

**Sınır Sahipliđi İle
Görüntülerden Hassas Görsel Bilgi Edinimi**

Program Kodu: 3501

Proje No: 111E155

Proje Yürütücüsü:

Yrd. Doç. Dr. Sinan Kalkan

Danışman(lar):

Özge Öztimur Karadağ

Bursiyerler:

Alper Karamanlıođlu

Buğra Özkan

Gaye Topuz

Hacer Nihal Tarkan

Mehmet Akif Akkuş

Eylül 2015

ANKARA

ÖNSÖZ

Görme, doğası gereği, 2B görüntülerden muğlak ve eksik bilgiyi işleyerek 3B dünya hakkında çıkarımlar yapmak durumunda olan bir problemdir. Bu zorlu problemin çözümü için en önemli araçlardan bir tanesi ise, sınır sahipliği bilgisidir; sınır sahipliği bilgisi sayesinde hem kenarlardaki eminliği yüksek bilgi eksik ve muğlak bilgi içeren iç alanlara aktarılabilen, hem de derinlik kestirimi gibi problemlerde alanlar arası ayırım sağlanabilmektedir.

Proje yürütücüsü, 2008'de tamamlanan doktora öğrenimi sırasında derinlik kestirimi üzerine çalışırken sınır sahipliği bilgisinin farklı görme problemleri için ne kadar gerekli olduğunun ayırıcısına varmış, ve yaptığı literatür taraması sonucunda, insan görme sisteminde de bu problemin çözüldüğü ve çözümünün kullanıldığını ama yapay görme sistemlerinde o zamanlar bu probleme odaklanmış henüz başarılı çalışmalar olmadığını keşfetmiştir.

Proje yürütücüsünün bu keşif esnasında farketdiği eksiklikler üzerine çalışmak, ancak 2012 yılından itibaren bu proje ile mümkün olmuştur. Bu projede, sınır sahipliği problemi kapsamlı bir biçimde çalışılmıştır. Projede, sınır sahipliği için geniş bir veriseti oluşturulmuş, bu veriseti Bilgisayarlı Görü üzerine çalışan araştırmacılar ile paylaşılmış, veriseti üzerinden sınır sahipliği ipuçlarını incelenmiş ve sınır sahipliği kestirimi problemini çalışılmıştır. Ayrıca, sınır sahipliği bilgisi ile optik akış ve stereo ayrıklık gibi görsel ipuçlarını iyileştirilebildiği gösterilmiştir.

Bu proje, Türkiye Bilimsel ve Teknolojik Araştırmalar Kurumu (TÜBİTAK) tarafından desteklenen 111E155 numaralı fon ile desteklenmiştir.

Sinan Kalkan

Ankara, 2015

İÇİNDEKİLER

1. GİRİŞ	1
1.1 Optik Akış ve Stereo Hesaplama.....	2
1.2 Eşleştirme Problemi ve İçeriye Doldurmanın Önemi.....	3
1.3 Projenin Kapsamı ve Katkıları	4
1.3.1 Sınır Sahipliği Veriseti Oluşturma (ÇP1).....	4
1.3.2 Sınır Sahipliği İpuçlarını İnceleme (ÇP2).....	5
1.3.3 Sınır Sahipliği Kestirimi İçin Bilişimsel Yöntemler (ÇP3).....	5
1.3.4 Sınır Sahipliği Bilgisinin Kullanımı (ÇP4).....	5
1.4 Projenin Yayın Çıktıları.....	6
1.4.1 Dergi Yayınları	6
1.4.2 Ulusal Bildiri	6
1.4.3 Öğrenci Tezleri.....	6
1.5 Raporun Krokisi.....	7
2. LİTERATÜR ÖZETİ.....	8
2.1 Sınır Sahipliği ve Şekil-Arkaplan Ayrımı	8
2.2 Sinirbilimde Sınır Sahipliği.....	8
2.3 Psikolojide Sınır Sahipliği	9
2.4 Bilişimsel Sınır Sahipliği Çalışmaları	10
2.5 Değerlendirme.....	12
3. VERİ SETİ TOPLAMA.....	13
3.1 Görüntüler	13

3.2	Katılımcılar	15
3.3	Veri Toplama.....	15
3.4	Prosedür	15
3.5	Tutarlılık İncelemesi	17
4.	GÖRSEL İPUÇLARI VE İNCELENMESİ	18
4.1	Görsel İpuçları.....	18
4.1.1	Eğrilik	18
4.1.2	Alt-alan.....	19
4.1.3	T ve L köşeleri.....	19
4.1.4	Kontrast.....	20
4.1.5	Entropi	20
4.2	Görsel İpuçlarının Analizleri.....	21
4.3	Görsel ipuçlarının sınır sahipliği konusunda zıtlaşması	23
5.	TEKRARLAMALI VEKTÖR OYLAMA YÖNTEMİ İLE SINIR SAHİPLİĞİ KESTİRİMİ	24
5.1	Tensör Oylama.....	24
5.2	Tekrarlamalı Vektör Oylama.....	25
5.3	Deneyler ve Sonuçlar	27
6.	ŞARTLI RASTGELE ALAN İLE SINIR SAHİPLİĞİ KESTİRİMİ	29
6.1	Yöntem.....	29
6.2	Deneyler ve Sonuçlar	32
7.	LİTERATÜRDEKİ BİLİŞİMSEL YÖNTEMLERİN KIYASLANMASI	34
7.1	Kıyaslanan Yöntemler	34
7.1.1	Naif İpucu Birleştirme	34

7.1.2	Zıtlık Çevre Modülasyonu.....	34
7.1.3	Şekilcikler Üzerinde Şartlı Rastgele Alan.....	36
7.1.4	Görsel İpuçları Üzerinde Şartlı Rasgele Alan	37
7.1.5	Spektral Öznitelikler Üzerinden Destek Karar Makineleri.....	37
7.1.6	Öznitelikler Üzerinden AdaBoost Yöntemi	38
7.2	Deneyle ve Sonuçlar	39
7.2.1	Yöntemlerin En İyilenmesi.....	39
7.2.2	Yöntemlerin Kıyaslanması.....	43
8.	SINIR SAHİPLİĞİNİ KULLANARAK GÖRSEL BİLGİYİ İYİLEŞTİRME	44
8.1	Yayınım teknikleri ile kenarlardaki stereo ve optik akış bilgisinin ilgili alana aktarılması	44
8.2	Markov Rastgele Alan (MRA) yöntemi ile bölütleme ve sınır sahipliği kestirimini beraber çözme.....	45
8.2.1	Deneyle ve Sonuçlar	47
8.3	Derinlik Kestirimini İyileştirme.....	48
8.3.1	Yöntem	48
8.3.2	Sonuçlar.....	49
8.4	Markov Rastgele Alan ile Stereo Bilgisinin İyileştirilmesi	51
8.4.1	Yöntem	51
8.4.2	Sonuçlar.....	51
8.5	Markov Rastgele Alan ile Optik Akış Bilgisinin İyileştirilmesi.....	52
8.5.1	Yöntem	52
8.5.2	Sonuçlar.....	53

8.6	İyileştirmelerin Genel Değerlendirmesi	54
9.	SONUÇ	55
9.1	Projenin Bilimsel Sonuçları.....	55
9.2	Projenin Etkisi	55
9.3	Projenin Geleceği.....	56
10.	KAYNAKÇA.....	57

TABLO LİSTESİ

Tablo 1. Tutarlılık sonuçları (%).	17
Tablo 2. Farklı görsel ipuçlarının sınır sahipliğini tahmin etme gücü. “1/3 set”: 3 denekten sadece birisinin işaretlediği alanı doğru aldığımız işaretlemeler. “2/3 set”: Üç denekten ikisinin işaretlediğini doğru kabul ettiğimiz işaretlemeler. “3/3 set”: Tüm 3 deneğin de aynı yönü işaretlediği sınırlar.....	21
Tablo 3. Farklı görsel ipuçları üzerinden yapılan tekrarlamalı vektör oylama yöntemimizin sonuçları. Tekrar edildikçe doğruluk bir yere kadar artmakta, sonra düşmektedir. İdeal tekrarlamalı sayısının 3 olması gerektiği gözlemlenmektedir.	27
Tablo 4. ŞRA yöntemi ile elden edilen iç-alan ve dış-alan başarımlarının yüzdeleri.	32
Tablo 5. Yöntemlerin iç-alan ve dış-alan başarımları.	43
Tablo 6. MRA ile Bölütleme, <i>MRABSS</i> temel ve <i>MRABSS</i> gelişmiş yöntemlerinin ROI (Rand Olasılık İndeksi), KTH (Küresel Tutarlılık Hatası) ve Bölütleme Derecesi ölçütlerine göre bölütleme performanslarının karşılaştırılması	48
Tablo 7. Stereo ayırım kestiriminin sınır sahipliği eklendiğinde elde edilen sonuçlar (K: Kazanım, SS: Sınır Sahipliği).	52
Tablo 8. MRA yöntemi kullanarak optik akış kestiriminin sınır sahipliği eklendiğinde elde edilen sonuçlar (K: Kazanım).....	53

ŞEKİL LİSTESİ

- Şekil 1:** Eşleştirme problemi. Optik akış ve stereo, bir sahnenin iki farklı görüntüsü içindeki her pikseli eşleştirmeyi gerektirir. Ancak bu eşleştirmeyi elde etmek, tekdüze görüntü alanlarında mümkün olmayabilir.1
- Şekil 2:** Bir stereo kameradan alınan sol ve sağ kamera görüntüleri (a) ve bu görüntülerden iki farklı yöntem ile (solda: dinamik programlama (Scharstein ve Szeliski, 2002), sağda: faz-tabanlı bir yöntem (Sabatini vd., 2007)) elde edilen eksik ve muğlak stereo bilgisi.....2
- Şekil 3:** Sınır sahipliği, özellikle birden fazla alan tarafından paylaşılan görüntü alanları alanlarından hangisinin bir kenarın sahibi olduğunu belirtir. (a) ve (b) örnek çizimlerinde, kırmızı renk ile işaretlenmiş kenarların sahipliği bilgisi, o kenarın hangi alanın görsel bilgilerini hesaplamakta kullanılacağı konusunda önemlidir.....3
- Şekil 4:** (A) alt alan ve (B) konvekslik ipuçları, şekil-alan ayrımı için önemli ipuçlarıdır. (Vecera, vd., (2002)'dan izin ile uyarlanmıştır.).....9
- Şekil 5:** (A) T-köşeleri, oklüzyon bölgeleri için belirgin bir ipucudur. (B) L-köşesi, bir şeklin köşesi olarak algılanmakta ve bu nedenle, kenarların köşeyi oluşturan alana ait olduğu algılanmaktadır. (Layton, vd., (2012)'den uyarlanmıştır.).....10
- Şekil 6.** Berkeley Bölümlendirme Veritabanından (İng. Berkeley Segmentation Database) örnek bir fotoğraf ve bölümlendirmesi. (a) Fotoğraf. (b-c) İki farklı denek tarafından elle yapılmış bölümlendirme.....13
- Şekil 7.** Bir imgedeki farklı sınırlar. Katılımcılar beyaz sınırın iki alandan hangisine (kırmızı ya da mavi) ait olduğunu işaretlediler (En iyi renkli görünür).....14
- Şekil 8.** Sınır sahipliği işaretleme sayfasından bir görüntü. İmgeler kullanıcı dostu bir arayüz ile sunuldu. İmgelerdeki her bir sınır en az üç katılımcı tarafından işaretlendi. (Renkli örneğe bakınız)15
- Şekil 9.** Web-tabanlı işaretleme programındaki alıştırmaya sayfasından bir görüntü. Katılımcıları sınır sahipliği işaretleme prosedürüne alıştırmak için her bir işaretlemeden sonra 'doğru' ve 'yanlış' olmak üzere geribildirim verildi.16
- Şekil 10.** İç-alan ve dış-alan görüntülerindeki tutarlılık (3 deneğin de aynı yönü işaretlemesi durumu) yaşa (a) ve cinsiyete (b) göre çizilmiştir.17

