

Ramon, Herman, Dimitros Moshou, Cedric Bravo, Els Vrindts, and Josse De Baerdemaeker. 2006. Section 5.6 Sensing and Information Handling for Crop Protection, pp. 279-289 of Chapter 5 Precision Agriculture, in CIGR Handbook of Agricultural Engineering Volume VI Information Technology. Edited by CIGR-The International Commission of Agricultural Engineering; Volume Editor, Axel Munack. St. Joseph, Michigan, USA: ASABE. Copyright American Society of Agricultural Engineers.

Çevirmenler: Pınar DEMİRCİOĞLU ve İsmail BÖĞREKÇİ
Çeviri Editörleri: Sefa TARHAN ve Mehmet Metin ÖZGÜVEN

5.6 Bitki Korumada Algılama ve Bilgi Yönetimi

Yazarlar: H. Ramon, D. Moshou, C. Bravo, E. Vrindts ve J. De Baerdemaeker

Çevirmenler: Pınar DEMİRCİOĞLU ve İsmail BÖĞREKÇİ

Özet: Tarımsal bitkilerin durumlarının değerlendirilmesini esas alan, bölgesel olarak optimize edilmiş bitki korumaya imkan veren hassas tarım teknikleri, etkin bitki korumanın gelişimine yeni bir itici güç olmuştur. Son yıllarda, bu tür değerlendirmeler için farklı algılama teknikleri geliştirilmiştir. Bu bölümde yabancı ot algılaması ve bitki hastalıklarının tespiti üzerinde duracağız. Çok çeşitli otomatik değerlendirme olanakları, zirai ürünlerin ışınım karakteristiklerine bağlıdır. Termal ışınımın yanında güneş ışığı yansımaları burada kullanılabilir. Klorofil ışınımı, bitki büyümesi sırasında oluşan fizyolojik değişimlere daha derin bir bakış şansı sağlamaktadır. Ancak, bu tekniklerin büyük bir özenle kullanılması gerekmektedir. Güncel hesaplama yöntemleri; gerçek tarla koşulları altında bitki durumuyla alakalı güvenilir bilgileri oluşturur ve sağlar. Sinir ağları ve sensör birleştirme mimarileri tartışılmıştır.

Anahtar Kelimeler: Yabancı ot tespiti, Yansıma, Floresans, Hastalık tespiti, Sensör birleştirme, Sinir ağları, Noktasal püskürtme.

5.6.1 Giriş

Geleneksel olarak bitki koruma önlemlerine; yabancı otların türleri ve yoğunluklarına göre mevcut durumlarının tespit edilmesi, hastalıkların ve diğer haşerelerin yaygınlığının ve görünürlüğüne belirlenmesi amacıyla yapılan tarım arazisinin denetlenmesiyle karar verilir. Daha sonraki gerekli uygulamalara karar verecek olan çiftçi tarafından bu görev gerçekleştirilir. Son yıllarda optik algılama teknikleri, yabancı ot ve hastalık tespitinin otomasyonu için test edilmiştir. Hassas tarımdaki gelişmeler, tarlanın her bir yeri için uygun işlemleri yapacak şekilde değişken oranlı uygulamaların yapılmasını mümkün kılmıştır. Bu kitabın Bölüm 5.5’indeki Şekil 2, bu tür bir sistemin çalışma prensiplerini şekillendirmektedir. Takip eden bölümler, yabancı otların ve bitkilerin sağlık durumlarının daha otomatikleştirilmiş tespiti için kullanılabilecek tekniklerle ilgili genel bir bakış sunmaktadır.

5.6.2 Yabancı Ot Tespiti için Optik Teknikler

Çevrim içi yabancı ot mücadelesi yapabilmek için ticari olarak bulunabilecek birkaç sistem (Örneğin, Concord [Avustralya] şirketi tarafından geliştirilen Detectspray; Progressive Farm Products [ABD] şirketi tarafından geliştirilen Spot Shot ve Patchen [ABD] şirketi tarafından geliştirilen Weedseeker) kızıl ve yakın kızılötesi yansımayı temel alan yeşil bitki tespitini kullanmaktadır. Bu sistemler, tarımsal bitkiler ile yabancı otlar arasında ayırım yapmamaktadır ama bu sistemler sıraya ekilmiş bitkilerin araları ile nadasa bırakılan arazi, meyve bahçeleri veya bağlar ve diğer tarım dışı alanlar için kullanışlıdır [1,2].

GPS ve bilgisayarlar, tarlanın denetlenmesi sırasında kısmi yabancı ot gruplarının noktasal tespitinde kullanılabilir fakat bu iş yoğun bir aktivitedir. Uzaktan algılama yoluyla (havadan fotoğrafı, yüksek çözünürlüklü uydu görüntüleme), tarladaki yüksek yoğunluklu yabancı ot kümeleri tespit edilebilmektedir.

