

Marchant, John A. 2006. Section 5.4 Machine Vision in the Agricultural Context, pp. 259-272 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: İlnur BÖĞREKÇİ ve İsmail BÖĞREKÇİ
Çeviri Editörleri: Sefa TARHAN ve Mehmet Metin ÖZGÜVEN

5.4 Tarımda Makine Görüsü

Yazar: J. A. Marchant

Çevirmenler: İlnur BÖĞREKÇİ ve İsmail BÖĞREKÇİ

Özet: Bu bölüm, ancak son zamanlarda yapılabilir hale gelen, ziraat mühendisliği alanında heyecan verici bir teknolojinin tanıtımıyla ilgilidir. Yazarın özellikle yararlı bulduğu bazı ders kitapları, konuyla ilgili okuyuculara yardımcı olması açısından ekte sunulmuştur. Bu bölüm, yazarın özellikle tarımda bulunan faaliyet tipleriyle alakalı olduğunu düşündüğü birkaç konu üzerinde yoğunlaşmıştır. Bu faaliyetler doğal ve biyolojik nesnelere olup bazıları kontrolsüz dış ortam aydınlatma şartlarında bulunmaktadır. Bazı araştırmalardan belirli noktaları tasvir etmek için alıntı yapılmıştır. Bazı çalışmaların liste dışı bırakılması, onlar hakkında herhangi bir olumsuz eleştiri anlamına gelmemektedir. Ayrıca, yazar tarımsal uygulamalar dışında kalan fakat bu bölümün konusuyla alakalı olan genel çalışmaları da dahil etmeye çalışmıştır. Bu yaklaşımın amacı, ziraat mühendislerinin makine görüşü (ve diğer) araştırmalarından tam yarar sağlamak için kendi özel uygulamalarının dışına da bakmaları gerektiği mesajını kısmen yaymak içindir.

Anahtar Kelimeler: Makine görüşü, Görüntü analizi, Patern tanıma, Bilgisayarla Görü, Algılama, Tarım, Bilgi teknolojisi.

5.4.1 Giriş

Makine Görüsü Nedir?

Bu konu tartışılırken ortak bazı terimlerle karşılaşılır. Bunlar arasında görüntü analizi, patern (örüntü) tanıma, bilgisayarla görüş, makine görüşü vardır. Bu terimlerin hepsi, neredeyse tüm uygulama durumlarında, dikdörtgen ve büyük olasılıkla kare olan bir çeşit konumsal (alansal) grid üzerine düzenlenmiş iki boyutlu veri analiziyle ilgilidir. Böylece bir görüntü, gözlemci konumundaki kişiye gösterildiği zaman (örneğin, bilgisayar ekranı ya da bir yazıcı gibi uygun bir cihaz üzerinde), görüntüyü oluşturan verilerin bir düzen içerisinde ifadesi olarak ele alınır. Terminolojide tam bir fikir birliği yoktur. Fakat muhtemelen en genel tanımıyla görüntü analizi; insanların yorumlayabilmesi için zıtlık geliştirme ve netleştirme gibi işlemlerle nesnelere görüntü verilerinin matematiksel işlenmesini içermektedir.

Örüntü (patern) tanıma; genellikle büyük oranda istatistiksel uygulamalara [1] ve sınıflandırma tekniklerine dayalı yöntemleri işaret eder. Çoğunlukla, *bilgisayarla görü* ve *makine görüsü* eşanlamlıdır. Otomatik olarak kararlar almak (yani, insan yorumu olmadan) ve ileriki işlem aşamaları veya cihazları kontrol etmek için bu kelimelerin (bilgisayarla görü ve makine görüsü) ikisini de görüntü analizi anlamına gelecek şekilde ele alacağız. Davies [2]'nin kitabının (şiddetle tavsiye edilmektedir) çok daha genel bir görünümü sahip olduğuna dikkat edilmelidir. Bu nedenle, bu bölüm otomatik makine veya sistemler için elektronik algılama gibi teknolojilerin kullanmasıyla ilgilenmektedir.

Makine Görüsü Kabiliyeti

Makine görüsü sistemleri hızlı bir şekilde çok büyük miktarda veriyi elde edebilme kabiliyetine sahiptir. Tipik bir sistem; her bir piksel için 3 bayt olacak şekilde (her renk kanalı için bir tane) renkli ve 768x576 piksel boyutunda görüntü yakalayabilmektedir. Yakın zamana kadar, görüntü yakalama ve gösterme, görüntü frekansı saniyede 25 (Avrupa TV Standartlarında çalışırsa) ya da 30 (ABD Standartlarında) olan standart TV sistemlerine bağlıydı. Bu da saniyede 3,3 milyon baytın üzerinde bir veri hızı oranına eşittir. Makine görüsü verileri dijital olduğu için, bilgi kontrolü olarak sonradan kullanım açısından daha sonraki bilgisayar analizlerine uygundur. Veri yakalama cihazı (kamera) doğası gereği temassızdır. Bu sebeple kurulumu için basit mühendislik gerektirir, algılanan nesneyle hiçbir etkileşim içerisinde değildir (örneğin hasarsız muayene için uygundur) ve herhangi bir olumsuz etki yapmadan (örneğin doğal davranışlarını bozmadan hayvanların gözlemlenmesi için) çalıştığı ortama yerleştirilebilir.

Bu zamana kadar, büyük miktardaki veri hem kazanımında hem de işleme sürecinde depolama problemleri oluşturmuştur. Bu zorluklar, yüksek yoğunluklu hafıza cihazlarının mevcut olmasıyla aşılmaktadır. Bugün bile, girişi eşleştirecek uygun bir hızda verilerin işlenmesi çoğunlukla mümkün değildir. Mesela, daha düşük bir hızda (saniyede 5 görüntü ya da düşük çözünürlük) veya düşük çözünürlükte yakalamak bir çözümdür. Ancak, gerçek problemleri çözmek için ihtiyaç duyulan yoğun işleme bu düşük hızlarda bile çalışmayı zorlaştırmaktadır. Ayrıca, makine kontrol sisteminin iyi çalışması için önemli ölçüde daha yüksek hıza gerek duyulabilir ve yüksek görüntü çözünürlüğü etkili görüntü analizi için gerekli olabilir. Neyse ki bilgisayar sisteminin kabiliyeti artmaya devam etmekte ve mesela 5 yıl önce imkânsız olan şimdi sıradan olmuştur.