Şekil 11. Eğriliğin tanımı ve sınır sahipliğine etkisi.	19
Şekil 12. T köşelerinin (a) ve L köşelerinin (b) taşıdığı sınır sahipliği bilgisi. Sol: Bir iç-alan görüntüsü. Orta: Bir dış-alan görüntüsü. Sağ: Bir köşenin hangi yönünün sınıra sahip olduğu bilgisi.	20
Şekil 13. İpuçlarının birleştirilmesinin sınır sahipliği tahminine etkisi. (a) İç-alan görüntüleri için, (b) dış-alan görüntüleri için.....	22
Şekil 14. Görsel ipuçlarının birbiri ile ne kadar zıtlaştığı. (a) Zıtlama matrisindeki rakamların anlamı. (b) İç-alan, (b) dış-alan görüntülerinde ipuçlarının nasıl zıtlaştığını gösteren zıtlama matrisi.	23
Şekil 15. Tensör türleri ve geometrik temsilleri.....	24
Şekil 16. Tekrarlamalı Vektör Oylama yöntemimizin genel hatları.	25
Şekil 17. Sol: Bir kenar üzerinden bir kesit ve kenarın ayırdığı alanların ortalama parlaklık değerleri. Sağ: Bu kenarın sahibi konusundaki oyunu ve şiddetini belirten vektör.....	26
Şekil 18. Sol: Tensör oylama yöntemindeki tensör oylama alanı. Merkezden uzaklaştıkça, oylamaların birbiri üzerine olan etkisi azalır. Sağ: Önerdiğimiz tekrarlamalı vektör oylama yöntemi için oluşan oylama alanı. Oylama uzaklıkla azalmaz ve aynı yöndeki oylar birbirinin etkisini artırır.....	26
Şekil 19. Örnek bir görüntü üzerinden ara aşamaların gösterimi. (a) Girdi görüntü. (b) Görüntünün kenarları. (c) Görüntüden çıkan kontrast ipucu haritası. (d-e) Kontrasta göre oyların birleştirilmesi. (f) Sınır sahipliği tahmini (yeşil: doğru, kırmızı: yanlış).	27
Şekil 20. Örnek görüntüler için yapılan sınır sahipliği tahminleri. Yeşil: doğru tahminler. Kırmızı: Yanlış tahminler.	28
Şekil 21. T ve L köşeleri hakkında görsel bilgi.....	31
Şekil 22. T ve L köşeleri örnek sonucu.....	31
Şekil 23. ŞRA yönteminin örnek çıktısı. Kırmızı yanlış, yeşil doğru sınır sahipliği tespitlerini göstermektedir.	32
Şekil 24. Şekilciklerden bir kısmının görsel gösterimi. Kaynak: Ren vd. (2006).	37

Şekil 25. Chen vd. (2013) tarafından kullanılan semantik bilgiler.	38
Şekil 26. AdaBoost sınıflandırıcı.	38
Şekil 27. Spektral Öznitelikler üzerinden Karar Destek Makineleri yönteminde pencere ebatının performansa etkisi.	39
Şekil 28. Zıtlık Çevre Modülasyonu yönteminde Gabor filtresinin kullandığı eğilim sayısının etkisi.	40
Şekil 29. Zıtlık Çevre Modülasyonu yönteminde Gabor filtrelerinin ebatının performansa etkisi.	40
Şekil 30. Zıtlık Çevre Modülasyonu yönteminde çevre modülasyonunun performansa etkisi.	41
Şekil 31. Şekilcikler Üzerinde Şartlı Rastgele Alan yönteminde Gaussian Mixture Model sayısının performansa etkisi.	41
Şekil 32. Şekilcikler Üzerinde Şartlı Rastgele Alan yönteminde köşe türlerinin performansa etkisi.	42
Şekil 33. Görsel İpuçları Üzerinde Şartlı Rastgele Alan yönteminde köşe türlerinin ve görsel ipuçlarının performansa etkisi. (a) İç-alan. (b) Dış-alan.	43
Şekil 34. Örnek bir görüntüden elde edilen içeriye doldurma sonuçları.	45
Şekil 35. (a) MRA ile Bölütleme Yapısı (b) MRA ile Bölütleme ve Sınır Sahipliği Tespiti Yapısı (en iyi renkli görünür).	46
Şekil 36. Eski yöntemin çalışma prensibi. (a) Homojen yeğlinliğe sahip bir alanda derinlik, kenarlardaki derinlik bilgisi kullanılarak öngörülebilir (tabi ki başka derinlik ipuçları da kullanılabilir). (b) Eski-yöntemde önerilen, her bir homojen bölgecik için, onu çevreleyen kenarcıkları bulmak ve o kenarcıklardan ikili eşler oluşturarak, ikili eşlerin homojen bölgecik için bir kestirimde bulunmasını sağlamak (c). Problem şu ki, (b)'de de görüldüğü gibi, bir homojen bölgeciği çevreleyen kenarlar, o bölgeye/alana ait olmayabilirler, ki bunun çözümü, sınır sahipliği bilgisi kullanmaktır.	49
Şekil 37. Eski yöntem (DeP) ve yeni yöntemin (BO DeP) kıyaslanması. (a) Yöntemleri kıyaslamak için kullandığımız yapay düzenek. OpenGL ortamında oluşturduğumuz düzenek	

sayesinde doğru derinlik bilgisini elde edebiliyoruz ve görüntüye farklı oranda doku ve gürültü ekleyebiliyoruz. (b) Farklı doku miktarlarında ve (c) farklı gürültü ve doku miktarlarında RMS (root-mean-squared hatası) ve BM (bad-matching percentage hatası – hesaplanan disparitesi doğru değerden farklı olan piksellerin oranı)50

Şekil 38. Örnek bir görsel üzerinde sınır sahipliği bilgisinin kullanılarak stereo ayırım bilgisinin nasıl değiştiği. (a) Beklenen sonuç. (b) DBA ile elde edilen sonuç. (c) Sınır sahipliği eklenince elde edilen sonuç.52

Şekil 39. Örnek bir görselde sınır sahipliği bilgisinin optik akış kestirimine katkısı. (a) Beklenen sonuç. (b) DBA ile elde edilen sonuç. (c) Sınır sahipliği eklenince elde edilen sonuç.53

ÖZET

Tekdüze görüntü alanlarının neden olduğu eksik ve muğlak görsel bilginin düzeltilebilmesi, ilgili görüntü alanlarını çevreleyen sınırlardaki (görüntü işleme diliyle; kenarlardaki) güvenilir görsel bilgilerin 'içeriye doldurma' mekanizması kullanılarak görüntü alanlarının iç kısımlarına iletilmesiyle mümkün olabilir. Ancak, bu yöntemin kullanılabilmesi, görüntü alanlarının sınırlarının daha önceden belirlenmesini gerektirir; bir başka deyişle, görüntüdeki her kenara bir 'sınır sahipliği' bilgisi verilmiş olmalıdır. 'Sınır sahipliği' bilgisi, görüntüdeki kenarları ve alanları birbirine bağlar; böylece, kenarlardaki güvenilir görsel bilgi, doğru alanların içine doğru aktarılabilir.

Bu projede üç hedefi gerçekleştirilmiştir: (1) Sınır sahipliğinin belirlenmesi için önemli mekanizmaları incelemek, (2) bu inceleme sonuçlarını kullanan bilişimsel (ing. computational) bir model geliştirmek ve (3) bu bilişimsel modeli, yerel mekanizmalar kullanan, önemli görme problemlerine uygulayarak, sınır sahipliği bilgisinin görsel bilginin kalitesi ve niceliği üzerindeki etkisini göstermek.

İlk hedefimizde, insan denekler tarafından sınır sahipliği işaretlenecek ve incelememiz için temel oluşturacak görüntüler toplanmıştır. Sınır sahipliği işaretlenmiş bu görüntüleri kullanarak, sınır sahipliği bilgisi ve farklı görsel öğeler arasında incelemesi yapılmıştır. Bu türden bir yaklaşımın, sınır sahipliği gibi henüz işleme mekanizması anlaşılamamış bir problem için oldukça uygun olduğunu düşünüyoruz; çünkü insan görme sisteminin görüntülerdeki düzenliliği kullandığı ve bu düzenliliği (işaretlenmiş görüntüler üzerinden) incelemenin farklı algısal mekanizmaların çalışma prensipleri hakkında ipuçları taşıyacağı literatür tarafından yaygın olarak kabul görmektedir.

İkinci hedefimiz için, sınır sahipliği bilgisi taşıyan farklı veri kaynaklarını ve bu kaynaklar arasındaki ilişkileri modellemek için farklı bilişimsel yöntemler geliştirdik. Bu yöntemler arasında, tensör oylama, olasılıksal rastgele alan, karar destek makineleri, Bayes sınıflandırma, AdaBoost sınıflandırma sayılabilir. Ayrıca, bu yöntemleri verisetimiz üzerinde detaylı bir biçimde kıyaslamış bulunmaktayız.

Bilişimsel modeli geliştirdikten sonra, modelimizi yerel hesaplama yöntemleri kullanan üç önemli görme problemi olan, optik akış ve stereo görme hesaplamalarına ve kenarlardaki derinlik bilgisini kullanarak görüntü alanları içerisinde derinlik öngörme problemlerine uyguladık ve sınır sahipliği bilgisinin farklı seviyelerde katkı sağladığını gösterdik.

Anahtar Kelimeler: Bilgisayarlı Görme, Sınır Sahipliği, İçeri Doldurma Mekanizmaları

ABSTRACT

One way to rectify the ambiguous and the incomplete visual information is to utilize the reliable visual information available at the borders (in image processing terms, the edges) of the regions by ‘filling-in’ mechanisms, which diffuse the information in to the regions. However, such mechanisms require that the borders of the regions have already been determined; i.e., each border in the scene is assigned to a region. ‘Border ownership’ links the regions and the edges in the scene; in this way, the reliable information at the edges can be diffused into the correct regions.

In this project, we achieved three goals: (1) Investigate the mechanisms important for determining border ownership. (2) Use and interpret the results of the investigation in item (1) to develop a computational model that would estimate the border ownership of the edges in the images. (3) Apply the developed computational model to important vision problems to demonstrate that using border ownership improves acquisition of reliable and complete visual information.

As our first goal, we collected human-labeled dataset that contains the border ownership of the edges. Using this labeled data, we investigated the relationship between different visual information and the border ownership assignment. We argue that such an investigation is crucial for a problem whose underlying mechanisms are unknown (like border ownership) since it is known that human vision system utilizes the regularities in the scenes and investigating such regularities (from labeled data) can yield important facts about different visual processes.

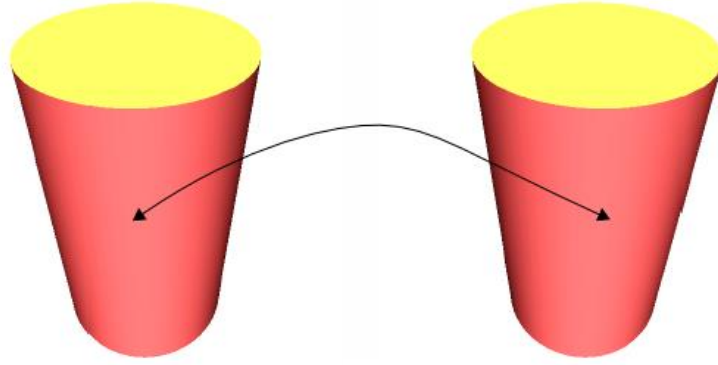
As our second goal, we developed several computational methods to estimate border ownership. The developed methods include tensor voting, conditional random field, support vector machines, Bayesian classification, AdaBoost learning etc. Moreover, we evaluated all these algorithms on our dataset.

As our final goal, we applied the computational model derived in our second goal to three important vision problems: optic flow and stereo disparity computation, and depth estimation at image regions from the edges in the scene, and showed that border ownership improves the quality of such visual information.