Ancak düşük yoğunluklar ve karışık türler, uzaktan algılamayla doğru şekilde tanımlanamazlar [3,4]. Yabancı ot popülasyonundaki mevcut türlerin kesin olarak belirlenebilmesi için tarla denetimi gereklidir. Makine görüşü, otomatik yabancı ot tespiti konusunda test edilmiştir. Şekil, tekstür ve renk; tarımsal bitkilerin ve yabancı otların tanımlanması için kullanılabilir [5-8]. Segmentasyon veya bitki ve arka planı arasında ayırım yapma ilk önemli adımdır. Bitkiler çoğunlukla renk tabanlı olarak tanımlanmaktadır. Fakat bu ortamda bulunan ışığa bağlıdır. Tian ve Slaughter [9], ortamdaki değişken ışık koşullarını hesaba katan ve daha iyi sonuçlar veren yeni bir segmentasyon yöntemi tasarlamıştır. Renk ve şeklin yanında tarımsal bitkilerin işlenmemiş biçimi, yabancı otlardan ayırt etmek için kullanılabilir [5]. Daha karmaşık şekil analizi, yaprak şekil tiplerinin tanımlandığı ve sınıflandırma için kullanıldığı aktif şekil modellemeyi içermektedir. İlk testler bu yöntemle yapılan sınıflandırmanın %80 doğru olduğunu göstermiştir [10]. Üst üste gelen yaprak şekillerinin görüntüde doğru şekilde tanımlanamaması, şekil analizinde hala problem teşkil etmektedir.

Klorofil floresansı ayrıca, türleri birbirinden ayırmaya yarayacak ve böylece yabancı otları tanıyacak, türlere özel modeller ortaya koymaktadır. Chapelle ve ark. [11], lazerle uyarılmış floresans yoluyla türlerin tanınması yolunda bir potansiyelin varlığını ortaya koymuştur. Yeşil bitki örtüsünün floresans sinyalleri, normal yansımayla kıyasla düşük yoğunluğa sahiptir ve bu yüzden ölçümü zordur. Bu durum dış ortam şartları için iyi bir sistem tasarımı geliştirmeyi zorlaştırmaktadır. Ancak, Kebabian ve ark. [12] ortam ışığının ve yansımanın bulunmadığı durumda, 760 nm civarındaki oksijen emilimi bandında ışınımı ölçebilen pasif bir sistem tanımlamışlardır. Yabancı ot tespitine yönelik bu sistemin performansı henüz bildirilmemiştir.

Yabancı ot tespitine yönelik spektral yöntemler; çeşitli dalga bandları ve dalga bandı genişlikleri (spektral çözünürlük) için araştırılmıştır [13-15].

Wang ve ark. [16], sabit ışıkta ve 5 banddaki yansımayı kullanmışlar ve %80 doğru bir yabancı ot sınıflandırma seviyesine ulaşmışlardır. Sabit aydınlatmada ve 600 nm ile 1060 nm aralığında, yüksek spektral çözünürlüğe sahip hat görüntüleme spektrografisi, Borregaard ve ark. tarafından [14] yabancı ot, patates ve şeker pancarının tespiti için test edilmiştir. Görüntüleme spektrografisi, %90 doğru sınıflandırma seviyesiyle iyi derecede performans göstermiştir. Vrindts ve ark. [13], benzer bir ekipmanı 420 nm ile 830 nm aralığında tarla koşullarında, doğal ışık altında test etmiştir. Sınıflandırma sonuçları benzer olmuştur (%90'ın üzerinde doğru sınıflandırma). Bu durum, sınıflandırma modelinin ışık şartlarına uyarlanabileceğini göstermiştir. Moshou ve ark. [17] sinir ağları sınıflandırmasının, tarımsal bitkiler ve yabancı ot spektral verileri üzerinde yapılan klasik çok değişkenli ayrıştırıcı tekniklere göre daha iyi sonuçlar verdiğini belirtmişlerdir.

Günümüzde, değişen ışık koşulları hala iyi bir yabancı ot tespit sistemi geliştirmede önemli zorluklardan biri olarak karşımızdadır. Anlık ışığı ölçme ve belirli ışık koşullarına uyarlanmış sınıflandırma modelleri kullanmak bu sorunu çözmeye yardımcı olabilir. Sensör birleştirme ve sinir ağları gibi gelişmiş işlem süreçleri yabancı ot tespiti sonuçlarını daha ileriye götürebilir. İhtiyaç duyulan yüksek kalite görüntüler ve yüksek bilgi işlem süresi, yabancı ot tespitinde bilgisayar görüşü kullanmanın temel çekinceleridir. Fakat kamera ve donanımların sürekli gelişmesi, çevrim içi yabancı ot tespiti gibi uygulamaları mümkün kılacaktır.

