temel dayanak, objelerin elektromanyetik bölgelerde kendine özgü bir yansıma değerlerinin bulunmasıdır. Bu yansıma değeri objeye renk, doku, parlaklık ve görünüş gibi özellikleri veren kimyasal yapısından kaynaklanmaktadır. [1]

Spektroradyometreler 375-2500 nm dalga boylarında yansıma ölçümü yapabilen cihazlardır. Spektroradyometre 512 kanalda topladığı 16 bitlik analog veriyi sayısal hale dönüştürmektedir. Cihazın kalibrasyonunda beyaz referans olarak alçı bloktan imal edilmiş spektralon kullanılmaktadır. Işınım algılanması 1°, 2°, 3°, 3.5°, 4°, 5°, 7.5°, 8°, 10° ve 25° lik mercekler (foreoptic) ya da kontak prob ve bitki probu ile yapılmaktadır.

1.1. Besin ve Hastalık

Bir organizmanın gelişimi ve enerji kaynağı olarak ihtiyaç duyduğu kimyasal maddelere besin denilmektedir. Dünya üzerinde yaşayan her canlı gibi bitkilerde beslenmek zorundadır. Ancak, bitkiler diğer canlılardan farklı olarak geliştikleri ortamdan inorganik maddeleri alıp sentezleyerek organik madde yaparlar ve güneşin fiziksel enerjisini kimyasal gıda enerjisine dönüştürerek hayatsal faaliyetlerine devam ederler. [2]

Bitkinin başlıca besin kaynağı topraktır ve bitkiler besin kaynağı olan topraktan birçok element alır. Bitkilerin değişik organlarında 74 element olduğu belirlenmiştir. Ancak bunların çok az bir kısmı bitki gelişimi için mutlaka gerekli olan elementlerdir. Bitki gelişimi için mutlaka gerekli olan bitki besin elementlerine mutlak gerekli besin elementi denilmektedir. Bunlar; karbon (C), hidrojen (H), oksijen (O), azot (N), fosfor(P), potasyum (K), kalsiyum (Ca), magnezyum (Mg), kükürt (S), demir (Fe), mangan (Mn), molibden (Mo), bakır (Cu), bor (B), çinko (Zn), klor (Cl), sodyum (Na), kobalt (Co), vanadyum (V) ve silisyum (Si) dur. [2]

Hastalıklar İnsanlara özgüymüş gibi anımsansa da aslında insan varlığının öncesinde hastalıkların olduğu, hayvanların, bitkilerin de bu dertten muzdarip olduğu bilinmektedir. Bitkilerin sağlıklı gelişmeleri ve verim artışı için mutlak gerekli besin maddelerince dengeli beslenmesi gereklidir. Alınabilir formdaki besin elementlerinin bir veya daha fazlasının eksikliği toprak verimliliğini ve bitki gelişimini önemli oranda etkiler. [2]

1.2. Bitki

Bitkiler de ışına teorisine uygun olarak herhangi bir kaynaktan gelen radyasyonu absorbe ederler, yansıtırlar, yayarlar veya dağıtırlar. Bu işlemler genellikle bitki yapraklarında gerçekleşir. Farklı bitki hücresi kısımlarında soğurulan ışık dalga boyları farklılık göstermektedir. [1]

Bitkilerde en büyük yansıma değerleri yakın kızılötesi olarak ifade edilen 700-1300 nm dalga boylarında elde edilmekte ve birçok bitki özelliği bu dalga boylarındaki farklılıklarla ortaya koyulabilmektedir. [1]

1.2.1. Bitkilerde yansımayı etkileyen faktörler;

Bu faktörler bitkiden kaynaklanabileceği gibi bazı dış etkilere bağlı da olabilirler. Bunlar; Yaprığın morfolojik yapısı, Yaprakların yaşı, Bitkilerin büyüme dönemleri, Bitkilerin yaprak yapısı, Yapraklardaki su kaybı, Yüksek tuzluluk, besin elementi eksiklikleri, Hastalık ve zararlılar. [1]

1.3. Biber

Ülkemizin her bölgesinde yetiştiriciliği yapılan biber, Dünyada ve Ülkemizde değişik şekillerde yoğun olarak tüketilen önemli bir sebze türüdür. Taze tüketimin yanında, toz biber, salça, közleme, sos, turşu ve ana yemeklerin içerisinde çok değişik şekillerde değerlendirilmektedir.[3]