Keywords: Computer Vision, Border Ownership, Filling-in Mechanisms

1. GİRİŞ

Gelişen teknoloji sayesinde, bilgisayarlar ve bilgisayarlı aygıtlar (örn., robotlar) gündelik hayatımızda karşımıza çıkmakta, farklı gereksinimlerimizi, çoğunlukla bizlerle kapsamlı bir etkileşim sonucu, limitli ortamlarda, çok kısıtlı hedefler için de olsa karşılamaktadır. Bu etkileşimin daha verimli olabilmesi, muhakkak ki, ancak çevreyi olabildiğince bizim gördüğümüz gibi görebilen ve yorumlayabilen bilgisayarlarla veya robotlarla mümkün olabilir.



Şekil 1: Eşleştirme problemi. Optik akış ve stereo, bir sahnenin iki farklı görüntüsü içindeki her pikseli eşleştirmeyi gerektirir. Ancak bu eşleştirmeyi elde etmek, tekdüze görüntü alanlarında mümkün olmayabilir.¹


Bu kapsamda, bilgisayarlı görme sistemlerinin, bir görüntüyü hassas ve tam bir şekilde işleyebilmesi elzemdir. Ancak, görme, doğası gereği düzensiz (ing. ill-posed) bir problemdir ve çoğunlukla elde edilen bilgi hassas ve tam olmaktan uzaktır. Bunun en önemli nedeni, gözlerimize veya kamera devrelerine düşen görüntülerin, üç boyutlu dünyanın sadece iki boyutlu izdüşümleri olmasıdır.

Bu 2B izdüşümlerden 3B bilgisini doğru çıkarabilmek için, yapay ya da biyolojik her görme sisteminin, eksik ve muğlak görsel bilgiyi işleyebilmesi gerekmektedir. Örneğin, tekdüze koyuluğu olan görüntü alanlarının, sinir hücrelerinin algı bölgelerinde herhangi bir değişikliğe neden olmadığı ve bu nedenle, gözdeki ve görsel korteksteki sinir hücrelerini uyaramadığı

¹ ARDEB-PTS sistemi sonuç raporunun dosya boyutuna 3MB dosya limiti koyduğu için rapordaki tüm görseller sıkıştırılmış ve çözünürlükleri düşürülmüştür.

bilinmektedir (Neumann vd., 2007). Ancak, bizler, tekdüze koyuluğu olan alanları da algılayabilmekteyiz. Bunu sağlayan önemli mekanizmalardan bir tanesi, içeriye doldurma mekanizmasıdır; bu sayede kenarlarda veya belirgin noktalarda elde edilen değerli görsel bilgi iç-alanlara aktarılmaktadır. Ancak bunun mümkün olabilmesi için, görsel bilginin hangi alanlara doğru aktarılacağı, bir başka deyişle, sınır sahipliği bilgisi gerekmektedir.

1.1 Optik Akış ve Stereo Hesaplama



Şekil 2: Bir stereo kameradan alınan sol ve sağ kamera görüntüleri (a) ve bu görüntülerden iki farklı yöntem ile (solda: dinamik programlama (Scharstein ve Szeliski, 2002), sağda: faz-tabanlı bir yöntem (Sabatini vd., 2007)) elde edilen eksik ve muğlak stereo bilgisi.


Optik akış ve stereo disparite, bir görüntüyü anlamak için önemli bilgiler sağlar. Bu nedenle, bu iki görsel bilginin tam ve hassas edinimi, görüntüyü doğru yorumlamak için önemlidir. Hem optik akış, hem de stereo disparite için, aynı sahnenin iki farklı görüntüsü arasında eşleşen pikselleri bulmak gerekir (ing. correspondence problem) (Şekil 1). İnsan görme sistemindeki gibi yerel eşleşme kullanıldığı zaman, tekdüze görüntü alanlarındaki görsel bilgi ayrık olmadığı için, edinilen optik akış ve stereo bilgisi muğlak ve eksik olacaktır (Şekil 2). Bu nedenle, mevcut yöntemler, desenli görüntüler üzerine yoğunlaşmaktadır ve oklüzyon probleminden dolayı, oklüzyon kenarlarındaki değerli bilgiyi kullanmamaktadır (Scharstein ve Szeliski, 2002; Brown vd., 2003; Weickert vd., 2006).

Stereo ve optik akış, bir sahnenin iki farklı görüntüsündeki her pikseli (veya öznelikleri) eşleştirmeyi gerektirir (Şekil 1). Ancak bu, tekdüze görüntü alanlarında mümkün değildir. Literatür, bu tür alanların etkisini azaltabilmek için, global optimizasyon kullanmakta ve desenli görüntülere yoğunlaşmaktadır (Scharstein ve Szeliski, 2002; Brown vd., 2003; Bayerl ve Neumann, 2007; Weickert vd., 2006; Ince ve Konrad, 2008).

Mevcut stereo ve optik akış yöntemlerinde kenarlardaki değerli bilgi ihmal edilmekte veya sadece oklüzyon olmadığı düşünülen bölgelerde kullanılmaktadır (Scharstein ve Szeliski, 2002; Ince ve Konrad, 2008). Örneğin, mevcut yöntemlerde yaygın olarak kullanılan düzenleyici (ing. regularization) terimi, kenarlardaki görsel bilgiyi ihmal etmektedir. Bu düzenleyici terim, optik akış ve stereo hesaplanmasında, komşu pikseller arasındaki görsel

bilgiyi benzerleştirmekte (bir nevi, 'doğru' bilgiyi yaymakta), ancak kontrast olan yerlerde (yani, kenarların olduğu bölgelerde) bu benzerleştirme uygulanmamaktadır (Scharstein ve Szeliski, 2002; Weickert vd., 2006).

1.2 Eşleştirme Problemi ve İçeriye Doldurmanın Önemi



(a)



(b)

Şekil 3: Sınır sahipliği, özellikle birden fazla alan tarafından paylaşılan görüntü alanları alanlarından hangisinin bir kenarın sahibi olduğunu belirtir. (a) ve (b) örnek çizimlerinde, kırmızı renk ile işaretlenmiş kenarların sahipliği bilgisi, o kenarın hangi alanın görsel bilgilerini hesaplamakta kullanılacağı konusunda önemlidir.

Sınır sahipliği, bir görüntüdeki kenarların hangi görüntü alanlarına ait olduğunu ifade etmektedir (Bknz. Şekil 3). Bir kenar, sadece komşusu olduğu alanlara ve aynı anda sadece bir alana ait olabilir. Bilgisayarlı görme literatürü tarafından çok kullanılmayan sınır sahipliği bilgisi, doğru görsel bilginin yayılabilmesi için önem arz etmektedir.

Tekdüze görüntü alanlarının neden olduğu, yukarıda bahsettiğimiz eksik ve muğlâk görsel bilginin düzeltilebilmesi, ilgili görüntü alanlarını çevreleyen sınırlardaki (görüntü işleme diliyle; kenarlardaki) güvenilir görsel bilgilerin 'içeriye doldurma' mekanizmasıyla görüntü alanlarının iç kısımlarına iletilmesiyle mümkün olabilir (Kikuchi ve Akashi, 2001; Nishimura ve Sakai, 2004; Neumann vd., 2007). Ancak, bu yöntemin kullanılabilmesi, görüntü alanlarının sınırlarının daha önceden belirlenmesini gerektirmektedir; bir başka deyişle, görüntüdeki her kenara bir 'sınır sahipliği' bilgisi verilmelidir. 'Sınır sahipliği' bilgisi, görüntüdeki kenarları ve alanları birbirine bağlar; böylece, kenarlardaki güvenilir görsel bilgi, alanların içine doğru aktarılabilir.

İçeriye doldurma, sadece var olan muğlâk bilginin düzeltilmesi veya eksik görsel bilginin tamamlanması için değil, kenarlardaki güvenilir görsel bilgiden faydalanarak, hiçbir bilgi

içermeyen görüntü alanlarında öngörü yapmak için de kullanılabilir (Nishimura ve Sakai, 2004).

Yerel eşleşmenin getirdiği muğlâk ve eksik bilgi probleminin yanında, mevcut bilgisayarlı görme yöntemlerinde yaygın olarak kullanılan düzenleyici (ing. regularization) terimi, kenarlardaki görsel bilgiyi ihmal etmektedir. Bu düzenleyici terim, optik akış ve stereo hesaplanmasında, komşu pikseller arasındaki görsel bilgiyi benzerleştirmekte (bir nevi, 'doğru' bilgiyi yaymakta), ancak kontrast olan yerlerde (yani, kenarların olduğu bölgelerde) bu benzerleştirmeyi uygulamamaktadır. Bu yaklaşım, dolaylı olarak, kenarlardaki değerli görsel bilginin kullanılmamasına, hatta hesaplanan kalite ölçütlerinde (çoğunlukla) hesaba katılmamasına neden olmaktadır (Albert, 2001; Baki vd., 2000).

Özetle, sınır sahipliği bilgisi biyolojik ve yapay görme sistemleri için önemlidir çünkü hassas ve tam görsel bilginin elde edinimi için problem teşkil eden yukarıdaki problemler, sınır sahipliği bilgisi kullanılarak azaltılabilir ve aşılabilir; yani, yapay görme sistemlerinde üretilen stereo ve optik akış gibi görsel bilgiler sınır sahipliği bilgisi ile iyileştirilebilir. Bunun yanında, sınır sahipliği bilgisi, nesnelerin sınırlarını da belirlediği için nesne tanıma ve algılamaya katkı sağlar; nesnelerin birbirlerine göre göreceli derinlik bilgisi hesaplanmasına olanak sağlar.

1.3 Projenin Kapsamı ve Katkıları

Projede, sınır sahipliği problemi modelleme bakış açısı ile çalışılmıştır. Bu kapsamda, aşağıda detaylı özetlenen problemler çalışılmış ve katkılar yapılmıştır.

1.3.1 Sınır Sahipliği Veriseti Oluşturma (ÇP1)

Literatürdeki mevcut sınır sahipliği çalışmaları kısıtlı sayıda ve türde görüntü üzerinden test edilmektedir. Projenin en önemli katkısı, 500 iç-alan ve 500 dış-alan görüntüsünün üçer denek tarafından işaretlenmesi ve bunun tüm literatür ile paylaşılmasıdır. Bu veriseti sayesinde, daha gelişmiş bilişimsel yöntemler geliştirilmesi sağlanabilecektir.

Verisetinin toplanabilmesi için kullanıcı dostu bir web arayüzü geliştirilmiş, ve ODTÜ Etik Kurulu tarafından onaylanan bir prosedür ile farklı yaşlardan, eğitim seviyelerinden ve cinsiyetten deneklerden veri toplanmıştır.

1.3.2 Sınır Sahipliği İpuçlarını İnceleme (ÇP2)

Literatür, hangi görsel bilgilerin veya mekanizmaların sınır sahipliği için ipucu olabileceği konusunda detaylı bir inceleme yapmamıştır. Varolan çalışmalar modellerini zayıf hipotezlere dayandırarak, sadece bir görsel bilgi üzerinden geliştirmiştir. Mevcut durum göz önüne alınarak, insanlar tarafından elle işaretlenmiş sınır sahipliği bilgisini kullanarak bu projede yaptığımız inceleme, literatür tarafından faydalanılacak önemli sınır sahipliği ipuçlarını, bulgularını ortaya çıkarmaktadır. Elde edilecek sonuçlar arasında, sınır sahipliği için hangi görsel bilgilerin daha değerli olduğu ve birbiriyle çelişen ipuçlarının nasıl ve hangi ipucu doğrultusunda çözümlendiği yer almaktadır ve bu sonuçlar bilgisayarlı ve bilişsel görme camiası için oldukça önemlidir.

1.3.3 Sınır Sahipliği Kestirimi İçin Bilişimsel Yöntemler (ÇP3)

Proje kapsamında tensör oylama, şartlı rastgele alan ve AdaBoost yöntemleri üzerine inşa edilmiş üç özgün bilişimsel yöntem geliştirilmiştir ve görsel ipuçlarının zıtlığı durumları kestirmeye dayalı bir adet özgün yöntem de geliştirilmektedir. Bu yöntemler ve literatürde (bir kısmı proje esnasında önerilmiş) yöntemler verisetinde kıyaslanmıştır.

Proje kapsamında geliştirilmiş ve kıyasladığımız yöntemlerin kendi gerçekleştirmemiz ile oluşturduğumuz kaynak kodları, yayınımızın kabulünden sonra projenin web sayfası üzerinden herkese açık halde sunulacaktır.