Makine görüsü için gerçekten zor olan taraf, insanın akıl yürütme sistemine ulaşabilme yeteneğidir. Bu, biz insanların belirli şeyleri kolayca yapmasına rağmen, onları nasıl yaptığımızı kelimelere dökemediğimiz gerçeğiyle özdeşleştirilebilir. Birini bir ara görmesek bile onun yüzünü nasıl tanıdığımız buna bir örnektir. Bizler çoğu aydınlatma koşullarında ve kişinin buruşuk bir yüze sahip olması durumunda bile en ekstrem açılı aralıklarında bu yüz tanımayı yapabiliriz. Otomatik bir sistem

tasarlamak için, görüntüden elde edilen sayısal veriler üzerinde işlem yapabilmek amacıyla, bu tanıma yetisini öncelikle kelimelere ve daha sonra algoritmalara dönüştürmek zorundayız.

Görüntülenecek özneler oldukça basit olduğunda ve kontrollü bir şekilde herhangi görüntüleme sistemine sunulduğunda konu basitleşebilir. Fabrika denetim sistemlerinin iyi çalışmasının nedeni budur. Tarımsal çevre ile ilgili görüntü tanımını zor yapan şey yukarıda “kolay” makine görüsü için istenilen şartların çok az durumda karşılanabilmesidir. Bizim ilgilendiğimiz biyolojik nesnelere ilgili görüntü tanıma problemleri arasında şunlar bulunur:

- Görüntüdeki nesnelere genetik olarak bir birine benzer olsa bile, mühendislik açısından hepsi farklı olacaktır. Bu karakteristik değişkenlik, bizim ne görebileceğiyle ilgili herhangi bir sabit beklentimizin (veya model) olamayacağı anlamına gelir.
- Bazen (özellikle dışarıda çalışırken) aydınlatma kontrol edilemez.
- Bazen (örneğin canlı hayvanlarla çalışırken) nesnelere kameraya yansımaları değişkendir.
- İlgili nesnelere çoğunlukla bir birine temas eder ya da üst üste gelir.
- Arka planlar, alakasız veya kafa karıştırıcı veriler içerebilir. Bu verileri, dağınık olarak tanımlanan istatistiksel modellere bile uyarlamak oldukça zordur.

Teknolojik Etmenler

Neyse ki son zamanlarda makine görüsü uygulamasını, tarımda uygulanabilir hale getiren çok sayıda teknolojik ve sosyal etmen olmuştur. 1960'ın ortalarında G.E Moore, entegre devre başına transistör sayısında çok yüksek bir büyüme gözlemledi ve bu eğilimin devam edeceğini tahmin etti.


Sık sık alıntılanmış şekliyle "Moore Yasası" tek bir çip üzerindeki transistörlerin sayısının, her iki yılda bir iki katına çıkacağını söylemektedir. Bu bilgisayarların gücünde önemli ölçüde artışın olduğu anlamına gelmektedir. 1997 yılında yaptığı bir konuşmada Moore, bu eğilimin yaklaşık olarak 2017 yılında bitebileceğini söyledi. Ancak, bu sınırlılığa rağmen bilgisayarlar bir şekilde yeteneklerini hala arttırmaya devam edecektir. Yaklaşık olarak 1980'lerin ortalarına kadar teknolojinin gelişimi havacılık ve savunma sanayileri üzerinden gerçekleşmiştir. Maliyetler yüksek olduğundan sadece bu pazar onları destekleyebilmiştir. Şimdi en önemli etmen (bu yazarın görüşüne göre) ise tüketicilerin kullandıkları günlük araçlara yönelik olan pazardır. Tüketici mallarının oluşturduğu bu ilerleme etmeni, başlangıçta otomobil gibi değeri yüksek ürünlerden ve kişisel bilgisayar gibi düşük maliyetli ürünlerden kaynaklanmaktaydı. Şimdi ise bilgisayar oyunları ve oyuncaklar gibi düşük maliyetli ve yüksek hacimli olanlardan kaynaklanmaktadır. Makine görüsünün ihtiyaç duyduğu teknoloji, yüksek yetenek ve

düşük maliyetin bileşiminden özel olarak yararlanmıştır. Otomobillerde kullanılan enstrümanlara yönelik ara yüzler, bilgisayar oyunları, fotoğraf için video ara yüzleri ve evde internet kullanımı makine görüşünün maliyetinin, tarımda kabul edilebilir seviyelere düşmesine yardımcı olmuştur.

5.4.2 Makine Görüsü Süreci

Görüntü Oluşumu ve Algılama

Daha önceki bölümde açıklandığı gibi, tarımsal bağlamda makine görüşü genellikle zordur. Süreç hakkında olabildiğince çok bilgiyi anlamak ve kullanmak faydalı olacaktır. Bilgi kaynaklarından biri, görüntü oluşumu ve algılamanın ardındaki fiziksel ilkeleri içerir. Bu durumdan daha önceki genel bağlam[3, 4] anlamında ve kendi alanımız olan tarımda [5, 6] yararlanılmıştır. Görüntü oluşumu için kullanışlı bir model Şekil 1 'de gösterilmiştir.




Şekil 1. Görüntü oluşum süreci.

Aydınlatma (E), dalga boyunun (λ) bir fonksiyonudur ve aynı zamanda dalga boyuna bağlı iki işlemde geçer. Bu işlemler, yansıtıcılıkla (ρ) tanımlanan nesnelere yansıtma ve spektral tepkiyle (S) tanımlanan algılayıcıya yakalanmadır (renk filtrelerinden geçtikten sonra). Bu yüzden bir kameranın çıktısı aşağıdaki gibi tanımlanır:

$$C_I = a_I \int S_I(\lambda) \rho(\lambda) E(\lambda) d\lambda \quad (1)$$

Bu eşitlikte; C_I I'nci kamera kanalının çıktısı (yani, geleneksel renkli kameralar için kırmızı, yeşil ya da mavi) ve a_I , kanalın kazanımını tanımlayan sabittir. İki Renkli Yansıtma Model[7] gibi, ışıklı bölümleri (bazen *aynasal yansıtma* olarak adlandırılır) dikkate alan ve daha gelişmiş modeller mevcuttur ve tarımsal amaçla kullanılmıştır[5]. Şekil 2'de önemli bir ışık kaynağı olan gün ışığı ve ışık ile birlikte tipik bir yansıtma ve bir dizi kamera kanal hassasiyetlerini gösteren grafik grubu sunulmuştur.