Biber, ılık ve sıcak iklim sebzesidir. Biber için en uygun sıcak, 20-30°C'dir. Biberler, sıcaklıkla birlikte toprak rutubetini de sever. Bitkilerin iyi bir gelişme göstermesi, düzenli sulamaya bağlıdır. Diğer taraftan, gereğinden fazla sulamadan da kaçınılmalıdır. Sıcaklığın biberlerde meyve bağlama ve olgunluğu üzerine de etkisi vardır. Biberlerin gün uzunluğuna karşı nötr oldukları, bununla birlikte, ışık şiddetinden kısmen hoşlandıkları görülür. Işık yoğunluğunun düşmesi bitkilerde bol yapraklı bir görünüm kazandırır. Çiçek tomurcuklarının oluşumu durur. Meyve verimi azalır. Buna karşılık, ışık şiddetinin artması meyve oluşumu artırır. Biberlerde iyi bir gelişme ve verimlilik için oldukça derin, geçirgen, su tutma özelliği iyi, besin ve organik maddece zengin bahçe toprağı denilen tınlı topraklarda iyi sonuç alınmaktadır. Kökler narin yapıda olduklarından ağır killi, havasız ve su tutan topraklarda iyi bir yetiştiricilik yapılamaz. Erkencilik amacıyla yapılan yetiştirmelerde takviye edilmiş kumlu topraklar ve özellikle kumlu-tınlı topraklar uygundur. Buna karşılık geç olmakla birlikte bol ürün almak arzu edildiğinde kumlu-tınlı topraklar tercih edilebilir. Biberler tınlı-kumlu, tınlı-haff killi, organik maddece zengin topraklar üzerinde en iyi gelişmeyi ve verimi verir.[3]

2. Materyal Ve Metot

2.1. Çalışmada Kullanılan Veri Seti

Bu çalışmada Şanlıurfa GAP Tarımsal Araştırma Enstitüsü Müdürlüğü (GAPTEAM) bitki yetiştirme laboratuvarında toprak özellikleri, sıcaklık, nem gibi tüm fiziksel şartların sabit olduğu bir ortamda biber bitkisine ait örneklerden Spektrometre cihazıyla alınmış yansıma değerleri kullanılmıştır. Biberlerin yetiştirildiği ortam şekil 1'de gösterilmiştir.

Alınan kayıtlar; bitkinin sağlıklı Negatif kontrol grubu ve hastalıklı Pozitif kontrol grubu veri setlerinden oluşmuştur. Veri seti A ve B olarak isimlendirilip veri setlerinin her biri 2151x5 boyutunda işaretten oluşmuştur. Spektrometre cihazı ve ölçümlerin yapılışı şekil 2'de verilmiştir. Kayıtlar [A1,A2,A3,A4,A5], [B1,B2,B3,B4,B5], olarak etiketlenilmiş olup, her bir etiket 2151x1 niteliğinde bir vektörü ifade etmektedir. Çıktılarda ise; A etiketli kayıtlar 1 ve B etiketli kayıtlar 2 olarak tanımlanmıştır.



Şekil 1. Biberlerin yetiştirildiği ortam



Şekil 2. Spektrometre cihazı ve ölçümlerin yapılması

2.2. Sınıflandırma Tespitinde Önerilen Sistem

Bu çalışma kapsamında, Spektrometre cihazı ile elde edilen biber yapraklarına ait spektral yansımalar, uygun dönüşümler sağlanarak notpade aktarılıp oradan matlab ortamına geçirilmiştir. Daha sonra elde edilen kayıtların öznelik vektörleri Dalgacık Dönüşümü Daubechies4 (db4) kullanılıp, normalizasyon işlemi ve bazı istatistiksel değerlerden (maksimum, minimum) de yararlanarak sınıflandırmaya uygun hale getirilmiştir. Sınıflandırma için YSA yöntemi kullanılarak başarımların tespiti yapılmıştır.