1.3.4 Sınır Sahipliği Bilgisinin Kullanımı (ÇP4)

Var olan sınır sahipliği çalışmaları kapsamlı bir veritabanında test edilemediği için, sonuçları görüntü algılama problemleri için henüz kullanılmamıştır. Bu projede, sınır sahipliği modelini optik akış ve stereo bilgisindeki eksik ve muğlak bilginin giderilmesi için kullanmakta ve bu bilgileri iyileştirdiğini göstermekteyiz. Buna ek olarak, erken görme aşamasında çözümlenmekte olan ilintili bir problem olan bölütleme ile sınır sahipliğinin iş çözümü konusunda da bir katkı yapmış bulunmaktayız.

Bu katkılarımız ile aynı zamanda, özellikle oklüzyon olan bölgelerde ihmal edilen kenar bilgisini optik akış ve stereo hesaplamasına dahil etmek istiyoruz.

Bu iş paketinin hedefleri arasında, sınır sahipliği bilgisi kullanılarak iyileştirilmiş derinlik bilgisinin nesnelere tutmaya çalışan bir robot tarafından kullanılması da vardı. Ancak, proje teklifi aşamasında ortaya çıkan ve yayılan Kinect vb. RGB-D kameralar, robotbilim çalışmalarında daha hassas ve gerçek-zamanlı çalıştığı için oldukça yaygın kullanılmaya başlanmıştır. Bu nedenle, ve ek olarak, stereo-görme ve onun üzerine eklenecek sınır

sahipliği ile elde ettiğimiz sonuçlar robotbilim çalışmaları için yeterince iyi (birkaç cm'lik hata seviyesinde) olmadığından, robot üzerinde deneyler yapılmamıştır.

1.4 Projenin Yayın Çıktıları

Projede elde edilen yöntemler ve sonuçlar; 1 adet makale; ulusal konferanslarda 3 adet bildiri; ve 3 adet lisansüstü tez olarak yayınlanmıştır. Ayrıca bir dergi yayını da planlanmaktadır.

1.4.1 Dergi Yayınları

Akkuş, M. A., Olgunsoylu, S., Topuz, G., Kalkan, S. 2015. "Analysis of Visual Cues and Computational Models for Border Ownership", Computer Vision and Image Understanding, gönderildi.

Ayrıca, sınır sahipliği bilgisinin kullanımı ve görsel bilgiyi iyileştirmesi konusunda ikinci bir dergi yayını planlanmaktadır.

1.4.2 Ulusal Bildiri

Öztimur, Ö., Akkuş, M. A., Kalkan, S. 2015. "An MRF Framework for Co-Solving Image Segmentation and Border Ownership", IEEE 23rd Conference on Signal Processing and Communication Applications (SIU), Malatya, Türkiye.

Akkuş, M. A., Topuz, G., Özkan, B., Kalkan, S. 2013. "A Comprehensive Database for Border Ownership", IEEE 21st Conference on Signal Processing and Communication Applications (SIU), Girne, KKTC.

Özkan, B., Kalkan, S. 2013. "Extraction of Border Ownership Information by Conditional Random Field Model", IEEE 21st Conference on Signal Processing and Communication Applications (SIU), Girne, KKTC.

1.4.3 Öğrenci Tezleri

Özkan, B. 2014. "Estimating border ownership using iterative vector voting and Conditional Random Fields", Yüksek Lisans tezi, Bilgisayar Mühendisliği, ODTÜ.

Akkuş, M. A. 2014. "Analysis of border ownership cues and improvement of depth prediction using border ownership", Yüksek Lisans tezi, Bilgisayar Mühendisliği, ODTÜ.

1.5 Raporun Krokisi

Rapor, kısa bir literatür özetinden sonra, projenin katkıları aşağıdaki bölümlerde sunmaktadır:

- i. Veri seti toplama (**Bölüm 3**):
- ii. Görsel ipuçları ve incelenmesi (**Bölüm 4**)
- iii. Bilişimsel yöntemler:
 - a. Tekrarlamalı vektör oylama (**Bölüm 5**)
 - b. Şartlı rastgele alan (**Bölüm 6**)
 - c. Yöntemlerin kıyaslanması (**Bölüm 0**)
- iv. Sınır sahipliği bilgisinin kullanımı (**Bölüm 8**)

2. LİTERATÜR ÖZETİ

Bu bölümde, sınır sahipliği problemine geniş bir bakış açısı verdikten sonra, literatürde sınır sahipliği hakkında insan görme sisteminden elde edilen bulgular ve sınır sahipliğinin bilişimsel modeller ile kestirimi çalışmaları sunulacaktır.

2.1 Sınır Sahipliği ve Şekil-Arkaplan Ayrımı

Görme sistemimizin, eksik görsel bilgiyi tamamlamak ve muğlak bilgiyi düzeltmek için içeriye doldurma kullandığı bilinmektedir (Anderson vd., 2002; Julesz, 1971; Komatsu, 2006; Pessoa vd., 1998) ve bu bulgu, yapay görme sistemlerinde, başta derinlik ara değerlemesi (Anderson vd., 2002; Barrow ve Tenenbaum, 1981; Collett, 1985; Grimson, 1982; Terzopoulos, 1988) (ing. interpolation), optik akış (Treue vd., 1995; Bayerl ve Neumann, 2007) ve stereo hesaplama (Dellen ve Wörgötter, 2009) olmak üzere farklı problemlere başarılı bir şekilde uygulanmıştır.

Sınır sahipliği bilgisi, özellikle içeriye doldurma mekanizmalarında gerekli olduğu düşünülen, bir 'görsel gruplama' (ing. perceptual grouping) sürecidir (Neumann vd., 2007; Albert, 2001). İçeriye doldurma mekanizmasındaki faydasının yanında, sınır sahipliği bilgisi, nesnelere arka plandan ve diğer nesnelere ayırmayı kolaylaştırdığından, nesne algılama için de önemlidir (Albert, 2001).

2.2 Sinirbilimde Sınır Sahipliği

İnsan görme sisteminde Sınır Sahipliği bilgisine duyarlı nöronların olduğu ancak 2000'lerde keşfedilmiştir: Zhou vd. (2000) V1 bölgesindeki hücrelerin %18'inin, V2 ve V4 bölgesindeki hücrelerin ise %50'den fazlasının sınıra sahip bölgenin yönünü kodlamakta veya o yöne duyarlı olduğunu göstermiştir. En fazla sayıda sınır sahipliği seçici nöronları V2 ve V4 bölgeleri, (V2'nin %59'u ve V4'ün %53'ü) sınır sahipliği kestiriminde önemli bir yere sahiptir (Qiu vd., 2007).


Sınır sahipliği kestiriminin insan görme sisteminde nasıl gerçekleştirildiği tam olarak bilinmese de, zıtlık (kontrast – Layton vd., 2012), derinlik sırası (Qiu ve Von Der Heydt, 2005), eğrilik (Zhou vd., 2000; Hegde ve Van Essen, 2007) gibi görsel ipuçlarının önemli yeri olduğu gösterilmiştir. Bu görsel ipuçları arasında, bu proje kapsamında da gösterildiği üzere, en belirleyici olanın eğrilik olduğu bilinmektedir. Gösterilmiştir ki maymun beyninin V2 ve V4 bölgelerinde yer alan sınır sahipliği seçici nöronlar, şeklin kenarları konveks olduğu zaman aktif hale gelmektedir (Zhou vd., 2000). Nitekim, V4 bölgesinde, algı alanı geniş ve çevre-etkili (ing. on-surround) olan nöronların konveks ve konkav şekillere duyarlı olduğu

gösterilmiştir. Bu da, V4 bölgesinin eğrilik-temelli sınır sahipliği kestiriminde aktif rol oynayabileceği anlamına gelmektedir.

Sınır sahipliğine duyarlı nöronların, sınır sahipliği yönünü, sinyalin gelişinden 10-25 ms gibi kısa bir sürede belirlemeye başlayabilmesi (Zhou vd., 2000) ve sınır sahipliğine duyarlı hücrelerin V1 gibi erken bir evrede belirlemeye başlaması, sınır sahipliği bilgisinin yerel ipuçları ile kestiriminin mümkün olduğunu önermektedir. Ancak, aynı seviyede bulunan nöronlar arasındaki bağlantıların çok yavaş olduğu bilinmektedir (Zhou vd., 2000; Kogo ve van Ee; 2014). Bu nedenle, ileri-doğru (ing. feed-forward) ve geriye-doğru (ing. feed-back) bağlantıların hızlı sinapslardan oluşması (Zhou vd., 2000; Kogo ve van Ee; 2014) ve farklı psikofiziksel bulgular (Peterson vd., 1991; Vecera ve O'reilly, 1998), bu hızlı işlem gücünü ileri-doğru ve geriye-doğru bağlantıların sağladığını önermektedir. Bu ileri-doğru ve geriye-doğru bilgi akışı farklı seviyelerde sağlanabilir: yerel ipuçlarının birleştirilmesi ve elde edilen sonucun hemen geri-besleme vermesinden (Zhou vd., 2000; Kogo ve van Ee; 2014), görme sisteminin çok daha ileriki aşamalarında yer alan nesne seviyesindeki bilgilerden elde edilen geri beslemeye (Peterson vd., 1991; Vecera ve O'reilly, 1998; 2000; Peterson, 1998; Zucker, 2012) kadar değişmektedir. Örneğin, aşinalık, dikkat, duygu gibi üst seviye bilgilerin ve durumların sınır sahipliğini belirlemede etkin olabilmektedir (Fang vd., 2009).

2.3 Psikolojide Sınır Sahipliği


Psikolojide de sınır sahipliği problemi çalışılmıştır ve bu çalışmalar, sınır sahipliği mekanizmalarını anlamak için faydalı olmuştur. Örneğin, insan deneklerin konveks alanları kendine daha yakın, konkav bölgeleri ise daha uzak olarak algıladığı gösterilmiştir - bkzn. (Peterson ve Salvagio, 2008) ve Şekil 4.



Şekil 4: (A) alt alan ve (B) konvekslik ipuçları, şekil-alan ayrımı için önemli ipuçlarıdır. (Vecera, vd., (2002)'dan izin ile uyarlanmıştır.)

Sınır sahipliği için önemli diğer ipuçları, alt-alan (Şekil 4), T-köşeleri ve L-köşeleridir. Vecera vd. (2002), göstermiştir ki bir görüntüde aşağıda kalan alanlar daha önde algılanmaktadır. Ayrıca, T-köşelerinin bir oklüzyona işaret ettiğini ve T köşesindeki belirli bir alanın kenara sahip olduğunu gösterilmiştir (Şekil 5 – Layton vd., 2012).

Psikolojide farklı ipuçlarının sınır sahipliği problemi için önemli olduğu gösterilmiş olsa da, bu ipuçları için daha kontrollü deneylere ihtiyaç olduğu ve daha fazla görsel bilginin incelenmesigerekliliği görülmüştür.



Şekil 5: (A) T-köşeleri, oklüzyon bölgeleri için belirgin bir ipucudur. (B) L-köşesi, bir şeklin köşesi olarak algılanmakta ve bu nedenle, kenarların köşeyi oluşturan alana ait olduğu algılanmaktadır. (Layton, vd., (2012)'den uyarlanmıştır.)

2.4 Bilişimsel Sınır Sahipliği Çalışmaları

Finkel ve Sajda (1992), oklüzyon ve bir şeklin kapanma (ing. Contour closure) bilgisini sınır sahipliği (SS) için ipuçları olarak işleyen sinir ağı modüllerinden oluşan bir model önermiştir, ki bu model Kikuchi ve Akashi (2001) tarafından, uzun menzilli etkileşimler içerdiğinden dolayı, bir erken görme problemi için gerçekçi olmamakla eleştirilmiştir.

Kikuchi ve Akashi (2001), bunun yerine, köşelerin iç kısımlarını ve kıvrımlı kenarları sınır sahipliği için ipucu olarak kullanmıştır. Ancak, Kikuchi ve Akashi tarafından geliştirilen model yalnız, düzgünce alanlara ayrılmış siyah-beyaz (yani, iki renkli) görüntülerde ve dikdörtgen ve daire gibi basit nesnelere üzerinde test edilmiştir.