Şekil 2. (a) Üç renk sıcaklığında gün ışığı spektrumları. (b) Tipik bitki örtüsünün görüntü yansımaları. (c) Tipik bir kameranın renk kanalları duyarlılıkları.

Gün ışığının spektrumu sabit değildir fakat gökyüzü koşullarına göre değişim göstermektedir. Judd ve ark.'nın çalışması [8], gün ışığı spektrumunun değişken olmasına rağmen bağlantılı renk sıcaklığı (CCT) gibi tek bir değişken parametrelili bir eğri grubu ile karakterize edilebileceğini göstermiştir. Şekil 2, Judd'un çalışmalarını esas alan CIE (Commission Internationale de l'Eclairage) standardına [9] göre çizilen üç spektrumu göstermektedir. Bu CCT'ler İngiltere Silsoe'de kaydedilmiş ve tek bir gün içinde oluşan değişim tipidir. En düşüğü "tam güneşin" altında kaydedilmiştir. Spektrumdaki kırmızılığın (daha uzun dalga boylarında) oldukça yüksek oranına dikkat ediniz. En yüksek değer, açık bir gökyüzünde, aydınlatmanın daha mavimsi ve gök ışığından olduğu ortamda gölgede ölçülmüştür. Gökyüzünün oldukça bulutlu olduğu ve güneşin bulut arkasında gizlendiği zaman orta değer ölçülmüştür. Denklem 1, ışık kaynağının spektrumları değiştikçe kamera çıktılarının (yani algılanan renklerin) değiştiğini göstermektedir. İnsan algılama sistemi, gerçekte farkında olmadığımız ve renk sabitliği olarak adlandırılan yeti (kabiliyet) yoluyla buna uyum sağlar. Ancak, yapay sistemler aydınlatma spektrumu değiştikçe değişen renkleri kaydetmektedir ve bu nedenle renk tabanlı herhangi bir tanıma sistemi bu değişimi hesaba katmalıdır. Bu, görüntüdeki standart yansımaya yüzeyi veya gökyüzünü gözleyen ayrı bir sensör kullanılarak yapılabilir. Ancak, uygulamada referansta alınan aydınlatma koşullarının, görüntüdeki bütün noktalarda aynı olmasını sağlamak zordur. Son zamanlarda yapılan çalışmalarda, ışık kaynağı gruplarının bilinen özelliklerinden yararlanarak, Marchant ve Onyango [10–12],

ayrıca referans ölçümleri yapmadan kameralarda ve multispektral sensörlerde gümüşü değişimlerinin nasıl giderileceğini göstermiştir.

Görüntü Yakalama

Makine görüşü için en yaygın yakalama aygıtı CCD kameradır. Bir mercekle gelen görüntüyü, genelde kare ızgara biçiminde düzenlenmiş bir dizi bağımsız hassas alanlara (pikseller) bölünmüş bir silikon dizi üzerine odaklamaktadır. Silikon sensörler, yakın kızılötesi (NIR) dalga bandını kısmen içeren yaklaşık 350–1000 nm aralığı içerisinde duyarlıdır. NIR bölgesinde bitki örtüsü yüksek derecede yansıtıcı olduğu için silikon sensörler tarımsal amaçlarla kullanılmaya başlamıştır. Ancak, bazı üreticiler kendi kameralarına kızılötesi engelleme filtresi koyduğu için kullanıcılar bu özelliği kullanırken dikkatli olmalıdır. Renkli kameraların, gözle görünür görüntünün kırmızı, yeşil, mavi alanlarında bilgi elde etmek için üç filtresi vardır. Bu filtreler sensörün parçası olabilir ve her bir piksel (tekli-CCD kamera) üzerine düzenlenebilir veya bir prizmayla gelen ışık bölünebilir ve her bir bileşen ayrı bir sensöre (3-CCD kamera) yönlendirilebilir. Bu en son bahsedilen kameralar genelde daha pahalıdır.

Yukarıda belirtildiği gibi, son zamanlara kadar birçok kamera standart TV çıktıları kullanmıştır. Modern cihazların ayrı pikselleri olmasına rağmen, TV standartları analog kameraların kullanıldığı zamanlarda oluşturulmuştur. TV standartlarına bağlı kalınması, görüntü sensöründen gelen çıktının analog sinyale dönüştürülmesini (konvansiyonel TV ekranları ile uyumlu olmak için) ve daha sonra bir bilgisayara giriş için yeniden örneklendirilmeyi gerektirir. Elektronik olarak karmaşık olmasının yanında bu yöntem, görüntü kalitesinde önemli kayıplara neden olmaktadır. TV standartlarından son zamanlarda büyük ölçüde vazgeçilmiştir ve bu yüzden modern sistemler daha yüksek transfer hızına sahip olabilir. Belirli görüntü sensör tipleriyle (örneğin, CMOS), dizi rastgele okunabilir. Daha iyi görüntü oranı için, görüş alanından bir miktar fedakarlık yapılabilir ve böylece daha küçük alanlar daha hızlı transfer edilebilir. Kameralarla bilgisayarlar arasındaki bağlantılarla ilgili teknoloji ve standartlar hızla değişmektedir ve bu değişim burada açıklanmaya çalışılmamıştır. Okuyucuların bilgi için literatüre ve çok sayıda bulunan imalatçıların web sitelerine başvurularını tavsiye edilir.

5.4.3 Görüntü Analizi


Nokta İşlemleri

Şekil 3 (a) görünür frekans bandını kullanarak monokrom (siyah-beyaz) kamera ile çekilen bir görüntüyü gösterir. Gri seviye histogramı (b) görüntünün gri seviyelerinin birinci derece istatistikleri olarak temsilidir. Ümit ettiğimiz şey, görüntünün bir parçasındaki piksellerin (bitki örtüsü olabilir) diğerinden (toprak) farklı istatistiklere sahip olmasıdır. Ancak böyle eşiklemeyle (*thresholding*) gri seviyesi esasına göre iki bileşeni bir birinden ayırt etmek mümkün olur. Yani, eşik değerin altında kalan gri seviyelerinin hepsi bir parça ve eşik değere eşit veya


üstünde olan gri seviyeler diğer parça olarak değerlendirilir. Histogram, ayrılmanın bu durumda gri seviye ile başarılamayacağını gösterir (renk kullanmak daha verimli olacaktır).