5.6.3 Hastalık ve Stres Tespiti

Besin stresi, hastalıklar ve haşereler, tarımsal bitkilerde gözle görülür bozulmalara yol açtığından; bunların tarlada yayılımını belirlemede optik teknikler kullanılabilir. Yansıma spektrumlarının, çeşitli tür streslere karşı genel reaksiyonu [18] ve [19]'da verilen kaynaklar tarafından incelenmiştir. Yaprakların spektral yansıma karakteristiklerinin, kendi kimyasal içerikleriyle son derece yüksek korelasyona sahip oldukları gösterilmiştir. Lorenzen ve Jensen [20], Polischuk ve ark. [21] ve Sasaki ve ark. [22], sırasıyla arpa, domates ve salatalık yapraklarında spektral hastalık tespiti yapabilmeye başarılı olmuşlardır. Masoni ve ark. [23], farklı yaprak spektral özellikleri üzerine çeşitli mineral streslerinin etkilerini göstermişlerdir. Yerinde bitki azot durumu, hat görüntüleme spektrografisiyle başarılı şekilde tahmin edilebilir ve klorofil içeriği için tahminleme hatası %10 olmaktadır [24]. Hastalıkların ve stresin önceden haritasının çıkarılması da havadan uygulanan sistemlerle elde edilebilir. Birkaç metreye kadar indirgenen alansal çözünürlükler uydulardan; 1 m'nin altında çözünürlükler ise hava araçlarından sağlanabilmektedir [25]. Mevcut ticari uydu algılaması, konumsal çözünürlüğün kısıtlarından dolayı erken hastalık tespiti için muhtemelen uygun değildir (hatta verilerin toplandığı dalga boyları uygun olsa bile). En iyi durumda uydu görüntüleri, nispeten geniş olan bitki hastalık veya diğer stres dağılım alanlarının genel olarak tespitinde kullanışlı olacaktır fakat daha sonra çiftçi tarafından kontrol edilmesi

gerekmektedir. Buna ilaveten tekrar ziyaret zamanı ve bulutlanma durumundaki deęişkenlik, bu basit bilginin gerektiğinde hazır olamayabileceęi anlamına bile gelebilir. Hava araçlarına monte edilmiş sistemler bu kısıtları taşımamakta ve gerektięi zaman kullanılabilir. Ancak hava araçlarındaki veri toplama ekipmanı, kara araçlarına monte edilmiş sistemlere nazaran daha hızlı, daha karmaşık ve daha pahalı olma eğilimi göstermektedir.

Optik tabanlı hastalık tespit sistemleri için; yansıma, floresans ve termal algılama olmak üzere üç ölçme yöntemi kullanılmaktadır. Her bir ölçme yöntemi için farklı teknikler halihazırda bulunmaktadır. Yansıma ölçümleri için spektrofotometri, spektral hat görüntüleme ve çoklu spektral görüntüleme; ışımaya için floresans kinetięi, spektrometri ve görüntüleme; termal algılama için termoradyometri ve termografi teknikleri kullanılmaktadır.

Yansımaya Dayalı Algılama

Yansımayı temel alan yöntemler, bir veya daha fazla dalga bandında eş zamanlı ölçümler yapmaya dayanır. Kullanılan ekipmanın türüne göre, ölçülen spektrumların detayları (spektral çözünürlük) dar (0,5-5 nm) ile geniş (20-100 nm) dalga bandları arasında deęişkenlik gösterir. Eęer görüntü alanı büyük ise gelen yansımanın büyük bir bölümü, sağlıklı yapraklar ve toprak tarafından kaynaklanacağından, ancak küçük bir bölümü hastalıklı alanlara ait olacaktır. Bu durum, spektrofotometrelerin hassasiyetinin azaltılmasını gerektirebilecektir. Daha sonra tarımsal bitkiye ait hastalıklı ve sağlıklı alanları birbirinden ayırmak zor olacaktır.

Yansımaya dayalı spektral ölçümleri en iyi şekilde kullanabilmek amacıyla, aydınlatmadaki deęişimleri dikkate alacak şekilde bu ölçümlerin normalleştirilmeleri gerekmektedir [26]. Böylece pratik yansıma ölçüm sistemleri, gelen aydınlanmanın spektral içerięinin gözlem yöntemini içermelidir [27].

Tarımsal bitkinin hastalıklı ve sağlıklı alanları arasındaki ayırım; hastalıklı ve sağlıklı dokuların yansıttığı spektrumlardaki farklılıkların tanımlanmasına bağlıdır. Büyük miktarlardaki verilerin işlenmesinden kaçınmak amacıyla, hastalıklı ve sağlıklı bitkileri birbirinden ayırt eden, dalga bandları veya dalga bandları kombinasyonlarının tanımlanması gereklidir. Büyük bir aralıktan uygun dalga bandı kümesi tespit etmek için kullanılan bir algoritma, geniş aralıktaki tarla koşullarında elde edilen görüntüleri açıklamak için kullanılmıştır. Sonuçlar, hastalığın benzer noktadaki ciddiyetinin görsel yorumuyla mukayese edilmiştir [28,29]. Eęer nispeten çok az sayıda dalga bandları, hastalıkların varlığını tespit edebilmek için kullanılırsa, tespit ekipmanı daha basitleştirilebilir (örneğin spektrograflar yerine filtreler kullanılarak) ve böylece maliyetler düşürülebilir.