Nishimura ve Sakai (2004) ise önceki çalışmalara göre daha biyolojik motivasyonlu bir model önermiş, ancak önerdikleri modeli iki dikdörtgen içeren yapay görüntülerde denemiştir. Nishimura ve Sakai tarafından önerilen modelin ana çıkış noktası, sınır sahipliği hassasiyeti gösteren beyin hücrelerinin %80'inin sınırlardaki kontrast kutupluluğuna (bir kenarın hangi

tarafının açık veya koyu olduğu bilgisi) da hassas olmasıdır. Bu motivasyonla, Nishimura ve Sakai, bir kenarın sadece kutbuna bağlı olarak sadece kenarın bir tarafından aktive olan klasik algısal bölgeler (ing. Receptive field) kullanmaktadır. Bu tür aktivasyonların havuzlanması (ing. Pooling), sınır sahipliği bilgisini ortaya çıkarmaktadır. Ayrıca, Nishimura ve Sakai, T-köşeleri gibi yapıların sınır sahipliği modelleri için kullanılmaması gerektiğini iddia eder, zira T-köşeleri gibi görsel yapılara hassasiyeti bulunan beyin hücrelerinin varlığı henüz bilinmemektedir.

Sınır sahipliği pek çok görme problemi için önemli ve bu önem Koka (1935) tarafından 1935 gibi epey zaman önce ("aidiyet" isimli farklı bir terim olarak) belirtilmiş olsa da, sınır sahipliğinin kestirimi bilişimsel çalışmalarda yakın zamana kadar gözardı edilmiştir. Sınır sahipliğini kestiren ilk bilişimsel modeller, yapay sinir ağları temelli idi (Kienker vd., 1986; Sajda ve Finkel, 1995; Kikuchi ve Akashi, 2001; Kikuchi ve Fukushima, 2003; Craft vd., 2007). Bu çalışmalarda, eğrilik, L-köşesi gibi sınır sahipliği bilgisi taşıyan görsel ipuçları kullanılarak, farklı seviyelerdeki sinir hücreleri arasındaki etkileşim modellenmiş, ve bu etkileşimler sonucunda sınır sahipliği bilgisi kestirilmiştir. Benzer bir şekilde, Nishimura ve Sakai [53] tarafından, insan görme sistemindeki sinir hücrelerinin çalışma prensiplerinden esinlenerek kontrast bağlamına göre sınır sahipliğini kestiren bir model önerilmiştir. Bu modelde, ilk seviyelerde belirli bir kontrasta duyarlı basit hücreler kullanılmış ve bu hücrelerin sonuçları inhibitör ve ekzibitör bağlantılarla birleştirilerek sınır sahipliği kestirimleri elde edilmiştir. İlk sınır sahipliğini kestiren bu çalışmalarda yapay görüntüler kullanılmıştır.

İlintili bir problem olan oklüzyon kestirimi için, Chen vd. (2013), semantik, pozisyon, köşe ve konvekslik gibi ipuçlarını kullanan bir model geliştirmiş ve bu modeli 200 şehir, 250 yapay ve 645 doğa fotoğrafına uygulamıştır. Oklüzyon bilgisini kullanarak, görüntüdeki bölgeler arasındaki derinlik sıralamasını da kestirmektedirler. Yazarların analizi göstermiştir ki şehir görüntülerinde semantik ipucu, yapay görüntülerde ise pozisyon ipucu daha belirleyici olmaktadır.

Fowkles vd. (2007), alan büyüklüğü, alt-alan ve konvekslik gibi görsel ipuçlarını şekil-alan ayrımı problem için 200 doğa görüntüsünde test etmiştir. Analiz sonuçlarına göre, alan büyüklüğü en önemli ipuçlarından birisi olarak çıkmıştır ve %68 oranında sınır sahipliğini kestirebilmektedir. Alan büyüklüğünü, alt-alan ve konvekslik ipuçları takip etmektedir. Ayrıca, ipuçlarını birleştirmek için logistik regresyon kullanmışlardır. Birleştirilen ipuçları arasından, alt-alan ve alan büyüklüğü ipuçları en yüksek başarıyı göstermiştir.

Olasılıksal çizgiler ve modeller, sınır sahipliği kestirimi problemi için çok uygun yöntemlerdir. Doğa görüntülerinde sınır sahipliği kestirimi yapmak için, Froyen vd. (2010), alanların orta-eksen (ing. medial-axis) iskelet gösterimi üzerinden Bayes Ağ (ing. Bayesian Network) yöntemi kullanmıştır. Başka bir çalışmada, Ren vd. (2006), yerel öznitelikler (şekilcik – ing. shapeme) üzerinden Şartlı Rastgele Alan (ing. Conditional Random Field - CRF) kullanarak, yerel sınır sahipliği kestirimleri üzerinde küresel tutarlılık sağlamıştır. Göstermişlerdir ki şekilcik-temelli CRF, ipuçlarını oldukları gibi kullanmaya göre daha iyi bir başarımlı vermektir. 100 adet görüntü üzerinde, bu yöntem %78.3 başarımlı elde edebilmektedir.

Sınır sahipliği veya oklüzyon bölgelerini, nesne etiketleri (Chen vd., 2013) veya nesnelerin uzaklığı (Leichter ve Lindenbaum, 2009) gibi bilgileri kullanarak kestirmeye çalışan çalışmalar da bulunmaktadır. Örneğin, Leichter ve Lindenbaum (2009), CRF kullanarak nesnelerin derinlik sıralaması bilgisi ile sınır sahipliğini kestirmektedir. Ancak, bu kadar güçlü ve bilgilendirici bir ipucuna rağmen, Berkeley görüntülerinde sadece %82 oranında başarımlı elde edilebilmiştir (Leichter ve Lindenbaum, 2009).

2.5 Değerlendirme

Literatür bize göstermiştir ki:

- (1) Neumann ve çalışma arkadaşları (2007) tarafından da belirtildiği üzere, var olan sınır sahipliği çalışmaları günlük hayatta karşımıza çıkan veya doğada karşılaşılabileceğimiz karmaşık görüntüler için yetersiz ve uygulanmaktan çok uzaktır,
- (2) ayrıca ne tür görsel bilgilerin sınır sahipliği bilgisi için ipucu oluşturabileceği için detaylı bir analize ihtiyaç vardır ve
- (3) sınır sahipliği modellerinin pratik uygulamalarda kullanımına girilmiştir.

Bu proje ile bu üç noktada katkıda bulunmayı hedeflemekteyiz.


3. VERİ SETİ TOPLAMA

Bu bölümde, sınır sahipliği görsel ipuçlarının incelenmesi ve bilişimsel modellerin test edilmesi için kullanılacak olan kapsamlı veri setinin nasıl oluşturulduğu aktarılmaktadır. Bu bölümde anlatılan çalışmalar, aşağıdaki yayınlara konu olmuştur:

- Akkuş, M. A., Olgunsoylu, S., Topuz, G., Kalkan, S. 2015. "Analysis of Visual Cues and Computational Models for Border Ownership", Computer Vision and Image Understanding, gönderildi.
- Akkuş, M. A., Topuz, G., Özkan, B., Kalkan, S. 2013. "A Comprehensive Database for Border Ownership", IEEE 21st Conference on Signal Processing and Communication Applications (SIU), Girne, KKTC.
- Akkuş, M. A. 2014. "Analysis of border ownership cues and improvement of depth prediction using border ownership", Yüksek Lisans tezi, Bilgisayar Mühendisliği, ODTÜ.

3.1 Görüntüler


Proje kapsamında, 500 iç-alan ve 500 dış-alan fotoğraflarından oluşan, işaretlenmeye hazır veritabanları oluşturuldu. Veritabanımız, fotoğraflar, fotoğrafların alanlara bölümlendirmesi (ing. segmentation) ve alanları ayıran kenar (ing. contour, boundary) bilgisinden oluşmaktadır.



Şekil 6. Berkeley Bölümlendirme Veritabanından (İng. Berkeley Segmentation Database) örnek bir fotoğraf ve bölümlendirmesi. (a) Fotoğraf. (b-c) İki farklı denek tarafından elle yapılmış bölümlendirme.

Dış-alan veritabanımızı oluştururken, Berkeley Bölümlendirme Veritabanından (ing. Berkeley Segmentation Database)² faydalandık. Bu veritabanında, açık-alan fotoğraflarındaki bölgelerin insanlar tarafından (manüel olarak) işaretlemesi mevcuttur. Her fotoğraf, en az üç insan tarafından elle işaretlenmiştir (Bknz. Şekil 6). Bu projede ise, bu veritabanından rastgele bir şekilde, her fotoğraf için sadece bir insana ait bölümlendirme (işaretleme) alınarak kullanılmıştır (örneğin, Şekil 6'deki örnek görüntü için (b) ve (c)'de gösterilen örnek işaretlemelerden sadece birisi veritabanımıza eklenmiştir).

İç mekan içinse, LHI³ veritabanından 219 rastgele imge seçilmiş ve diğer 291 imge çeşitli imge paylaşım sitelerinden (örn. Flickr) bulunmuştur. Berkeley ve LHI veritabanından elde edilen imgeler ile birlikte bölütlenmiş imgeler de mevcutken, imge paylaşım sitelerinden elde edilen iç mekan imgeleri elle bölütlenmiştir. Bölütlenen alanlar arasındaki sınırlar bulunmuş ve sınır uzunluğu resmin köşegeninin yüzde 4'ünden küçük olan sınırlar elenmiştir. Şekil 7 katılımcıların imgelerdeki her bir sınırın iki alandan hangisine (kırmızı ya da mavi) ait olduğunu işaretlemeleri işlemini gösterir.



Şekil 7. Bir imgedeki farklı sınırlar. Katılımcılar beyaz sınırın iki alandan hangisine (kırmızı ya da mavi) ait olduğunu işaretlediler (En iyi renkli görünür).

² <http://www.eecs.berkeley.edu/Research/Projects/CS/vision/bsds/>

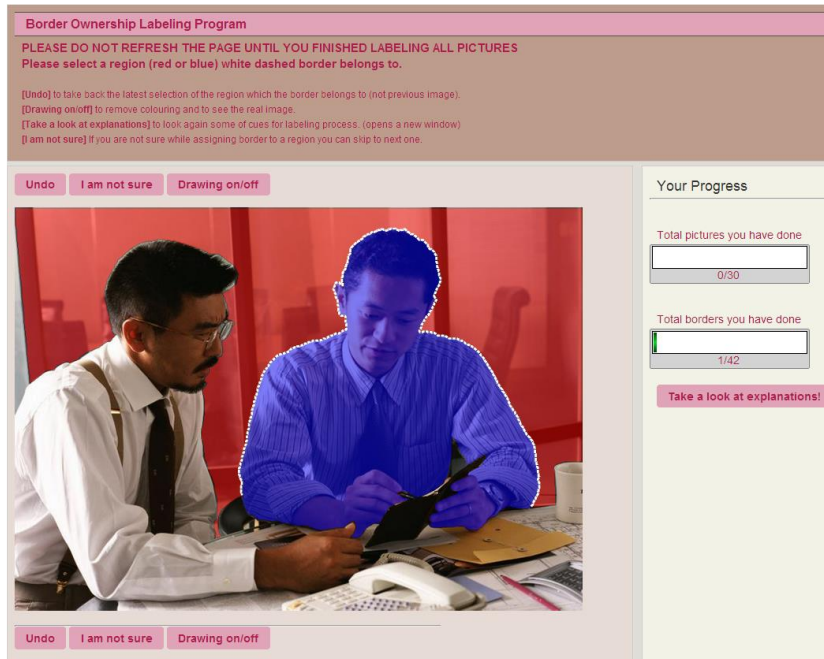
³ <http://www.imageparsing.com/>

3.2 Katılımcılar

Sınır Sahipliği işaretlemeleri 4 katılımcı (1 kadın ve 3 erkek) tarafından gerçekleştirilmiştir. Yaşları 24 ile 34 arasında değişen katılımcılar bilgisayar mühendisliği yüksek lisans öğrencileridir.