2.2.1. Dalgacık Dönüşümü (DD);

Kayıtların öznitelik vektörünün elde edilmesi için DD yöntemi kullanılmıştır. Dalgacık (Wavelet) teorisi matematikçilerin, bilgisayarlıların ve işaret işleyicilerin çalıştığı popüler bir konu olup halen gelişmektedir. Dalgacık temelli işaret analizinin durağan olmayan işaretler ve nümerik işaret işleme üzerine pek çok uygulama olanağı vardır. Dalgacık analizi farklı frekanslarda durağan olmayan güce sahip zaman serisi işaretlerinin analizinde kullanılabilir. DD yöntemi, durağan veya durağan olmayan işaretlerin zaman-ölçek analizi için olanak sağlar. DD yönteminde temel dalgacıklar kullanılır. Dalgacıklar sonlu süreli olduklarından, yerel işaret özelliklerinin analizini mümkün kılarlar. Dalgacık dönüşümleri tüm işaret frekans-zaman bilgisini korurlar. Bu sebeplerden dolayı durağan olmayan gerçek doğal işaretlerin dalgacık temelli metotlarla işlenmesi geleneksel metotlardan daha iyi sonuçlar sağlarlar [4].


2.2.2. Yapay sinir ağları (YSA);

YSA, insan yapısını inceleme ve onun yaptıklarını yapabilme çabalarının ürünleri sonucunda matematiksel bir yöntem olarak ortaya çıkmıştır. Çalışmayı yapanlar, beynin nöro fiziksel yapısını göz önüne alıp, beynin davranışlarını tam olarak modellemeye çalışmışlardır. Modelleme için çeşitli yapay hücre ve ağ modelleri geliştirmişler. [4]

Yapay sinir ağları, birbirlerine bağlanmış birçok nöronlardan oluşan matematiksel sistemlerdir. Bir işlem birimi, diğer nöronlardan sinyalleri alır, bunları birleştirir. İşlem birimleri kabaca gerçek nöronlara karşılık gelir ve bir ağ üzerinde birbirlerine bağlanırlar, bu yapı da sinir ağlarını oluşturur. Yapay Sinir Ağları nöron gösterilimi şekil 3’de verilmiştir. Yapay sinir ağları, yapısı bilgi işleme yöntemindeki farklılık ve uygulama alanları nedeniyle çeşitli dallarının da kapsam alanına girmektedir. Yapay sinir ağları, hesaplama ve bilgi işleme gücünü, paralel dağılmış yapısından, öğrenebilme ve genelleme yeteneğinden almaktadır. Genelleme, eğitim ya da öğrenme sürecinde karşılaşılmayan girişler için de yapay sinir ağlarının uygun tepkileri üretmesi olarak tanımlanır. Yapay sinir ağları, aşağıdaki özellikleri nedeniyle birçok alanda uygulanmaktadır. Doğrusal Olmama: Yapay sinir ağlarının temel işlem elemanı olan hücre, doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen Yapay sinir ağları da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile de doğrusal olmayan problemlerin çözümünde önemli bir araçtır. Öğrenme: Yapay sinir ağlarının istenilen davranışı gösterebilmesi için uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması demektir. Yapay sinir ağlarının karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlanarak verilmez. Yani yapay sinir ağları, eğitim örneklerini kullanarak problemi öğrenir. Genelleme: Yapay sinir ağları, problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir yapay sinir ağları, bozuk karakter girişlerinde de doğru karakterleri verebilir ya da bir sistemin eğitilmiş yapay sinir ağları modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir. Uyarlanabilirlik: İlgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen Yapay sinir ağları, problemdeki değişimlere göre tekrar eğitilebilir ve değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Uyarlanabilir örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır. Hata Toleransı: Yapay sinir ağları, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluşmuştur. Bu ağdaki bilgi, ağdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir yapay sinir ağlarının bazı bağlantılarının veya bazı hücrelerin etkisiz durumda olması, ağın doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, diğer yöntemlere göre hatayı tolere etme yeteneği son derece yüksektir. [5]

2.2.2.1. Yapay Sinir Ağlarının Kullanım Alanları

Yapay sinir ağları; ses tanıma, yazılan karakteri tanıma, robot kontrolleri, resim işleme ve yüz tanıma sistemlerinde çok sık olarak kullanılmaktadır. İnsanın (özellikle insan beyni ve algı sistemi) modellenmesi, yüz tanıma sistemleri son yıllarda önem kazanmıştır. Sanayi alanında arıza analizi ve tespiti; tıp alanında EEG, ECG sinyallerinin analizi, kanserli hücrelerin analizi, transplantasyon zamanlarının optimizasyonu; savunma sanayinde silahların otomasyonu, hedef izleme, nesnelere görüntüleme, ayırma, tanıma konularında yararlanır. Fabrikalarda üretim sistemlerinin optimizasyonu, ürün analizi ve tasarımı, kalite analizi gibi konularda kullanılmaktadır. [5]