Nokta işlemleri, komşu pikselleri dikkate almadan pikselleri dönüştürme yollarıdır. Tek bir haritalama fonksiyonu kullanarak bir görüntüde verilen piksellerden bir diğerini oluşturmak için piksellerin haritalanmalarıdır. Yaygın bir nokta işlemi *histogram eşitlemesidir*. Histogram eşitlemesinde bütün gri değerlerin histogramda eşit olarak temsil edilecek şekilde, bir fonksiyonla gri seviyelere dönüştürülür. Genel olarak fonksiyon doğrusal değildir. Şekil 3(c)'de verilen görüntü böyle dönüştürülmüştür. Hangi nokta işleminin kullanıldığını fark etmek önemlidir, ayırım hala mümkün olmayacaktır. Bu yüzden (c)'deki görüntüyü bileşenlere ayırmak kolay görünmesine rağmen, makine görüşü sistemi sadece nokta işlemi bazında bunu hala başaramayacaktır. Gözlemci olarak insan farkında olmadan, bundan daha fazla bilgi kullanmaktadır.

Şekil 4(a) benzer görüntüdür ama NIR dalga bandını içeren bir görüntü sunmaktadır. Beklenildiği gibi kontrast daha iyi olmakta (Bölüm 5.4.2 bakılabilir) ve histogram bitki örtüsüne ve toprağa karşılık gelen iki net modu göstermektedir. İki mod arasında yapılan eşikleme (128 gri seviye değeri) ve yüksek değerlerin beyaza düşük değerlerin siyaha dönüştürülmesi Şekil 4(c)'de verilen ayrımı verir.



Şekil 3 (a) bitki ve toprağın tek renkli görüntüsünü. (b) Gri düzey histogram. (c) , (a)'nın histogram eşitlemeli görüntüsü.



Şekil 4.(a) Bitki örtüsü ve NIR' a genişleyen toprağın tek renkli görüntüsü. (b) Gri-düzey histogram. (c) eşiklenen görüntü.


Komşuluk İşlemleri

Diğer veri türlerinin aksine görüntülerin temel karakterini oluşturan büyük bir organizasyon olmasına rağmen nokta işlemleri, görüntünün alansal organizasyonunu dikkate almaz. Bu yüzden alansal ilişkiyi dikkate alan işlemlerin daha güçlü olması şaşırtıcı değildir. Bunlar genellikle bitişik olan görüntü öğeleri üzerinde çalışır, bu yüzden *komşuluk işlemleri* olarak adlandırılırlar.

Komşuluk işlemlerinin basit bir türü doğrusal filtredir ve en basit örnek ortalama ya da düşük geçiş filtresidir. Orijinal görüntüdeki her piksel karenin ortasında 3x3 piksel boyutu gibi oldukça küçük ve tek boyutlu olarak değerlendirilir (Komşuluklar; kare, tek boyutlu veya hatta dikdörtgen biçiminde olmak zorunda değildir; ancak bunlar genel olarak hesaplama kolaylığı içindir). Ortalama filtreyle, komşu piksellerin ortalama değeri, aynı konumda orijinal görüntüdeki merkez piksel olarak, yeni bir görüntüde piksel oluşturmak için kullanılır. Tüm ortalama işlemlerinde uygulandığı gibi, netlik kaybı pahasına bazı parazit türlerini azaltmak için kullanılabilir. Düşük geçirgen filtrenin tersi bitişik görüntü öğelerini farklılaştırarak faaliyet gösteren yüksek geçiren filtredir. Bunlar gri düzeydeki keskin değişikliklerle şekillenen keskin kenarları tespit etmek için kullanılır. Diğer sinyal işleme alanlarında olduğu gibi yüksek geçiren filtreleme paraziti artırır. Yapılan naif bir hareketle nesne sınırlarını basit bir kenar dedektörüyle görülebilir yapmak mümkündür.

Bazen, komşuluklar üzerindeki doğrusal olmayan işlemler daha iyi sonuç verir. Paraziti azaltmak için ortalayan filtre kullanımı yerine, medyan filtre kullanımı buna bir örnektir. Makul homojen gri seviyeli bir manzaranın belli bir alanını düşünün; ortaya çıkan görüntü biraz parazitli süreçten dolayı çok farklı gri düzeyli tek bir piksele sahip olabilir. Ortalama filtrenin çıktısı, bu aykırı pikselin bir oranını içerir. Ancak, medyan filtre, medyan değeri için bir çıktı pikselini oluşturur (3x3 semtindeki en geniş 5. gri seviye) ve böylece aykırı değerden etkilenmez.

Doğrusal olmayan komşu piksel operasyonlarının büyük ve güçlü olan sınıfı *morfolojik* yöntemlerdir [14]. Genel olarak, morfolojik yöntemler gri seviye (ve multiband) görüntülere doğru doğal olarak kapsama alanı genişler. Burada, küçük nesnelerin ikili (2 değerli) görüntüden kaldırıldığı yerin sadece özet nitelikteki bir örneği verilmiştir.



Şekil 5. (a) Şekil 4(c)'nin uygulanan erozyon operatörlü görüntüsü. (b) (a)'ya uygulanan genleşme oparetörü.

Şekil 5 (a), Şekil 4(c)'deki, 3x3 ikili *erozyon işlemcisinin* iki kere uygulanmasından sonraki görüntüyü göstermektedir. Bu operatör, eğer orjinal görüntüdeki komşu herhangi piksel '0' ise (orjinal görüntü piksel dâhil olmak üzere) mantıksal '0' olarak, eğer tersi durum varsa mantıksal '1' olarak pikseli ayarlar. Büyük bir imge (blob) bölgesi üzerindeki etki, dış görüntünün yüzeyden kaldırılmasıdır. Eğer bir imge bölgesi yeterince küçükse, etkisi yüzeyden tamamen kaldırılabilir. Erozyonun karşıtı *genleşmedir*: eğer komşuluktaki her hangi bir piksel mantıksal '1' ise, sonuç '1' i oluşturmaktır. Bu işlem 5(a)'ya 5(b)'yi oluşturmak için iki kere uygulanmıştır. Görülebileceği gibi, genleşme tarafından izlenen erozyon (açma olarak bilinen işlem) orjinal görüntüyü değiştirir ve biri diğerini tersine çevirmez. Özellikle, küçük imge bölgeler bir kere çıkarıldı mı tekrar büyümmez, aksine büyük olanlar yaklaşık olarak orijinal boyutuna geri dönerler. Ancak, bazı istenmeyen etkiler olabilir, örneğin, imge bölgelerinin bağlanmış parçaları bir birinden ayrı görünebilir. Hiç şüphe yok ki istenmeyen etkileri gidererek, arzu edilen etkileri korumak için bir algoritma geliştirmek mümkün olacaktır. Ancak, makine görüşündeki genel bir ders: algoritmaların bir görüntü ya da küçük bir küme için ayarlanmış olması ve diğerleri üzerinde çalışmaması gerçeğidir. Bu makine görüşünde başarısızlık yaşanan noktadır ve uygun algoritma test etmenin önemi üzerinde fazla durulmamalıdır [15].