3.3 Veri Toplama

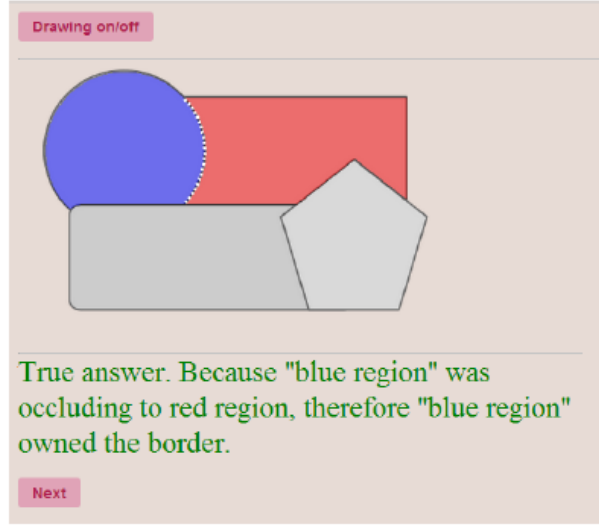
500 iç mekan, 500 dış mekan (toplamda 1000) bölütlenmiş resmin her biri ortalama 800 piksel genişliğinde tipik bir bilgisayar ekranından kullanıcı dostu bir arayüzle, internet tarayıcısı üzerinden sunulmuştur (bkz. Şekil 8).



Şekil 8. Sınır sahipliği işaretleme sayfasından bir görüntü. İmgeler kullanıcı dostu bir arayüz ile sunuldu. İmgelerdeki her bir sınır en az üç katılımcı tarafından işaretlendi. (Renkli örneğe bakınız)

3.4 Prosedür

Katılımcılar işaretleme işlemine sınır sahipliği işaretleme programına web sayfası üzerinden kayıt olarak başladılar. Kayıt sırasında katılımcıların yaşları, cinsiyeti, öğrenim seviyeleri (Doktora, Yüksek Lisans, Lisans, Lise, Ortaöğretim) soruldu. Kayıttan sonra işaretleme işlemi hakkında bilgi içeren gönüllü katılım formları katılımcılar tarafından dolduruldu.



Şekil 9. Web-tabanlı işaretleme programındaki alıştırmaya sayfasından bir görüntü. Katılımcıları sınır sahipliği işaretleme prosedürüne alıştırmak için her bir işaretlemeden sonra ‘doğru’ ve ‘yanlış’ olmak üzere geribildirim verildi.

İşaretleme işlemine başlamadan önce bir açıklama ve alıştırmaya sayfası yer aldı (bkz. Şekil 9). Açıklama sayfası, gerçek iç mekan ve dış mekan imgelerinden oluşan üç örnek içerdi. Örneklerin ikisinde, sınırın iki alandan birine (kırmızı ya da mavi) ait olduğunu, diğerinde ise ‘Emin değilim’ seçeneğini açıklayan, sınırın iki alandan hangisine ait olduğu muğlak olduğu bir imge yer aldı. Alıştırmada katılımcılardan birbirini örten temel yapay şekillerin (çember, dikdörtgen ve beşgen) arasındaki beyaz renkli sınırın ait olduğunu düşündükleri alanın (kırmızı ya da mavi) üstüne tıklayarak göstermeleri istendi (bkz. Şekil 9). ‘Çizimi aç/kapat’ ve ‘Açıklamalara göz at’ seçenekleri katılımcıların işaretlemelerine yardımcı olmak için şekillerin üzerindeki renkli alanları kaldırarak orjinal imgeleri ve işaretlemeleri kolaylaştırıcı bazı ipuçlarını görmelerini sağladı. Alıştırmada her bir işaretlemeden sonra ‘doğru’ ve ‘yanlış’ geribildirimi belirdi. Katılımcıların gerçek işaretleme işlemine başlamak için alıştırmada beş doğru işaretleme yapmaları gerekti. Esas işaretleme sayfasında iç mekan (oturma odası, ofis v.b.) ve dış mekan (doğa, hayvan v.b.) imgelerinden oluşan ortalama 30 sınır içeren 30 gerçek dünya resmi yer aldı.

Katılımcılardan bu sefer bu imgeleri 30 dakika içerisinde tıklaması istendi. Alıştırmaya sayfasında yer alan açıklamalar bu sayfada da yer aldı (bkz. Şekil 8). İmgelerdeki her bir sınır tutarlılık analizini sağlamak için en az üç katılımcı tarafından işaretlendi.


3.5 Tutarlılık İncelemesi

Her bir resmin en az 3 farklı katılımcı tarafından elle işaretlemelerinin tutarlılık sonuçları Tablo 1’de gösterilmiştir. Tutarlılık analizinde ‘Emin değilim’ seçeneğinden elde edilen sonuçların dahil edildiği ve edilmediği durumlarda tutarlılık sonuçları gösterilmiştir. Dış mekan imgelerinin işaretlemelerinde katılımcıların ‘Emin değilim’ seçeneğini seçtiği verilerin tüm verilere oranı %0.3 iken, tüm dış mekan işaretlemelerindeki ‘3/3’-tutarlılık oranı %72.4’tür. İç mekan imgelerinin işaretlemelerinde katılımcıların ‘Emin değilim’ seçeneğini seçtiği verilerin tüm verilere oranı %3.1 iken, tüm iç mekan işaretlemelerindeki ‘3/3’-tutarlılık oranı %78.5’tir.

Tablo 1. Tutarlılık sonuçları (%).

Tutarlılık türü	Görüntü türü	İç-alan	Dış-alan	Toplam
Üç denek de aynı işaretledi (3/3)		78.5 %	72.4 %	75.95 %
İki denek aynı işaretledi (2/3)		18.4 %	27.3 %	22.85 %
Denek “Emin değilim” işaretledi		3.1 %	0.3 %	1.7 %

Şekil 10, insanlar tarafından el ile işaretlenmiş sınır sahipliği verisinin yaşlara ve cinsiyetlere göre tutarlılık oranlarını yüzde cinsinden göstermektedir. Buna göre, tutarlılık yaşla birlikte azalıyor görünse de, her yaştan eşit sayıda katılımcı olmadığı için böyle bir çıkarımın doğru olmayacağı düşünülmektedir (A). 35 kadın ve 100 erkek katılımcıdan elde edilen sınır sahipliği işaretlemeleri yüksek tutarlılık oranına (%72) sahiptir (B). Cinsiyetlerin tutarlılık oranları birbirine eşit görünmesine rağmen kadın ve erkek katılımcı sayılarının eşit olmadığı göz önüne alınmalıdır.



Şekil 10. İç-alan ve dış-alan görüntülerindeki tutarlılık (3 deneğin de aynı yönü işaretlemesi durumu) yaşa (a) ve cinsiyete (b) göre çizilmiştir.

4. GÖRSEL İPUÇLARI VE İNCELENMESİ

Bu bölümde, deneklerden toplanan verisetinde görsel ipuçlarının incelenmesi üzerine yaptığımız çalışmalardan bahsedilmektedir. Bu çalışmalar, aşağıdaki yayınlara konu olmuştur:

- Akkuş, M. A., Olgunsoylu, S., Topuz, G., Kalkan, S. 2015. "Analysis of Visual Cues and Computational Models for Border Ownership", Computer Vision and Image Understanding, gönderildi.
- Akkuş, M. A. 2014. "Analysis of border ownership cues and improvement of depth prediction using border ownership", Yüksek Lisans tezi, Bilgisayar Mühendisliği, ODTÜ.

4.1 Görsel İpuçları

Bu bölüm altında, literatürde yaygın olarak kullanılan ve bu projede incelenen görsel ipuçları anlatılmaktadır.

4.1.1 Eğrilik

Eğrilik bilgisi, sınır sahipliği için önemli ipuçlarından birisidir. Eğrilik için kullandığımız tanım, bir noktaya oturtulan çemberin çapının tersidir. P adet noktadan oluşan bir b sınırı üzerindeki bir p_i noktasına çember (o) oturtmak için, o nokta ve etrafındaki iki noktadan oluşan üç noktayı (p_{i-12}, p_i, p_{i+12}), ki burada p_{i-12} , p_i 'den 12 önceki pikseli ifade etmektedir. Şekil 11'de kırmızı p_i noktasını, griler ise 12 önceki ve sonraki noktaları göstermektedir. Eğriliğin yönü $s(p_i)$, p_i noktasını dairenin merkezine ($m(o_{p_i})$) bağlayan vektörün yönüdür:


$$s(p) = m(o_p) - p. \quad (1)$$

Bu tanımla birlikte, sınıra ait olan bölge aşağıdaki gibi tanımlanabilir:

$$\hat{r}_c(b) = \arg \max_{r \in \{r_1, r_2\}} \sum_{p \in b} (s(o_p) \rightarrow r), \quad (2)$$

ki burada $s(o_p) \rightarrow r$ ifadesi, eğriliğin yönü r bölgesini gösterdiği durumda 1, aksi halde sıfırdır.

Şekil 11'de kırmızı nokta eğriliğin değerini bilmek istediğimiz nokta olmak üzere, onun 12 piksel öncesi ve sonrasından seçilen gri noktalar çemberin oturtulacağı noktaları belirlemektedir. Yeşil ok işareti eğriliğin yönünü göstermektedir.



Şekil 11. Eğriliğin tanımı ve sınır sahipliğine etkisi.




4.1.2 Alt-alan

Fotoğrafın altına yakın olan alanlar/nesnelerin, diğerlerine göre daha önde olma olasılığı yüksektir ve bu, tek fotoğraftan derinlik kestirmesi yapan çalışmalarda da ipucu olarak kullanılmaktadır (örn. Liu vd., 2010). Formal olarak, r_1 ve r_2 alanlarını ayıran b sınırı için, alt alan ipucunun kestirimini şu şekilde tanımlayabiliriz:

$$\hat{r}_1(b) = \arg \min_{r \in \{r_1, r_2\}} \left[\arg \min_{(x,y) \in r} (y) \right]. \quad (3)$$

4.1.3 T ve L köşeleri

Önceki dönemde eğrilik, alt alan ve zıtlık ipuçlarını incelemiştik, L ve T köşelerinin sınır sahipliğine etkisinin incelenmesini bu döneme bırakmıştık. L ve T köşeleri, derinlik hakkında değerli bilgiler sağlayan önemli özniteliklerdir. Sınır sahipliği bilişimsel modelleme çalışmalarında da L ve T köşeleri kullanılmaktadır (Ren vd., 2006). Şekil 12'de görüldüğü gibi, L köşesi, kenarlar tarafından kapanmış iç-alanın, T köşesi ise uzun kenara komşu alanın ilgili sınıra sahip olduğunu belirtmektedir.



(a) Örnek T köşeleri ve sınır sahipliği bilgileri.



(b) Örnek L köşeleri ve sınır sahipliği bilgileri.

Şekil 12. T köşelerinin (a) ve L köşelerinin (b) taşıdığı sınır sahipliği bilgisi. Sol: Bir iç-alan görüntüsü. Orta: Bir dış-alan görüntüsü. Sağ: Bir köşenin hangi yönünün sınıra sahip olduğu bilgisi.

L ve T Köşelerin Görüntülerden Çıkarılması

Görüntülerden L ve T köşelerini bulmak için öncelikle Harris köşe bulma yöntemini kullanılmaktadır. Harris yönteminin bulduğu köşelerin kümesini \mathcal{C} ile ifade edersek; her köşe $c \in \mathcal{C}$ için, o köşede kesişen doğru segmentlerini (l_1, \dots, l_n) buluyoruz. Köşenin türünü bize doğru segmentleri arasındaki açılar $(\theta_i = \angle(l_i, l_{(i+1) \bmod n}), i = 1, \dots, n)$ vermektedir. Örneğin, Şekil 12'de görüleceği gibi, bir c köşesinde iki açı varsa (θ_1, θ_2) ve $\theta_2 \gg \theta_1$ (veya tam tersi), c bir L köşesidir ve küçük olan açı yönündeki alan sınıra sahiptir.