Şekil 3. Yapay sinir ağları nöron gösterilimi

3. Literatürde Sunulan Spektrometre ve YSA Yaklaşımları

Literatürde farklı bitkilerde farklı durumların Spektral yansımalarının Knn, YSA, DVM gibi yöntemlerin kullanılarak sınıflandırma başarımlarına bakılmıştır. Bu çalışmalar da su stresi ve bitki hastalıkları incelenmiştir. Bizde çalışmamızda güncelliğini koruyan akıllı tarım uygulamalarına bir basamak olan bu tip çalışmalarda biber bitkisine ait hastalık tespitini YSA kullanarak başarmayı amaçlıyoruz.

Literatürde Spektrometre ve sınıflandırma ile ilgili çeşitli çalışmalar bulunmaktadır. Örneğin;

Zhang ve arkadaşları; Spektrometre Cihazı ile elde ettikleri Domates yapraklarının Sağlıklı ve hastalıklı olanlarının spektral yansımalarını principal component ve Spectralratio analysis yöntemleri ile incelemişler.[6]

Huang ve Apan; kereviz yapraklarından spektrometre ile topladıkları 30 hastalıklı ve 41 sağlıklı datadan istatistiksel yöntemlerden yararlanarak, Kısmi En Küçük Kareler Regresyon yöntemi kullanarak hastalık tespiti yapmışlar.[7]

Larsolle ve Muhammed; iki ayrı üründe (Buğday ve Arpa) Spektrometre Cihazı ile elde edilen spektral yansımalar Normalizasyonu yapılarak Nearest Neighbors yöntemi ile sınıflandırılmıştır.[8]

Liu ve arkadaşları; pirinç salkımlarının boş, sağlıklı ve hastalıklı durumlarının yakın ve Kızıl ötesi spektroskopisi ile elde edilen değerlerinin; Principal Component Analysis (PCA) ve Support Vector Machines (SVM) kullanarak karşılaştırmasını yapmışlar.[9]

Sankaran ve Ehsani; Avokado yapraklarında laurelwilt (bir mantar hastalığı) etkisinin ağaç üzerindeki gelişiminin etkisini inceleme çalışması yapmışlar. Yapraklardan Sağlıklı, Hasarlı, Belirtisiz ve Donmuş şeklinde bilgiler alınmış öznitelik çıkarımı için principal component analysis (PCA) ve Sınıflandırma için ise linear discriminant analysis, quadratic discriminant analysis (QDA), Naïve-Bayesclassifier, and bagged decision trees (BDT) yöntemleri kullanılmış ve yüksek başarı oranları elde edilmiştir.[10]

Mishra ve arkadaşları; Narenciye bahçesinden 80 hastalıklı 55 sağlıklı yapraklardan Spektrometre cihazından dataları alarak, k-Nearest Neighbors (KNN), Logistic Regression (LR), and Support Vector Machines (SVM) sınıflandırma yöntemlerini kullanarak çalışmalarını yapmışlar.[11]

Liu ve ark; pirinç yaprağındaki dört ayrı durumu değerlendirmişler. Öznitelik çıkarmada principal component analysis (PCA) ve sınıflandırma yöntemi olarak da neural network kullanılmış.[12]

Rumpf ve ark; şeker bitkisi yapraklarının üç farklı hastalık durumlarının değişik günlerde aldıkları Spektrel datalarını Artificial Neural Networks (ANNs), Decision Trees, K-means, k nearest Neighbors, and Support Vector Machines (SVMs) sınıflandırma yöntemlerini kullanarak karşılaştırma yapmışlar.[13]

Li ve He; Çay tarlasını Spektrel verilerini almışlar. Öznitelik Çıkarmada Dalgacık Analizi ve Sınıflandırma yöntemi olarak da Artificial Neural Networks kullanmışlar.[14]

Wu ve ark; Patlıcandaki Sağlıklı, Hastalıklı bitkilerden Spektrometre cihazı ile aldıkları spektral yansımaları öznitelik çıkarmada principal component analysis ve sınıflandırma yöntemi olarak da back-propagation neural networks (BP-NN) kullanılmış.