Bölgeler

Görüntü analizinde önemli bir prosedür bağımsız pikselleri bölgelere gruplamadır. Bir *bölge*, piksel özelliklerinde bazı benzerliklerinin olduğu görüntü alanıdır. Yani bölgeler, tek bir bitki veya hayvan vücudu içeren anlamlı fiziksel varlıkların görüntüsüdür. Şekil 4 (c)'deki imge bölgeleri, bahsedilen bölgelerdir ve her biri gri düzeyleri eşik değerinin üzerinde olan özelliği paylaşır. Bu görüntüde bir birinden ayrı bitkiler daha koyu renkteki toprak ile çevrilir ve böylece her imge bölgesi genellikle tek bir bitkidir.

Birçok yolla her imge bölgesinin ölçüsünü bulmak mümkündür. Bütünsel bir veri temsilini sağlayan hızlı bir yöntem, *Freeman zinciri kodudur* [16]. Bir pikselden 3x3 ızgara içindeki herhangi komşusuna olan yön 0 ile 7 arasında bir etiket verilir. Bir imge bölgesi sınırı üzerinde ilk piksel bulduktan sonra diğer yönde olan bulunur ve etiket saklanır. Algoritma, başlangıç pikseli tekrar ziyaret edilinceye kadar sınır etrefında dolaşır ve böylece bütün doğrultu dizisini saklar. Sebze sınıflandırma konusundaki ilk çalışmalarda, donanım içerisinde bu algoritmalar geliştirilmiştir [17]; ama işlemci gücündeki büyük artış göz önüne alındığında, bir yazılım sürümü ile yeterli bir hız elde etmek artık mümkün olabilecektir.

Genellikle eşikleme gibi basit bir gruplama stratejisi yeterli değildir. *Bölge büyüme*; bir "tohum" pikselin, belirli bir bölgenin parçasını oluşturması gereken piksellerin özniteliklerinin istatistik modeli ile birlikte kullanıldığı süreçtir. Bu model, örneğin (GR)/(G+R) gibi piksel renklerinin bazı değerlerinin ortalama ve standart sapmalarının bir özel tanımlamasını içerebilir. Burada G ve R sırasıyla yeşil

(bitki örtüsü için daha yüksektir) ve kırmızı (toprak için daha yüksektir) renk kanal çıktılarıdır. Özel tanımlamalar önceki görüntülerden veya eğitim görüntülerinden elde edilebilir. Genel uygulama tekniği, model tarafından sunulan istatistiki popülasyona muhtemelen ait olan komşu pikselleri, sözkonusu bölgeye kabul ederek tohumdan bölgenin büyütülmesidir. Kullanılacak ilgili istatistiki teknik, t testi olabilir [18].

Yılanlar [19], bölge bulma tekniklerinin ilginç bir sınıfını oluştururlar. Onların çalışması, bölgenin sınırlarına yakın elastik bir dizi yerleştirilmesine benzemektedir ve bu dizi üzerinde etkin olan kuvvetler bu diziyi kenarlara doğru çekmektedir. Elastik dizi mekaniği yılan, sınır boşlukları üzerinde ve hatta küçük oklüzyonlar üzerinde köprü kurmasına müsaade eder. Elastik dizideki gerginlik bölgenin belirsiz şekilde büyümesini engeller. Onlar böylece belirli bir alanda elde edilen bazı sorunların üstesinden gelebilir (bölüm 5.4.1 bakılabilir) ve tarımsal bağlam olarak kullanılmıştır [20]. Ancak, yılanın mekanik özelliklerini seçme ve başlangıç pozisyonunu bulmak zor olabilir. Bölge büyütmenin ve yılanların avantajları, dış mekân manzaraları üzerinde Alexander ve Buxton tarafından bir araya getirilmiştir [21].

Özellikler ve Sınıflandırma

Makine görüşünün büyük bir kısmı, görüntülerden özellikleri ayıklama ve bileşenleri sınıflandırma ile ilgilidir. Örneğin tarımsal bir sorun, renkli bir görüntüyü bitki örtüsü ve toprak olarak sınıflandırma konusunu ve daha sonra bitki görüntüsünü ise kültür bitkisi ve yabancı ot olarak sınıflandırma konusunu içerebilir. Bariz bir başlangıç noktası bitki ve toprak arasındaki renk farklılıklarını kullanmak olabilir [22] ve daha sonra kültür bitkileri ve yabancı otların arasında ayırım yapmak için bir birinden ayrı imgeler üzerinde bir şekil analizi kullanmaktır [22-24]. Başlangıç noktası olarak, buradaki mantığımız imge bölgelerinin bütün bir yaprak gibi karakteristik bitki bölümlerine denk olduğunu varsaymaktır. Bu durum pratikte yapraklar ve yaprak parçaları tek bir imgede birbirine karışması veya tek bir yaprağın birçok imge içinde parçalara ayrılması durumu olmayacaktır. Tek tek anlamlı görüntü parçaları bulmak (*segmentasyon*) gerçek manzaralar üzerinde çalışırken çok zordur.