Bu yöntemle bulduğumuz örnek T ve L köşelerini, aynı zamanda bu köşelerdeki belirlenen sınır sahipliği yönleri ile birlikte Şekil 12'de bulabilirsiniz.

4.1.4 Kontrast

Sınır sahipliği için bir diğer ipucu, kontrasttır. Daha parlak görünen alan, kameraya daha yakın ve dolayısı ile, sınıra sahip olduğu algılanır. Formal olarak, r_1 ve r_2 alanlarını ayıran b sınırı için, kontrast ipucunun kestirimini şu şekilde tanımlayabiliriz:

$$\hat{r}_{co}(b) = \arg \max_{r \in \{r_1, r_2\}} \sum_{p \in r} \frac{1}{N} I(p), \quad (4)$$

ki burada $I(p)$, p pikselinin yoğunluğunu ifade etmektedir.

4.1.5 Entropi

Görüntü entropisi, bilgi teorisinden esinlenmiştir ve bir alanın bilgi miktarını ifade etmektedir. Efektik olarak, bir bölgenin ne derecede desen içerdiğini, bir başka deyiş ile, ne kadar enerjiye sahip olduğunu ölçmektedir. Düşük entropiye sahip bir alanda yüksek miktarda

desen, kontrast değişimi veya enerji yoktur. Entropinin pek çok tanımı bulunmaktadır, ancak çoğunlukla aşağıdaki gibi hesaplanabilir:

$$E(r) = - \sum_j P_j \log_2 P_j, \quad (5)$$

ki burada P_j , iki komşu piksel arasındaki farkın j olma olasılığıdır, ve basitçe histogram kullanılarak hesaplanır. Entropi bilgisini kullanan görsel ipucu, $\hat{r}_e(b)$, aşağıdaki gibi hesaplanır:

$$\hat{r}_e(b) = \arg \max_{r \in \{r_1, r_2\}} E(r). \quad (6)$$

4.2 Görsel İpuçlarının Analizleri

Verisetimiz üzerinde yaptığımız inceleme Tablo 2’de sunulmuştur. Burada, (i) 3 denekten sadece 2sinin aynı yönü işaretlediğini, (ii) 3 deneğin de aynı yönü işaretlediğini ve (iii) uzmanın işaretlediğini doğru varsayarak ayrı ayrı incelemeler yapılmıştır. Sonuçlara göre T köşeleri, sınır sahipliğini yüksek bir yüzde (%83’e kadar) ile doğru tahmin edebilmektedir. Bunun dışında şansın yeterince üzerinde tahmin yapabilen ipuçları, eğrilik (%74’e kadar) ve L köşeleridir (%58’e kadar).

Tablo 2. Farklı görsel ipuçlarının sınır sahipliğini tahmin etme gücü. “1/3 set”: 3 denekten sadece birisinin işaretlediği alanı doğru aldığımız işaretlemeler. “2/3 set”: Üç denekten ikisinin işaretlediğini doğru kabul ettiğimiz işaretlemeler. “3/3 set”: Tüm 3 deneğin de aynı yönü işaretlediği sınırlar.

	“1/3 set”		“2/3 set”		“3/3 set”	
	İçalan (%)	Dışalan (%)	İçalan (%)	Dışalan (%)	İçalan (%)	Dışalan (%)
Eğrilik	65.6	61.0	71.4	64.6	74.2	68.3
T-köşe	77.0	66.0	79.6	66.4	83.3	69.4
L-köşe	50.0	55.0	57.7	50.6	58.7	50.9
Alt-alan	46.0	50.0	55.4	53.2	56.7	53.5
Zıtlık	44.0	45.8	45.4	47.3	44.7	46.1

Görsel ipuçlarının sınır sahipliğine birlikte etkisinin incelenmesi


Farklı görsel ipuçlarının sınır sahipliği ile ilişkisine ek olarak, birden fazla ipucunun sınır sahipliği ile nasıl ilişkilendiğini de inceledik (bknz. Şekil 13). Bu birleştirmede, ipuçlarının çoğunluğu bir alanı sahip olarak seçiyorsa çoğunluğun seçtiği alan; aksi halde, ipuçlarının tek başlarına tahmin etme yüzdelerini ağırlıklı ortalama olarak alarak, en fazla ağırlığa sahip alan

sahip olarak seçilmektedir. Bir başka deyişle, b sınırına ait alanı $\hat{r}(b)$ belirlerken l_1, \dots, l_I ipuçları kullanılıyorsa ve bunların tek başlarına başarımlar w_{l_1}, \dots, w_{l_I} ise:


$$\hat{r}(b) = \begin{cases} \arg \max_{r \in \{r_1, r_2\}} \sum_{l \in \{l_1, \dots, l_I\}} v(l, b, r) \times w_{l_1}, & \text{eğer } I \bmod 2 = 0 \\ \arg \max_{r \in \{r_1, r_2\}} \sum_{l \in \{l_1, \dots, l_I\}} v(l, b, r), & \text{eğer } I \bmod 2 \neq 0 \end{cases} \quad (7)$$

ki burada $v(l, b, r)$, l görsel ipucunun b sınırı için r alanını sahip olarak oyladığını gösteren ikili bir fonksiyondur.

Bu basit birleştirme yönteminin sonuçlarına bakacak olursak (Şekil 13): Farklı ipuçları birleştiğinde, birleştirme yönteminin basitliği nedeniyle, sonuçların en iyi ipucunun başarısını geçemediği görülmüştür. Önümüzdeki dönemde, bilişimsel yöntemler iş paketinin bir parçası olarak, ipuçlarının birleştirilmesine yönelik daha uygun yöntemler kullanılacaktır.



(a) İç-alan görüntüleri.



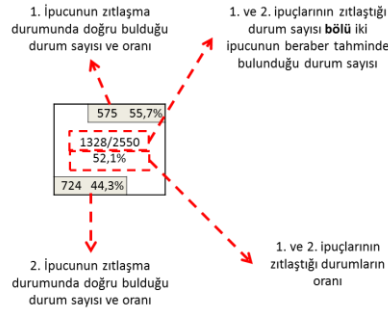
(b) Dış-alan görüntüleri.

Şekil 13. İpuçlarının birleştirilmesinin sınır sahipliği tahminine etkisi. (a) İç-alan görüntüleri için, (b) dış-alan görüntüleri için.

4.3 Görsel ipuçlarının sınır sahipliği konusunda zıtlaşması

Bizim için önemli bilgilerden bir diğeri, hangi ipuçlarının birbiri ile zıt sınır sahipliği yönleri tahmin ettiği ve bu tür zıtlaşmalarda hangi ipucunun tahmininin daha doğru olduğudur. Bu bilgi sayesinde, bilişimsel modelde zıtlaşan ipuçları daha doğru bir şekilde dikkate alınabilecektir.

Şekil 14'te sunduğumuz zıtlaşma matrisine göre, L-köşesi, T-köşesi ve eğrilik ipuçlarının birbirleri ile göreceli olarak uyumlu olduğunu; bu uyum oranının dış alan görüntülerinde azaldığını; alt alan ve kontrast görsel bilgilerinin genelde diğer ipuçları ile uyumsuz olduğunu görmekteyiz.



(a)

	L-köşe	T-köşe	Eğrilik	Alt-alan	Zıtlık
L-köşe		767 69.4%	796 73.0%	1252 32.7%	775 29.9%
T-köşe	1105/3184 34.7%		1091/5950 18.3%	3831/5986 64.0%	3029/5986 50.6%
Eğrilik	338 30.6%	295 27.0%		2579 67.3%	1813 70.1%
Alt-alan		816 37.9%	505 23.2%		582 17.0%
Zıtlık		2154/6622 32.5%	2176/6680 32.6%	3414/6680 51.1%	
		1338 62.1%	1671 76.8%	2832 83.0%	
		2291 35.8%	1496 24.6%		
		6392/11783 54.2%	4101 64.2%	6083/11783 51.6%	
			4587 75.4%	2348 39.2%	
			5986/11892 50.3%	3638 60.8%	

(b)

	L-köşe	T-köşe	Eğrilik	Alt-alan	Zıtlık
L-köşe		327 62.8%	558 73.2%	787 50.2%	583 45.4%
T-köşe	521/1134 45.9%		762/2505 30.4%	1567/2514 62.3%	1283/2514 51.0%
Eğrilik	194 37.2%	204 26.8%		780 49.8%	700 54.6%
Alt-alan		385 52.0%	225 37.6%		274 30.6%
Zıtlık		740/1809 40.9%	599/1815 33.0%	896/1815 49.4%	
		355 48.0%	374 62.4%	622 69.4%	
		1010 41.6%	1418 58.4%	1374 68.0%	
		2428/3956 61.4%	1418 58.4%	2021/3956 51.1%	
			856 42.1%	2032/3973 51.1%	
			1176 57.9%		

(c)

Şekil 14. Görsel ipuçlarının birbiri ile ne kadar zıtlıştığı. (a) Zıtlaşma matrisindeki rakamların anlamı. (b) İç-alan, (b) dış-alan görüntülerinde ipuçlarının nasıl zıtlıştığını gösteren zıtlaşma matrisi.

5. TEKRARLAMALI VEKTÖR OYLAMA YÖNTEMİ İLE SINIR SAHİPLİĞİ KESTİRİMİ



Proje kapsamında geliştirilen bilişimsel yöntemlerden ilki, Tekrarlamalı Vektör Oylama yöntemi, bu bölümde aktarılmaktadır. Bu bölümden aşağıdaki tez üretilmiş, ancak öğrencinin projeye katkı vermeye devam etmek istememesi nedeniyle bir yayına dönüştürülemediği.

- Özkan, B. 2014. "Estimating border ownership using iterative vector voting and Conditional Random Fields", Yüksek Lisans tezi, Bilgisayar Mühendisliği, ODTÜ.

5.1 Tensör Oylama

Tensör oylama yöntemi Medioni ve grubu tarafından (örn., Mordohai ve Medioni, 2006) yönelimli veya yönelimsiz, gürültü içeren görüntüler içerisindeki görsel yapıları bulabilmek için geliştirilmiş bir yöntemdir. Farklı görsel bilgilerin gösterimi ve etkileşimi için oturmuş bir yöntem olması sebebiyle tensör oylama, sınır sahipliği bilgisi bulmak için çok uygun bir yöntemdir. Sonuçların aynı görsel ipuçları için iyileşme göstermesi bu yargının doğruluğunu pekiştirmektedir.

Oylamada kullanılan tensörler, farklı boyutlarda olabilir. 2 boyutlu tensörleri, 2x2 matris veya iki boyutlu bir elips olarak ifade edebiliriz. Her tip tensör yalnızca kendi türüne ait olanlara oy verebilmekte, ancak kompozit bir tensör bu iki tür tensörden bir araya gelmektedir. Çubuk ve yuvarlak tensörün geometrik tanımlamaları Şekil 15'de belirtilmiştir.