Yansıma spektrumları sadece ortam aydınlanmasının spektral kalitesine bağlı değildir, aynı zamanda sensörün görüş yönü ile aydınlanma arasındaki açıya bağlıdır. Yorumlama algoritmaları; güneş açısını, doğrudan ve daęınık radyasyon oranlarını

hesaba katması gerekebilir. Bunun yanında optik sensörlerin görme açıları, tarımsal ürün yaprakları boyunca geçen ve bitki örtüsünden kaynaklanan yansımalarla karışmış olan toprak kaynaklı yansımaların etkisini dikkate almalıdır. Diğer bir dikkat edilmesi gereken husus ise patojenler bir kuluçka süresi gerektirdiğinden ve üst yaprakların en son açılmasından dolayı bu yapraklarda hastalık semptomunun bulunmamasıdır.

Floresans Tabanlı Algılama

Floresans tabanlı hastalık tespiti; bir uyarma kaynağına ve aynı zamanda ışımaya sinyali tespit etmek için bir ekipmana ihtiyaç duyar. Uyarma kaynakları UV lambaları veya lazerler olabilir. Floresans görüntüleri, uygun filtre takılan dijital kameralar (örneğin, 690 nm seviyesinde tek bandlı) veya eğer birden fazla floresans dalga bandı kullanılıyorsa çoklu spektral kameralar kullanılarak kaydedilebilir. Floresans sinyalleri kolaylıkla arka plan ortam aydınlığıyla sönmülenebilir. Bu durumun üstesinden, senkronize girişli dedektörlerin eşlik ettiği belli bir darbe sinyalindeki kaynaklar kullanılarak gelinebilir. Gün ışığında tarla gözlemi için atımlı girişli sistemler, birkaç yüzlük uyarı maruziyetleri üzerinde floresans sinyali entegre ederek kullanılmıştır [30,31]. Hareketli platformlara (örneğin traktörler, hava taşıtları) daha uygun olan daha hızlı ölçme sistemleri, tek noktalı kanopi floresans özelliklerini hem spektral içerikleri [32,33] hem de zaman çözünürlüklü yoğunluk [34,35] açısından tespit etmek için tasarlanmıştır. Hastalık semptomlarının gözle görünmesinden önceki aşamasını tanımlama potansiyeline sahip olan bu teknikler, tarladaki klorofil floresansını tespit etmek için geliştirilmiş olsalar da ilgili ekipmanların karmaşıklığı bunların pratik kullanımını sınırlamaktadır. Özellikle çok hızlı floresans ölçmedeki gelişmeler gibi uzaktan algılayabilen kinetik floresans tekniklerindeki gelişmeler, atmosfer ve ortam ışığındaki değişimlere karşı hassasiyet taşımadıklarından, tarla uygulamaları için özel ilgi odağı olacaktır.

Termal Algılama

Termal görüntüleme hastalık tespiti için bir potansiyel sunmaktadır [36,37]. Ekipmanın oldukça pahalı olmasından dolayı pratikte ve taşıtlara monteli düşük maliyetli sistemlerde kullanımı sınırlı kalmıştır.

5.6.4 Bitki Koruma İçin Veri Yönetimi

Çoklu Sensör Birleştirme

Yukarıda belirtildiği gibi her tür hastalık tespit sistemi, kendine has teknik problemlere ve yorumlama zorluklarına sahiptir. Tekli sensör sistemine kıyasla daha hassas ve ayırt edebilen sistem elde edebilmek için bir başka alternatif yaklaşım, birden fazla sensör sistemi kullanmak ve ölçümleri bütünleştirmektir.

Çoklu sensör veri birleştirme sistemleri; çoklu sensörlerden gelen verileri, tek bir sensörden elde edilemeyecek şekilde anlam elde edebilmek için bir araya getirir

[38,39]. Veri birleştirme, sürekli dış dünya hakkında çıkarımda bulunmak amacıyla algıladıkları verileri bir araya getirmek için halihazırda insanlar tarafından kullanılan bilişsel sürecin aynısıdır. Veri birleştirme sistemleriyle ilgili geliştirme süreçleri, gözlemlenen olaylara kullanılan sensörlerin tiplerine ve araştırılan çıkarımlara bağlıdır. Genellikle yüksek seviyeli çıkarımları hedefleyen uygulamalar; uzman sistemler, model eşleştirme, sinir ağları ve bulanık mantık gibi yapay zeka alanlarındaki tekniklerin kullanımını gerektirmektedir.