Sınıflandırma farklı düzeylerde yapılabilir. Sınıflandırmanın üzerindeki bitki örtüsü ve toprak sorunları $(G-R) / (G+R)$ oranını temel alan bağımsız pikseller üzerinde çözülebilir. Bu oranın histogramı çift durumlu (bimodal) olmalıdır (örn, [22]), iki tepe arasındaki vadi otomatik olarak tespit edilebilir ve bu iki bileşen eşikleme ile sınıflandırılır. Bu örnek, *denetimsiz sınıflandırma* için bir örnek olabilir. Buna alternatif olarak, *denetimsiz sınıflandırma*, sınıf örneklerinin sisteme tanıtılmasını gerektirmektedir. Sonrasında, istatistiksel modeller türetilir. Bilinmeyen bir piksel, piksel özelliklerinin herbir sınıfın istatistik değerlerine yakınlığına bağlı olarak bir kategoriye atanabilir. Denetimli sınıflandırma yöntemleri

arasında Bayesian yöntemleri, bazı sinir ağıları yaklaşımları ve en yakın komşu tekniklerini [25] içermektedir. Yukarıdaki örnekte, renk oranı kullanılarak her bir piksel kendisiyle ilişkili tek bir özellik veya ölçüme sahiptir. Sınıflandırma teknikleri doğal olarak birden fazla özelliği kapsayabilir bu sayede genellikle daha iyi ayırt edilebilir. İmge bölgeleri üzerinde daha yüksek seviyede bir sınıflandırma yapılabilir. Örneğin, her bir imge bölgesinden çeşitli boyut ve şekil ölçümleri elde edilebilir ve daha sonra bu ölçüler imge bölgelerini nesne tiplerine ayırmak için çok özellikli sınıflandırıcı ile kullanılır.

Bu bölümde sıkça belirtildiği gibi, tarımda makine görüşü oldukça zordur. İnsan akıl etkinliğini taklit etmek mümkün olabilir umuduyla birçok araştırmacı yapay zekâ tekniklerine başvurmuştur. Bu konuyla ilgili örnekler; ayırma ve sınıflandırma [26-29], bitki tayini [23,30,31], bitki yapısı tanımlama [32] ve atıştırılabilir gıdaların kalitesini [33] içermektedir. Bir umut vadetmesine rağmen birçok yapay zeka (AI, Artificial Intelligence) tekniğinin istenmeyen bir yönü, bir dizi parametrenin sınırlı sayıdaki (eğer varsa) seçimi yöneten kurallarla seçilmek zorunda olmasıdır. Sinir ağılarıyla ilgili bir örnek olarak, ağ yapısının sıkı kurallarla tanımlanamaması gösterilebilir. Fakat başka bir yaklaşım, çeşitli sensörlerden gelen verinin ve yöntemlerin akıllı bir yolla birleştirildiği en iyi cevabın, tek bir tekniğin veya ölçümün sağlayamayacağını farz etmektir [34,35].

Model Tabanlı Teknikler

Veri içerisindeki belirli paternleri ararken, beklentilerimizle ilgili bilgiler çoğu zaman faydalıdır. Bu durumdan yukarıda bölge büyütmeyle ilgili istatistiksel modeller bağlamında kısaca bahsedildi. Burada biz, görüntüdeki piksellerin doğrudan alansal düzenlemesiyle ilgili önceki bilgileri kullanmayı dikkate alırız. Bu çalışma, nesnelerin şekillerini ve bu nesneler içerisindeki desenler için modelleri içermektedir.

Doğal nesnelerin makine görüşüne ait naif bir yaklaşım, bir şablonun oluşumunu içerebilir. Bu, bir görüntünün belirli bir kesitinden elde edilen gri düzeylerin (veya renklerin) özel bir düzenlemesi olabilirdi. Örneğin, tek bir ot yaprağı için farklı gri seviyeler saklanabilir. Başka bir örnek verecek olursak, görüntüde (belirli bir toleransla) şablona uyan bölümler araştırılabilir. Gerçek bir durumda bu, 5.4.1. bölümdeki bahsedilen doğal değişkenlikten dolayı neredeyse kesin başarısız olmaktadır. Hedef alan, gri seviyeler açısından tamamen farklı bir yapıya sahip ve hala yabancı ot yaprağı olabilir. Bizim çalışma alanımızda, sabit şablonlar için yer yok gibi görünebilir. Ancak, en azından iki bölgede yararlı olabilirler: *hareket tahmini* ve *3D nirengidir*. Hareket, bir dizinin ardışık çerçevelerindeki görüntü özellikleri arasındaki farklardan ölçülebilir. Eğer çerçeveler arasındaki görünür hareket küçük olsun diye çerçeveler arasındaki zaman farkı kısa olursa bağımsız alanların görünümü çok farklı olmayacaktır. Bir görüntünün küçük alanına ait şablon, bir sonraki karşılık gelen alana eşleştirilebilir. Sıklıkla beklenen

hareketin bilgisi, eşleşmenin arandığı küçük bir alanı tanımlamak için (ümit edilirdi) kullanılabilir. Alt piksel çözünürlüğünde eşleşmenin konumu hakkında ek bilgi verebilen (faz yoluyla) bir Fourier yaklaşımı [37] dikkate değer olmasına rağmen, eşleşmenin derecesi normalleştirilmiş çapraz korelasyon kullanılarak ölçülebilir. Buna çok benzer bir şekilde, şablonlar stereo nirengileme için iki görüntüdeki özelliği eşleştirmek için kullanılabilir.

Şekli ve görünümünü değiştirebilen bir şablon, potansiyel olarak biyolojik nesnelere görüntü analizlerinde önceki bilgilerin kullanılma avantajlarını sağlayabilir. Bu avantajlar arasında, nesne örtüşmesiyle doğabilecek veya bir birinden ayrı olmayan bölgelerde olabilecek veya arkaplan karışıklığından doğabilecek ilgili görüntü verilerindeki boşluklar üzerinde köprü kurabilmek olabilir. Esnek bir şablon fikri ilk Widrow [38] tarafından tanıtılmış ve genel yöntem ilk olarak Yuille ve ark. tarafından biyolojik nesnelere (insan yüzleri) uygulanmıştır [39]. Anılan ikinci çalışmada, gözlerde olduğu gibi şablonları belirli özelliklere uyarlamak için elle işlenmiştir. Bitki tanımlanması için de benzer bir fikir Manh ve ark. tarafından kullanılmıştır [40]. İlginç bir yaklaşım sadece beklenen şekli değil, aynı zamanda şeklin değişebildiği ana yolları kapsamaktır. Bu çalışma, Cootes ve ark. tarafından *nokta dağıtım modeli (PDM, Point Distribution Model)* olarak adlandırılmıştır [41]. Nesne sınır çevresindeki yerlerin pozisyonları, çeşitli eğitim görüntüleri içerisinde elle tanımlanır. Sonrasında temel bileşen analizi, şekil değişimi modlarını belirlemek için yapılır. Yöntem genellikle, birkaç mod içindeki değişkenliği sunar. Son zamanlarda, modelleri görüntü verisine daha çabuk uydurabilecek bir metot içerisinde, yüzey görünümü dahil edilmiştir [42]. Temel fikir domuzları izlemek için [43] ve balık kitlesini tahmin etmek için kullanılmıştır [44]. Ancak, aynı yılan yaklaşımında olduğu gibi bu modellerin uyarlanması, başlatmayla ilgili sorunlara yol açacaktır.