Liaghat ve ark; Palmiye Yapraklarından, Sağlıklı ve çeşitli zararlara uğramış şekilde dört grup oluşturup spektral yansımalarını almışlar. Öznitelik alma işleminde principal component analysis (PCA) uygulayıp sınıflandırma yöntemi olarak da, linear and quadratic discrimination analysis, k nearest neighbour (kNN), ve Naïve-Bayes kullanmışlardır.[15]

4. Bulgular ve Sonuç

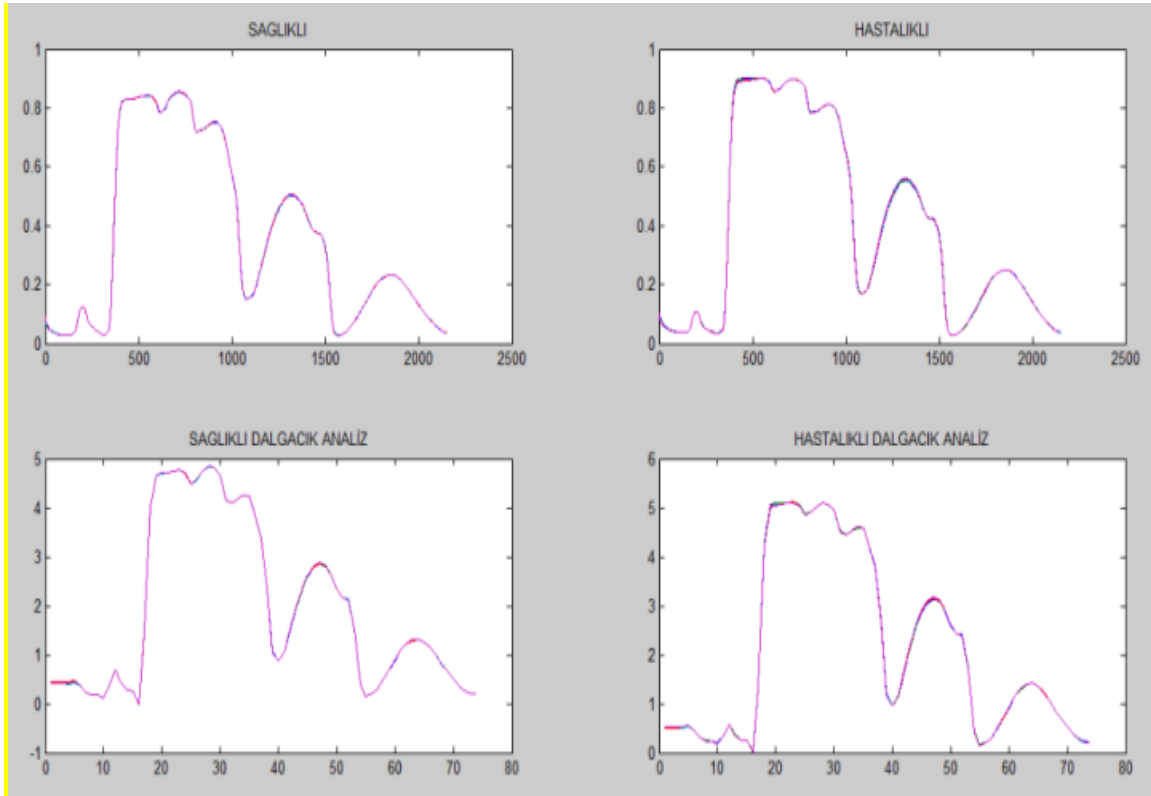
Bu çalışmada, Sağlıklı ve Zararlı fungus içeren biber yapraklarının kayıtlarına ilişkin spektral yansımalarının sınıflandırılması amaçlanmıştır. Öznitelik vektörü elde edilip, normalizasyon işlemi ile birlikte istatistiksel değerler sonucunda; sağlıklı (1) ve hastalıklı (2) olacak şekilde sınıflandırılmıştır. Çizelge 1'de ans ile gösterilen değerler test edilen değerler, round(ans) ile gösterilen değerler de yuvarlatılmış test değerlerini ifade etmektedir.