Temel bir konu mimari seçimidir [39]. Bu konu, iki veya daha fazla sensörden gelen veri işleme akışı içerisinde verilerin nerede bir araya getirileceği sorusu etrafında dönmektedir. Üç temel çoklu sensör füzyon mimarisi mevcuttur:

- *Merkezi füzyon mimarisi*: Bu yaklaşım, gözlemlenen nesnenin kimliğini belirlemek için çoklu sensörlerden gelen ham verileri kullanmaktadır. Sensörlerin bir nesnenin aynı fiziksel izlerini gözlemlediği durumlar için kullanışlı bir seçenektir (Örneğin, kızıl ötesi ve görünür görüntüler).
- *Özellik vektörlerine sahip merkezi füzyon*: Bir özellik vektörü çıkarmak için okuyan her bir sensöre bir ön işlem uygulanır. Bu özellik vektörleri tek bir vektör üzerinde yoğunlaştırılır ve sınıflandırma algoritmasına girdi olarak kullanılır.
- *Otonom füzyon*: Bu yaklaşımda, her bir sensörden gelen çıktı bir karardır (örneğin, kimlik beyanı). Akıllı sensörler bu tür bir füzyonla bütünleştirilebilir. Hastalık ve stres tespiti için optimum mimari, en az veri kaybıyla sonuçlanan ve gerçek zamanlı olarak uygulanabilecek kadar hızlı olan seçenek olacaktır. Özellik vektörlerine sahip merkezi füzyon en uygun seçenek gibi gözükmemektedir çünkü hem doğruluk hassasiyeti hem de hız anlamında her iki şartı sağlamaktadır.

Yapay Sinir Ağları

Yapay sinir ağları, kendi biyolojik eşdeğerlerinin fonksiyonlarına benzeyen genel haritalama cihazlarıdır [40]. Optimizasyon tabanlı öğrenme algoritmaları kullanılarak sinir ağları, dahili ağırlık kümelerinin ayarlanması yoluyla örneklerle eğitilebilir. Eğitimden sonra, bir sinir ağı beklenmeyen bir durumla ilgili genelleştirme yapabilir hale gelir (örneğin, daha önce karşılaşılmayan bir veri) [38]. Sinir ağlarının temel avantajları, modele bağlı olmamaları ve evrensel yaklaşım yeteneğine sahip olmalarıdır.

Çok Katmanlı Perseptron (ÇKP)


Ön beslemeli sinir ağları [41], girdi ve çıktı değişkenleri kümesi arasında doğrusal olmayan fonksiyonel haritalamaları temsil eden genel bir çerçeve yapısı sunmaktadır. Bu durum, aktivasyon fonksiyonları olarak adlandırılan tek bir değişkenin doğrusal olmayan fonksiyonlarının oluşturulması anlamında birçok değişkenin doğrusal olmayan fonksiyonunun temsil edilmesiyle elde edilebilir.

Bazı ortak kullanılan aktivasyon fonksiyonlarının arasında lojistik sigmoit ve hiperbolik tanjant bulunur. Bir ÇKP'nin eğitimi, ağırlıklarına oranla enerji fonksiyonunun minimumun bulunmasını içerir. Optimal ağırlıklar, enerji fonksiyonunun en düşük değerini küresel olarak oluşturmaktadır. Optimizasyon süreçlerinin çeşitleri, enerji fonksiyonunu minimize eden ağırlıkları bulmak için kullanılabilir.


Kendi Kendine Organize Eden Harita

Kendi kendini organize eden harita (KOH) [42] bir sinir ağıdır ve yüksek boyutlu uzaydan gelen sinyalleri nöron birimlerinin bir veya iki boyutlu kesikli örgüsü şeklinde haritalandırır. Harita, girdi uzayındaki komşu girdileri harita uzayındaki komşu nöronlara haritalayacak şekilde girdiler arasındaki topolojik ilişkileri korumaktadır. Veriler arasında korelasyon bulmak için KOH kullanılması, eğitim kümesinden farklı bir küme kullanarak ve test kümesi veya etiketleme kümesindeki herbir örnek için en uyan birimleri bularak KOH'un nöronlarını etiketlemektir. Çoğunlukla bir sınıfın örnekleri tarafından çok sıklıkla seçilen nöronların bazıları, oylama prosedürüne göre etiketlenir. Daha sonra bu nöronlar, örnek vektörün her bir nöronun çizelge vektörüne olan öklit mesafesini hesaplayarak ve EUB'u bularak KOH'a sunulan yeni bir örneğin sınıfını tahmin edebilmektedir. Daha sonra EUB etiketi, yeni örnek vektörünün tahmin edilen sınıfıdır. Etiketlenmeyen nöronlar, sınıfların sınırlarını oluşturur ve bir sınıfa ait örnek gözlemlerin, başka bir sınıfa ait gözlemler olarak yanlış sınıflandırma derecesini gösterir.