Model tabanlı yöntemin farklı bir tipi, görüntülerdeki çizgiler ve daireler gibi soyutlamaları ararken kullanılabilen *Hough dönüşümüdür*. Örneğin, düz bir çizgi için şu genel denklem dikkate alınır:

$$y = mx + c \quad (2)$$

Şimdi bir görüntü özelliğinin konumunun tespit edildiğini düşünün. Bunun, Şekil 4 (c)' deki lekelerden/ime bölgelerinden birinin ağırlık merkezi (x_f , y_f) olabileceğini farz edelim. Hipotez, bu özelliğin bir çizgi üzerinde bulunmasıdır. Bu hipotez doğru ise, o zaman Denklem 2'den elde edilen çizgi üzerindeki m ve c parametreleri arasında aşağıdaki gibi bir ilişki olmalıdır:

$$m = \frac{y_f - c}{x_f} \quad (3)$$

Parametre uzayı öyle ayrıklaştırılır ki her hangi bir (m, c) çifti değerleri uzaydaki hücre ile temsil edilir. İki boyutlu bir toplayıcı artık kurulmuş ve Denklem 3 ile temsil edilen tüm hücreler arttırılır. Toplayıcı, (xf, yf) içinden geçen olası tüm çizgilerin bir temsilidir. Eğer başka bir özelliğe aynı şekilde muamele edilirse, o zaman ikinci bir hücre kümesi arttırılır. Bu hücrelerin birisi, her iki işlem ile arttırılır ve aslında, özelliklerini birleştiren çizgi parametrelerini temsil eder. Daha fazla özellik değerleri toplayıcıya yüklendikçe en çok biriktiren hücreler, birçok özelliğin toplandığı çizgileri temsil edecektir. Tüm özellikler yüklendikten sonra toplayıcı, görüntüde belirgin çizgileri temsil eden yüksek değerler için araştırılabilir. Yöntem, kayıp verilere karşı dirençli (orijinal görüntüdeki çizgilerin eksik parçaları) ve sahte verilere karşı toleranslıdır (çizgilerde olmayan özellikler). Bu yüzden, uygulamamızda bulunan zor görüntülere karşı kullanışlı bir metottur. Bu metot, parametrik olarak temsil edilebilen, örneğin daire ve elips gibi başka tür soyutlamalara [2] genişletilebilir. Toplayıcıları etkin şekilde arama ve yükleme teknikleri üzerinde yapılmış birçok çalışma vardır. Tarım açısından bu teknik, Şekil 4 (c)'deki [45] görüntülerde olduğu gibi sıra üzeri bitki konumunun bulunması için kullanılmıştır. Bir otonom aracın kamerasının gördüğü şekilde üç paralel bitki sırasının bozumu için bir model geliştirilmiştir. Bu modelin parametreleri, aracın sapması ve yön açısidir. Aynı anda üç sıra kullanıldığında, bu metot eksik bitkileri ya da tüm eksik sıraları tespit etmede başarılıdır.

5.4.4 Sonuçlar

Makine görüşü ziraat mühendisliği için birçok avantajı olan bir teknolojidir. Neyse ki, sistem bileşenlerinin maliyetlerini aşağı çeken teknolojik ve sosyal faktörler bulunmaktadır. Aynı zamanda, bilgisayar sistemlerinin yetenekleri de artmaya devam etmektedir. Bu faktörler, önümüzdeki engelleri kaldırma eğiliminde olacaktır. Fakat görsel algılama ve yorumlama konusundaki insan yeteneğinin bu yapay sistemleri geride bıraktığı akılda tutulmalıdır. Bize kolay görünen şeyin makine görüşünce taklit edilmesi son derece zor olabilir. Böylece, güvenli bir şekilde uygulamadaki problemleri çözecek sistemlerin geliştirilmesi için mühendislerin yeteneklerini ve yaratıcılıklarını kullanabilecekleri büyük bir alan vardır.

Kaynaklar

1. Devijver, P. A., and J. Kittler. 1982. *Pattern Recognition*. London, UK: Prentice-Hall.
2. Davies, E. R. 1997. *Machine Vision*, 2nd ed. London, UK: Academic Press.
3. Klinker, G. J. 1993. *A Physical Approach to Color Image Understanding*. Wellesley, MA: A. K. Peters Ltd.
4. Healey, G. E., S. A. Shafer, and L. B. Wolff, eds. 1992. *Physics-Based Vision: Principles and Practice*. Boston, MA: Jones and Bartlett.
5. Pla, F., F. Juste, F. Ferri, and M. Vicens. 1993. Colour segmentation based on a light reflection model to locate citrus fruits for robotic harvesting. *Computers and Electronics in Agriculture* 9: 53-70.