Çizelge 1. YSA'da test sonucu elde edilen değerler

| Sonuç | A1 (sağlıklı) | A2 (sağlıklı) | B1 (hastalık) | B2 (hastalık) |
|------------|------------------|------------------|------------------|------------------|
| ns | 1.0231 | 1.0219 | 1.9820 | 2.0026 |
| round(ans) | 1 | 1 | 2 | 2 |


Her kaydın öznitelik vektörleri, dalgacık yöntemi ile elde edilmiştir. 2151x5 boyutundaki ham veri dalgacık analiz yapıldıktan sonra 75x5 boyutuna dönüştürülmüş, Normalizasyon işleminden sonra bazı

istatistiksel analizler sonucunda 6x5 boyutuyla işleme konulmuştur. Spektrometre cihazından alınan ham veriler ve normalizasyon işlemi yapılmış veriler şekil 4'te gösterilmiştir.



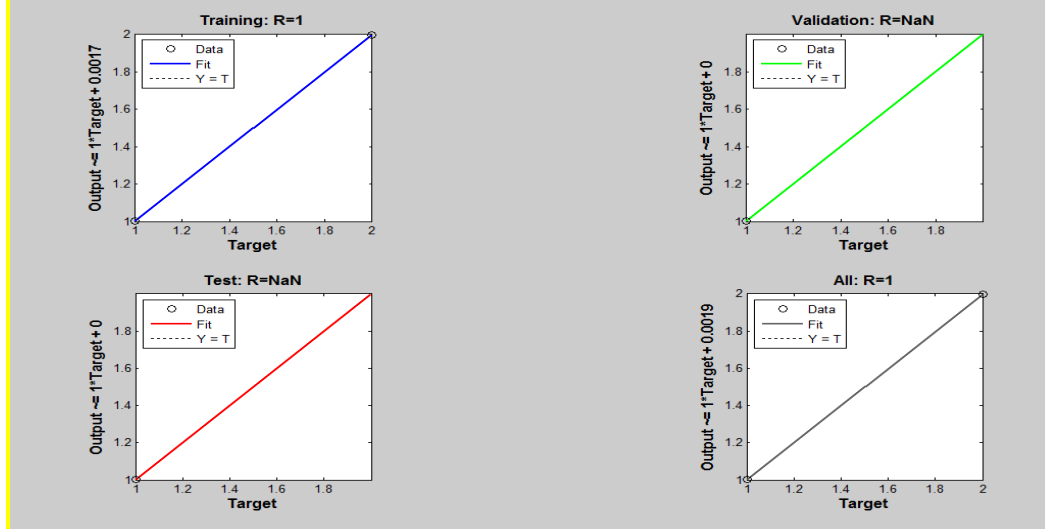
Şekil 4. Ham veriler ve Dalgacık Analizi yapılmış verilerin gösterilimi

Sınıflandırmaya uygun hale getirilen veriler YSA yöntemi kullanılarak karşılaştırılmıştır. İlk aşamada Sağlıklı ve Zararlı fungus (Hastalık) grupların sınıflandırılması değerlendirilip başarımların performans durumları şekil 5'de gösterilmiştir.



Şekil 5. YSA performans gösterilimi

Ysa yöntemine ait verilerin regrasyon sonuçları şekil 6’da gösterilmiştir.



Şekil 6. YSA sonucu başarımların gösterilimi

Teşekkür

Bu makale, “Biber Bitkisinden Alınan Spektral Yansımaların Yapay Sinir Ağları Kullanarak Hastalık Tespiti” adlı doktora tezinden türetilmiştir. Çalışmanın olgunlaşip mevcut duruma gelmesinde, laboratuvar imkânlarından faydalandığımız GAPTEAM yetkililerine, Özellikle yetiştirdiği bitkilerden veri almamıza olanak sağlayan Ziraat Mühendisi Ayşin Bilgili hanımefendiye, Spektrometre cihazını kullanmamıza izin veren hocamız A.Volkan Bilgili beye ve her türlü desteği sağlayan arkadaşım M. Emin Tenekeci hocamıza çok teşekkür ediyorum.