Vaka çalışmasında, Moshou ve ark. [43] tarla ortamında spektral yansıma verileri kullanarak hastalık stresini, besin eksikliği stresinden ayırt etme girişiminde bulunmuşlardır. Sarı pasla enfekte olmuş kış buğdayı bitkileri, besin stresi geçirenler ve sağlıklı olanlarla karşılaştırılmıştır. Tarla içi hiperspektral yansıma görüntüleri bir görüntüleme spektrografisiyle alınmıştır. Yaprak tanıma, yüksek alansal çözünürlük görüntüsü üzerinde Normalleştirilmiş Fark Bitki İndeksi (NDVI, Normalized Difference Vegetation Index) eşiğiyle kullanılarak mümkün olmuştur. Hastalıklı ve besin stresi yaşayan kanopiler, daha düşük NDVI değerleri göstermiştir. Bu durum stresli bitkilerdeki düşük klorofil aktivitesiyle kısmen açıklanabilir. Yansıma ve ışık yoğunluğu ayarlamalarını temel alan normalleştirme yöntemi uygulanmıştır. Yüksek performanslı stres tespitine ulaşabilmek için KOH tanıtılmıştır. Sarı pasla enfekte olan kış buğdayı, besin stresi ve sağlıklı olanlardan başarılı şekilde ayrılmıştır. 5 dalga boyu kullanılarak elde edilen genel performans, stresin (hastalık ve besin) tespiti ve tanımlanmasında %99'dan fazla olmuştur. Şekil 1; sağlıklı, hastalıklı ve azot stresi yaşayan kış buğdaylarının tipik spektral cevaplarını göstermektedir. Şekil 2; vaka çalışmasının sinir ağılarıyla sınıflandırılmış sağlıklı, besin stresli ve hastalıklı örnekleri temsil etmektedir.



Şekil 1. Spektrograf ölçümlerinin spektrumu.



Şekil 2. Hastalıklı, azot eksikliği ve sağlıklı bitkilerin spektrumlarının KOH tabanlı tanımlaması. Yeni bir spektrum gösterilen birimlerden biri için atanır ve buna tahsis edilmiş olan bir birim etiket kullanılarak belirlenir (D = hastalıklı ve H = sağlıklı, N = azot eksikliği olan). Elipsoidler tanımlanmış azot eksikliği olan bitki örtüsü (kanopi) spektrumlarını göstermektedir.

5.6.5 Bitki Koruma Uygulamalarına Karar Verme

Yabancı ot uygulamaları için herbisit seçimi veya diğer uygulamalar, yabancı otun türüne ve otların yayılma durumuna bağlıdır. Düşük yabancı ot popülasyonları belki tolere edilebilir, kültür bitkisinin tohumları arasına karışan yabancı ot tohumlarından çoğalacak olan gelecekteki yabancı ot problemleri çözümünün de aynı zamanda mücadele uygulamaları düşünülürken hesaba katılması gerekir. Gerekli yabancı ot mücadelesini optimize edilmesi geçmiş veriler (yabancı ot yoğunluğu ile verim cevap eğrileri ve herbisit dozu cevap eğrileri) temel alınarak gerçekleştirilir. Doğru herbisit kullanımı için ürün rehberleri (prospektüs) ambalajlarda, üreticilerde mevcuttur ve bunlar farklı koşullar için gerekli olan dozları belirtmektedir. En iyi uzun dönemli stratejiyi belirlemek için yabancı ot yönetimi, kültür bitkisi ile yabancı ot rekabet modelleri ve yabancı ot popülasyon modelleri kullanılarak geliştirilebilir [44].

Kapsamlı testlerle belirlenen ürün rehberleri, tarım ilaçlarının kullanımı konusunda net talimatlar sağlamaktadır. Zararlıları ve hastalıkları kontrol altına almak için önleyici bir uygulamaya ihtiyaç duyulur. Ancak, zorunlu hallerde tarım ilaçlarının kullanılmalıdır. Bölgesel bilgi ağları, çiftçileri hastalıkların ve zararlıların varlığı konusunda uyarabilir ve bölgedeki tarlalardaki doğru uygulamaları başlatabilir. Yine, zararlı ve hastalık kontrolünü iyileştirmek için modeller geliştirilebilir. Örneğin bitki koruma kriterleri (Zadoks [45] tarafından önerilen EPIPE sisteme bakılabilir) konusunda karar vermek için hastalık seviyesi, iklim bilgisi ve hastalık gelişim modelleri kullanılabilir. Modellerin cevaplayabileceği önemli bir soru: yapılacak olan mücadele hastalıktan kaynaklanan muhtemel verim kaybını karşılayabilecek midir?

Bölgesel tarımsal ürünlere, topraklara, iklime ve hastalıklara uygun olacak yabancı otların, zararlıların ve hastalıkların mücadelesinde gerekli karar desteğini geliştirmek için çok sayıda uygulamaya yönelik tecrübe ve bilgi gereklidir.