6. Andersen, H. J., C. M. Onyango, and J. A. Marchant. 2000. Design and operation of an imaging sensor for detecting vegetation. *Int. J. Imaging Systems and Tech.* 11: 144-151.
7. Shafer, S. A. 1985. Using color to separate reflection components. *Color Research and Application* 10: 210-218.
8. Judd, D. B., D. L. MacAdam, and G. W. Wyszecki. 1964. Spectral distribution of typical daylight as a function of correlated color temperature. *J. Opt. Soc. Am.* 54: 1031-1040.
9. Commission Internationale de l'Eclairage (CIE). 1986. *Colorimetry*. Tech. Rep. 2nd ed. Paris, France: CIE.
10. Marchant, J. A., and C. M. Onyango. 2000. Shadow-invariant classification for scenes illuminated by daylight. *J. Opt. Soc. Am. A.* 17: 1952-1961.
11. Marchant, J. A., and C. M. Onyango. 2001. Color invariant for daylight changes: Relaxing the constraints on illuminants. *J. Opt. Soc. Am. A.* 18: 2704-2706.
12. Marchant, J. A., and C. M. Onyango. 2002. Spectral invariance under daylight illumination changes. *J. Opt. Soc. Am. A.* 19: 840-848.
13. Walter-Shea, E., and J. Norman. 1991. Leaf optical properties. *Photon- Vegetation Interactions*, eds. R. B. Myneni, and J. Ross, 230-250. New York, NY: Springer-Verlag.
14. Soille, P. 1999. *Morphological Image Analysis*. Berlin, Germany: Springer-Verlag.
15. Haralick, R. M. 1992. Performance characterization in computer vision. *BMVC92*, eds. D. Hogg, and R. Boyle, 1-8. London, UK: Springer-Verlag.
16. Freeman, H. 1961. On the encoding of arbitrary geometric configurations. *IEEE Trans. Electronics and Computing* 10: 260-268.
17. Onyango, C. M., and J. A. Marchant. 1994. Transputers for high speed grading. *Food Control* 5: 29-32.
18. Snedecor, G. W., and W. G. Cochran. 1989. *Statistical Methods*, 8th ed. Ames, IA: State University Press.
19. Kass, M., A. Witkin, and D. Terzopoulos. 1987. Snakes: Active contour models. *Int. J. Computer Vision* 1: 321-331.
20. Marchant, J. A., and C. P. Schofield. 1993. Extending the snake image processing algorithm for outlining pigs in scenes. *Computers and Electronics in Agriculture* 8: 261-275.
21. Alexander, D. C., and B. F. Buxton. 1996. An evaluation of physically based statistical colour models for image region characterisation. *Proc. of the International Conference on Image Processing*, ed. P. Delogne, 1023-1026. New York, NY: IEEE.
22. Perez, A. J., F. Lopez, J. V. Benlloch, and S. Christensen. 2000. Colour and shape analysis techniques for weed detection in cereal fields. *Computers and Electronics in Agriculture* 25: 197-212.
23. Oide, M., and S. Ninomiya. 2000. Discrimination of soybean leaflet shape by neural networks with image input. *Computers and Electronics in Agriculture* 29: 59-72.
24. Molto, E., N. Aleixos, L. A. Ruiz, J. Vazquez, F. Fabado, and F. Juste. 1998. Determination of weeds and artichoke plants position in colour images for local herbicide action. *Acta Horticulturae* 421: 279-283.
25. Ripley, B. D. 1996. *Pattern Recognition and Neural Networks*. Cambridge, UK: Cambridge University Press.
26. Shahin, M. A., E. W. Tollner, and R. W. McClendon. 2001. Artificial intelligence classifiers for sorting apples based on watercore. *J. Agricultural Engineering Research* 79: 265-274.
27. Jahns, G., H. M. Nielsen, and W. Paul. 2001. Measuring image analysis attributes and modelling fuzzy consumer aspects for tomato quality grading. *Computers and Electronics in Agriculture* 31: 17-29.

28. Kondo, N., U. Ahmad, M. Monta, and H. Murase. 2000. Machine vision based quality evaluation of Iyokan orange fruit using neural networks. *Computers and Electronics in Agriculture* 29: 135-147.
29. Morimoto, T., T. Takeuchi, H. Miyata, and Y. Hashimoto. 2000. Pattern recognition of fruit shape based on the concept of chaos and neural networks. *Computers and Electronics in Agriculture* 26: 171-186.
30. Tang, L., L. Tian, and B. L. Steward. 2000. Color image segmentation with genetic algorithm for in-field weed sensing. *Trans. ASAE* 43: 1019-1027.
31. Burks, T. F., S. A. Shearer, R. S. Gates, and K. D. Donohue. 2000. Backpropagation neural network design and evaluation for classifying weed species using color image analysis. *Trans. ASAE* 43: 1029-1037.
32. McFarlane, N. J. B., B. Tisseyre, C. Sinfort, R. D. Tillett, and F. Sevilla. 1997. Image analysis for pruning of long wood grape vines. *J. Agricultural Engineering Research* 66: 111-119.
33. Sayeed, M. S., A. D. Whittaker, and N. D. Kehtarnavaz. 1995. Snack quality evaluation method based on image features and neural-network prediction. *Trans. ASAE* 38: 1239-1245.
34. Ozer, N., B. A. Engel, and J. E. Simon. 1995. Fusion classification techniques for fruit quality. *Trans. ASAE* 38: 1927-1934.
35. Ros, F., S. Guillaume, G. Rabatel, F. Sevilla, and D. Bertrand.. 1997. Combining global and individual image features to characterize granular product populations. *J. Chemometrics* 11: 483-500.
36. Rosenfeld, A., and A. C. Kak. 1982. *Digital Picture Processing*, 2nd ed., Vol. II. Orlando, FL: Academic Press.
37. Gonzalez, R. C., and R. E. Woods. 1992. *Digital Image Processing*. Reading, MA: Addison Wesley.
38. Widrow, B. 1973. The "rubber mask" technique. *Pattern Recognition* 5: 175-211.
39. Yuille, A. L., P. W. Hallinan, and D. S. Cohen. 1992. Feature extraction from faces using deformable templates. *IEEE International Journal of Computer Vision* 8: 99-111.
40. Manh, A. G., G. Rabatel, L. Assemat, and M. J. Aldon. 2001. Weed leaf segmentation by deformable templates. *J. Agricultural Engineering Research* 80: 989-996.
41. Cootes, T. F., C. J. Taylor, D. H. Cooper, and J. Graham. 1992. Training models of shape from sets of examples. *BMVC92*, eds. D. Hogg, and R. Boyle, 9-18. London, UK: Springer-Verlag.
42. Cootes, T. F., G. J. Edwards, and C. J. Taylor. 2001. Active appearance models. *IEEE Trans. Pattern Analysis and Machine Intelligence* 23: 681-685.
43. Tillett, R. D., C. M. Onyango, and J. A. Marchant. 1997. Using model based image processing to track animal movements. *Computers and Electronics in Agriculture* 17: 249-261.
44. Lines, J. A., R. D. Tillett, L. G. Ross, D. Chan, S. Hockaday, and N. J. B. McFarlane. 2001. An automatic image-based system for estimating the mass of free-swimming fish. *Computers and Electronics in Agriculture* 32: 151-168.
45. Marchant, J. A., and R. Brivot. 1995. Real time tracking of plant rows using a Hough transform. *Real Time Imaging* 1: 363-371.