Kaynaklar

- [1] Başayığıtl, Albayrak S, Şenol H, Akgül H. "Spektrometre Verileri İle Bitki Besin Elementi İçeriğinin Tahmin Edilebilirliği", 4. Ulusal Bitki Besleme ve Gübre Kongresi. Konya.2008
- [2] Daş Ö. B. "ICP-OES Kullanılarak Bitkilerdeki Makro ve Mikro Elementlerin Birlikte Tayininde Çok Değişkenli Kalibrasyon Tekniklerinin Uygulanması" Ankara Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans. Ankara. 2013
- [3] Tarım Ve Köy işleri Bakanlığı Koruma ve Kontrol Genel Müdürlüğü Biber Hastalık ve Zararlıları ile Mücadele. Ankara. 2011
- [4] Karadağ K. Özerdem M. S. "Dalgacık Dönüşümü Kullanılarak Fare EEG işaretlerinde Epileptik Nöbet Tespiti," Tıptekno. Kapatokya. 2014. p. 78-81
- [5] ÇakırŞ, ErtunçM ve Ocak H. " Yapay Sinir Ağları Kullanılarak Karbonat Kayalarındaki Dokunun Tanımlanmasına Bir Örnek: Akveren Formasyonu," Uygulamalı Yerbilimleri Sayı:2, 2009, p. 71-79.

- [6] Zhang M, Liu X, O’neill M. 2002. “Spectral discrimination of *Phytophthora infestans* infection on tomatoes based on principal component and cluster analyses”, *int. j. Remote sensing*, 2002, vol. 23, no. 6, 1095–1107
- [7] Huang J. F, Apan A. 2006. Detection of Sclerotinia Rot Disease on Celery Using Hyperspectral Data and Partial Least Squares Regression, *Journal of Spatial Science*, 51-2.
- [8] Larsolle A, Muhammed H. H. 2007. Measuring crop status using multivariate analysis of hyper spectral field reflectance with application to disease severity and plant density, *Precision Agric*, 8:37–47 [6]
- [9] Liu Z.Y, Shi J.J, Zhang L. W, Huang J.F. 2010. Discrimination of rice panicles by hyper spectral reflectance data based on principal component analysis and support vector classification, *Journal of Zhejiang University-SCIENCE B (Biomedicine & Biotechnology)* ISSN 1673-1581 (Print); ISSN 1862-1783
- [10] Sankaran S, Ehsani R, Inch S.A, Ploetz R.C. 2012. Evaluation of Visible-Near Infrared Reflectance Spectra of Avocado Leaves as a Non-destructive Sensing Tool for Detection of Laurel Wilt, *Plant Disease / Vol. 96 No. 11*
- [11] Mishra A. R, Karimi D, Ehsani R, Lee W. S. 2012. Identification Of Citrus Greening (HLB) Using a Vis-Nir Spectroscopy Technique, *American Society of Agricultural and Biological Engineers* ISSN 2151-0032, Vol. 55(2): 711-720
- [12] Liu Z.Y, Wu H, Huang J.F. 2010, Application of neural Networks to discriminate fungal infection levels in rice panicles using hyperspectral reflectance and principal components analysis, *Computers and Electronics in Agriculture* 72 (2010) 99–106
- [13] Rumpf T, Mahlein A. K, Steiner U, Oerke E. C, Dehne H. W, Plumer L. 2010, Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance, *Computers and Electronics in Agriculture* 74 (2010) 91–99
- [14] Li, X., He, Y., 2008, Discriminating varieties of tea plant based on Vis/NIR spectral characteristics and using artificial neural networks, *B I O S YSTEMS ENGINE E R I N G* 99 (2008) 313 – 321
- [15] Wu D, Feng L, Zhang C, He Y. 2008, Early detection of *Botrytis cinerea* on egg plant leaves based on visible and near-infrared spectroscopy, *American Society of Agricultural and Biological Engineers* ISSN 0001-2351, Vol. 51(3): 1133-1139
- [16] Liaghata S, Ehsani R, Mansora S, Shafria H. Z. M, Meonc S, Sankaran S, Azam S. H. M. N. 2014, Early detection of basal stem rot disease (*Ganoderma*) in oil palms based on hyperspectral reflectance data using pattern recognition algorithms, *International Journal of Remote Sensing*, Vol. 35, No. 10, 3427–3439