Kaynaklar

1. Felton, W. L. 1995. Commercial progress in spot spraying weeds. Brighton Crop Protection Conference—Weeds—1995. 3: 1087-1096. UK: British Crop Protection Council.
2. Ahrens, W. H. 1994. Relative costs of a weed-activated versus conventional sprayer in northern great plains fallow. Weed Technology 8: 50-57.
3. Brown, R. B., J.-P.G. A. Steckler, and G. W. Anderson. 1994. Remote sensing for identification of weeds in no-till corn. Trans. ASAE 37(1): 297-302.
4. Goel, P. K., S. O. Prasher, R. M. Patel, D. L. Smith, and A. DiTommaso. 2002. Use of airborne multi-spectral imagery for weed detection in field crops. Trans. ASAE 45(2): 443-449.
5. Pérez, A. J., F. López, J. V. Benlloch, and S. Christensen. 2000. Colour and shape analysis techniques for weed detection in cereals fields. Computers and Electronics in Agriculture 25: 197-212.

6. Woebbecke, D. M., G. E. Meyer, K. Von Bargen, and D. A. Mortensen. 1995. Shape features for identifying young weeds using image analysis. *Trans. ASAE* 38(1): 271-281.
7. Zhang, N., and C. Chaisattapagon. 1995. Effective criteria for weed identification in wheat fields using machine vision. *Trans. ASAE* 38(3): 965-974.
8. Hemming, J., and T. Rath. 2001. Computer-vision-based weed identification under field conditions using controlled lighting. *J. Agricultural Engineering Research* 78(3): 233-243.
9. Tian, L. F., and D. C. Slaughter. 1998. Environmentally adaptive segmentation algorithm for outdoor image segmentation. *Computers and Electronics in Agriculture* 21: 153-168.
10. Søgaard, H. T., and T. Heisel. 2002. Weed classification by active shape models. *EurAgEng Budapest 2002. EurAgEng Paper Nr. 02-AE-004.*
11. Chappelle, E. W., F. M. Jr. Wood, J. E. McMurtry III, and W. W. Newcomb. 1984. Laser-induced fluorescence of green plants 1: A technique for the remote detection of plant stress and species identification. *Applied Optics* 23(1): 134-138.
12. Kebabian, P. L., A. F. Theisen, S. Kallelis, H. E. Scott, and A. Freedman. 1999. Passive two-band plant fluorescence sensor with applications in precision agriculture. *Proc. of the Precision Agriculture and Biological Quality Conference*, eds. G. E. Meyer, and J. A. DeShazer, 3543: 238-245. Bellingham, WA: SPIE.
13. Vrindts, E., J. De Baerdemaeker, and H. Ramon. 2002. Weed detection using canopy reflection. *Precision Agriculture* 3(1): 63-80.
14. Borregaard, T., H. Nielsen, L. Nørgaard, and H. Have. 2000. Crop-weed discrimination by line imaging spectroscopy. *J. Agricultural Eng. Research* 75: 389-400.
15. Noble, S. D., and T. G. Crowe. 2001. Plant discrimination based on leaf reflectance. *ASAE Paper No. 01-1150.* St. Joseph, MI: ASAE.
16. Wang, N., N. Zhang, F. Dowell, and D. Peterson. 2001. Design of an optical weed sensor using plant spectral characteristics. *Trans. ASAE* 44(2): 409-419.
17. Moshou, D., E. Vrindts, B. De Ketelaere, J. De Baerdemaeker, and H. Ramon. 2001. A neural network based plant classifier. *Computers and Electronics in Agriculture* 31(1): 5-16.
18. Carter, G. A., and A. K. Knapp. 2001. Leaf optical properties in higher plants: linking spectral characteristics to stress and chlorophyll concentration. *American J. Botany* 88(4): 677-684.
19. Cibula, W. G., and G. A. Carter. 1992. Identification of a far-red reflectance response to ectomycorrhizae in slash pine. *International J. Remote Sensing* 13: 925-932.
20. Lorenzen, B., and A. Jensen. 1989. Changes in spectral properties induced in Barley by cereal Powdery Mildew. *Remote Sensing Environment* 27: 201-209.
21. Polischuk, V. P., T. M. Shadchina, T. I. Kompanetz, I. G. Budzanivskaya, and A. A. Sozinov. 1997. Changes in reflectance spectrum characteristic of *Nicotiana debneyi* plant under the influence of viral infection. *Archives of Phytopathology and Plant Protection* 31(1): 115-119.
22. Sasaki, Y., T. Okamoto, K. Imou, and T. Torii. 1998. Automatic diagnosis of plant disease-Spectral reflectance of healthy and diseased leaves. *Proc. of 3rd IFAC/CIGR Workshop on Artificial Intelligence in Agriculture*, Makuhari, Chiba, 158-163.
23. Masoni, A., E. Laura, and M. Mariotti. 1996. Spectral properties of leaves deficient in iron, sulphur, magnesium and manganese. *Agronomy J.* 88(6): 937-943.
24. Dumont, K., and J. De Baerdemaeker. 2001. In field wheat nitrogen assessment using hyperspectral imaging techniques. *Proc. of the Third European Conference on Precision Agriculture*, 905-910, eds. G. Grenier, and S. Blackmore, Montpellier, France: Agro Montpellier (ENSAM).

25. Blakeman, R. H., R. J. Bryson, and P. Dampney. 2000. Assessing crop condition in real time using high resolution satellite imagery. *Aspects of Applied Biology* 60, *Remote Sensing in Agriculture*, 163-71. Wellesbourne, UK: The Association of Applied Biologists.
26. Price, J. C. 1994. How unique are spectral signatures? *Remote Sens. Environ.* 49: 181-186.
27. Borel, C. C., and S. A. W. Gerstl. 1994. Are leaf chemistry signatures preserved at the canopy level? *Proc. Int. Geoscience and Remote Sensing Symposium*, 996-998.
28. Bravo, C., D. Moshou, R. Oberti, J. West, A. McCartney, L. Bodria, and H. Ramon. 2002. Detection of foliar disease in the field by the fusion of measurements made by optical sensors. ASAE Paper No. 023087. St. Joseph, MI:ASAE.
29. Moshou, D., C. Bravo, J. S. West, S. Wahlen, H. A. McCartney, and H. Ramon. 2004. Automatic detection of yellow rust in wheat using reflectance measurements and neural networks. *Computers and Electronics in Agriculture* 44: 173-178.
30. Johansson, J., M. Andersson, H. Edner, J. Mattson, and S. Svanberg. 1996. Remote fluorescence measurements of vegetation spectrally resolved by multicolour fluorescence imaging. *J. Plant Physiol.* 148: 632-637.
31. Saito, Y., K. Hatake, E. Nomura, T. D. Kawahara, and A. Nomura. 1997. Rangeresolved image detection of laser-induced fluorescence of natural trees for vegetation distribution monitoring. *Jpn. J. Appl. Phys.* 36: 7024-7027.
32. Corp, L. A., J. E. McMurtrey, E. W. Chappelle, C. S. T. Daughtry, and M. S. Kim. 1997. UV band fluorescence (in vivo) and its implications for the remote assessment of nitrogen supply in vegetation. *Remote Sens. Environ.* 61: 110-117.
33. Ludeker, W., H. G. Dahn, and K. P. Gunther. 1996. Detection of fungal infection of plants by laser-induced fluorescence: An attempt to use remote sensing. *J. Plant Physiol.* 148: 579-585.
34. Flexas, J., J. M. Briantais, Z. Cerovic, H. Medrano, and I. Moya. 2000. Steadystate and maximum chlorophyll fluorescence responses to water stress in grapevine leaves: A new remote sensing system. *Remote Sens. Environ.* 73: 283-297.
35. Morales, F., R. Belkhdja, Y. Goulas, J. Abadia, and I. Moya. 1999. Remote and near-contact chlorophyll fluorescence during photosynthetic induction in irondeficient sugar beet leaves. *Remote Sens. Environ.* 69: 170-8.
36. Chaerle, L., W. Van Caeneghem, E. Messens, H. Lambers, M. Van Montagu, and D. Van Der Straeten. 1999. Presymptomatic visualization of plant-virus interactions by thermography. *Nat. Biotechnol.* 17: 813-816.
37. Lili, Z., J. Duchesne, H. Nicolas, and R. Rivoal. 1991. Détection infrarouge thermique des maladies du blé d'hiver. *Bulletin OEPP/EPPO Bulletin* 21: 659-672.
38. van Dam, J., B. Krösse, and F. Groen. 1996. Neural network applications in sensor fusion for an autonomous mobile robot. *Reasoning with Uncertainty in Robotics*, eds. L. Dorst, M. van Lambalgen, and F. Voorbaak, 263-277. New York, NY: Springer-Verlag.
39. Hall, D. L. 1992. *Mathematical Techniques in Multisensor Data Fusion*. Boston, MA-London, UK: Artech House.
40. Haykin, S. 1994. *Neural Networks - A Comprehensive Foundation*. New York, NY: Macmillan College Publishing Company.
41. Rumelhart, D. E., G. E. Hinton, and R. J. Williams. 1986. Learning internal representations by error propagation. *Parallel Distributed Processing*, Vol. 1, eds. D. E. Rumelhart, and J. L. McClelland, 318-362. Cambridge, MA: MIT Press.
42. Kohonen, T. 1995. *Self-Organizing Maps*. Berlin, Germany: Springer-Verlag.
43. Moshou, D., C. Bravo, S. Wahlen, J. West, A. McCartney, J. De Baerdemaeker, and H. Ramon. 2003a. Simultaneous identification of plant stresses and diseases in arable

- crops based on a proximal sensing system and self-organizing neural networks. Proc. of the Fourth European Conference on Precision Agriculture (4ECPA Berlin), 425-432. Wageningen Academic Publishers.
44. Paice, M. E. R., W. Day, L. J. Rew, and A. Howard. 1998. A stochastic simulation model for evaluating the concept of patch spraying. *Weed Research* 38: 373-88.
 45. Zadoks, J. C. 1989. EIPRE: A computer-based decision support system for pest and disease control in wheat: its development and implementation in Europe. *Plant Disease Epidemiology, Vol. 2: Genetics, Resistance and Management*, ed. G. R. Conway Wiley, 344-351. Chichester, UK.