Tensör tipi	Özdeğerler	Karesel ifade
 Çubuk Tensör	$\lambda_1=1 \quad \lambda_2=0$	$\begin{bmatrix} n_x^2 & n_x n_y \\ n_x n_y & n_y^2 \end{bmatrix}$
 Yuvarlak Tensör	$\lambda_1=\lambda_2=1$	$\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$

Şekil 15. Tensör türleri ve geometrik temsilleri

2 boyutlu bir tensör, özdeğer ($\lambda_{1,2}$) ve özvektörleri ($e_{1,2}$) cinsinden şu şekilde de tanımlanıp bileşenlerine ayrılabilir:

$$T = \lambda_1 e_1 e_1^T + \lambda_2 e_2 e_2^T = (\lambda_1 - \lambda_2) e_1 e_1^T + \lambda_2 (e_1 e_1^T + e_2 e_2^T). \quad (8)$$

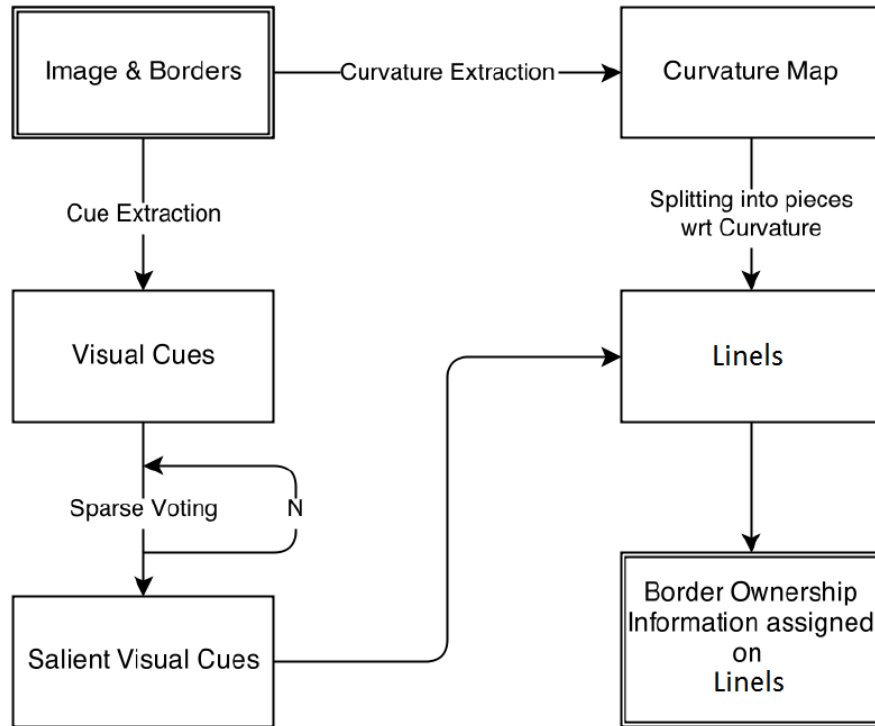
Oylama ise tamamen tensör cebirindeki toplama işlemine denktir, sadece bu işlemin hangi sınırlara dahil olduğunu biz belirlemekteyiz. Medioni, bu sınırı uzaklık ve açığa göre değişen bir fonksiyon olarak tanımlamıştır. Biz ise, aynı sınır üzerindeki tüm tensörleri oylamaya katmakta ve tek limiti uzaklık olarak tanımlamaktayız. Oylama limit fonksiyonu, belirtilen tanıma göre aşağıdaki forma sahiptir:

$$DF_{TV}(s, \kappa, \sigma) = \exp\left(-\frac{s^2 + c\kappa^2}{\sigma^2}\right), \quad (9)$$

ki burada s , tensörler arasındaki uzaklığı; κ , eğriliği; σ , oylamanın ölçeğini belirtmektedir ve c , bir sabittir.


5.2 Tekrarlamalı Vektör Oylama

Proje kapsamında Tensör Oylama (TO) yöntemi sınır sahipliği probleminin ihtiyaçları doğrultusunda değiştirilmiş ve tekrarlamalı (ing. iterative) bir versiyonu önerilmiştir: Tekrarlamalı Vektör Oylama – Iterative Vector Voting.



Şekil 16. Tekrarlamalı Vektör Oylama yöntemimizin genel hatları.

Yöntemimizde, eğrilik, T-köşesi, entropi, kontrast zıtlığı görsel ipuçları oluşturulmuş ve her bir görsel ipucunun oyunu temsil etmek için bir vektör oluşturulmuştur. Kontrast zıtlığı için oluşturulan vektör ve vektörün şiddeti Şekil 17’de örneklendirilmiştir.



Şekil 17. Sol: Bir kenar üzerinden bir kesit ve kenarın ayırdığı alanların ortalama parlaklık değerleri. Sağ: Bu kenarın sahibi konusundaki oyunu ve şiddetini belirten vektör.

Her görsel ipucu için benzer şekilde oy vektörleri çıkarılmakta, sonraki aşamada da bu oylar tensör oylama yöntemi kullanılarak birleştirilmektedir (Şekil 16). Oyların birleştirilmesi aşamasında, uzaklık ile birlikte oyların azalmaması için, tensör oylama yönteminde kullanılan azalma fonksiyonu (ing. decay function – bkz. Denklem (9)) aşağıdaki gibi değiştirilmiştir:

$$DF_{IVV}(\kappa, \sigma) = \exp\left(-\frac{c\kappa^2}{\sigma^2}\right), \quad (10)$$

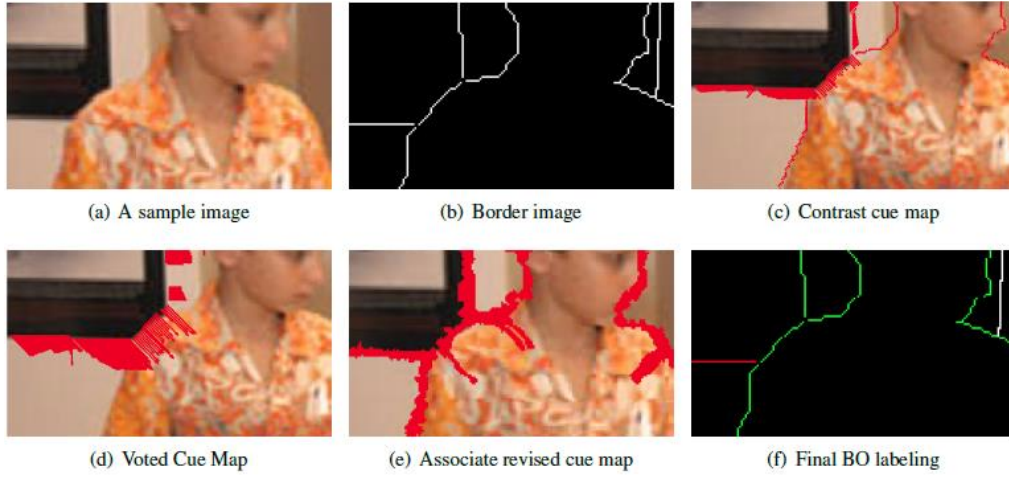
ki burada κ , eğriliği, σ , oylamanın ölçeğini belirtmektedir ve c , bir sabittir. Bu değişiklik sayesinde, tensör oylama alanı, Şekil 18’deki gibi olmuştur.



Şekil 18. Sol: Tensör oylama yöntemindeki tensör oylama alanı. Merkezden uzaklaştıkça, oylamaların birbiri üzerine olan etkisi azalır. Sağ: Önerdiğimiz tekrarlamalı vektör oylama yöntemi için oluşan oylama alanı. Oylama uzaklıkla azalmaz ve aynı yöndeki oylar birbirinin etkisini artırır.

5.3 Deneyler ve Sonular


Yöntemimizin ara aşamaları **Şekil 19**'da gösterilmiştir. Yöntemimiz ile elde ettiğimiz sonuçlar **Tablo 3** ve **Şekil 20**'de sunulmuştur. Sonuçlardan anlaşılmaktadır ki tekrar edildikçe doğruluk bir yere kadar artmakta, sonra düşmektedir. İdeal tekrarlama sayısının 3 olması gerektiği gözlemlenmektedir.



Şekil 19. Örnek bir görüntü üzerinden ara aşamaların gösterimi. (a) Girdi görüntü. (b) Görüntünün kenarları. (c) Görüntüden çıkan kontrast ipucu haritası. (d-e) Kontrasta göre oyların birleştirilmesi. (f) Sınır sahipliği tahmini (yeşil: doğru, kırmızı: yanlış).

Tablo 3. Farklı görsel ipuçları üzerinden yapılan tekrarlamalı vektör oylama yöntemimizin sonuçları. Tekrar edildikçe doğruluk bir yere kadar artmakta, sonra düşmektedir. İdeal tekrarlama sayısının 3 olması gerektiği gözlemlenmektedir.

Visual Cue	No of Iter.	2	3	4	5
T-junction		72,2%	73,1%	73%	71,8%
Curvature		57,4%	58%	56,7%	59,4%
Entropy		66,7%	71%	65,4%	58,3%
Contrast		64%	68%	64,2%	60,7%



Şekil 20. Örnek görüntüler için yapılan sınır sahipliği tahminleri. Yeşil: doğru tahminler. Kırmızı: Yanlış tahminler.

6. ŞARTLI RASTGELE ALAN İLE SINIR SAHİPLİĞİ KESTİRİMİ

Proje kapsamında geliştirilen Şartlı Rastgele Alan (ŞRA - ing. Conditional Random Field) yöntemi ve sonuçları, bu bölümde anlatılmıştır. Bu kapsamdaki çalışmalarımız, aşağıdaki yayınlara konu olmuştur:

- Akkuş, M. A., Olgunsoylu, S., Topuz, G., Kalkan, S. 2015. "Analysis of Visual Cues and Computational Models for Border Ownership", Computer Vision and Image Understanding, gönderildi.
- Özkan, B. 2014. "Estimating border ownership using iterative vector voting and Conditional Random Fields", Yüksek Lisans tezi, Bilgisayar Mühendisliği, ODTÜ.
- Özkan, B., Kalkan, S. 2013. "Extraction of Border Ownership Information by Conditional Random Field Model", IEEE 21st Conference on Signal Processing and Communication Applications (SIU), Girne, KKTC.

6.1 Yöntem

Sınır sahipliği bulma algoritmamız temel olarak, T ve L köşeleri yardımıyla sınır sahipliği önsel bilgisi çıkarılan test verisinin sınır sahipliği istatistiki olasılığının, sınırları hazır olarak sahibi olan alanlara atanmış eğitim veri seti ile oluşturulan Şartlı Rastgele Alan (ŞRA) modeli sayesinde artırılmasına dayanır. Bu model, kontrast oranı ve entropi, T ve L köşeleri ile alt alan olmak üzere iki spektral ve üç şekilsel ipucu üzerine kurulmuştur.

Çalışmada, görüntü alanları sınır sahipliği bilgisinin olasılık dağılım fonksiyonu bir Gibbs dağılımı şeklinde modellenmekte olup, bu ikili Şartlı Rastgele Alan (ŞRA) modelini tekli ve ikili klik potansiyellerinin toplamları oluşturmaktadır. Bu potansiyel fonksiyonları, grafik üzerindeki tek bir düğümün veya beraber komşu iki düğümün veri-etiket ilişkisini nasıl etkilediklerini gösterir. Potansiyel parametrelerinin tahmini sonrasında bu model yardımıyla ardıl olasılıkların hesaplanması mümkün hale gelir. Sınır sahipliği için geliştirilen ŞRA modeli şu şekilde formülize edilebilir:

$$P(R|x, \sigma) \rightarrow - \sum V1(Ri, x, \sigma) - \sum V2(Ri, Rj, x, \sigma). \quad (11)$$


Her ikili ŞRA modelinde olduğu gibi modelimizde, veriye (x) ait sonsal sınır sahipliği olasılığının değeri (R) hesaplanırken, tüm tekli (V1) ve ikili (V2) potansiyellerin toplamı bulunur ve bu toplamın negatif değerinin üsteli normalize edilerek hesaplanır. Potansiyeller, tek bir görüntü alanı ile iki komşu görüntü alanının verinin etiketlenmesinde nasıl rol aldığını, σ parametreleri ile belirler.

Çalışmada kullanılan sınır sahipliği modeli, iki düğümden (node) oluşan sade bir grafiktir. Bu modelin düğümleri, ortak bir sınıra sahip iki komşu görüntü alanını tanımlar. Sınır sahipliği ilişkisi komşu iki alan üzerinden doğan bir ilişki olduğundan dolayı, bu basit grafik, sınır sahipliği modeli için yeterlidir. Her iki komşu görüntü alanı, içeriksel ilişkileri doğrultusunda aralarında bulunduktan sınır için sahiplik değerini beraber belirler, bu sebeple bir ŞRA modeli, sınır sahipliği problemini çözmek için en uygun yöntem olarak gözükmektedir. Bu içeriksel ilişkiler için en ayırt edici öznitelikleri kullanmak, daha iyi bir model kurmamızı sağlamaktadır. Grafik düğüm ve kenarları için kullanılan bu öznitelikler, model parametrelerinin hesaplanması amacıyla tekli ve ikili potansiyellere dönüştürülür.


Sınır sahipliği bulma algoritmamız, üç ana basamaktan oluşmaktadır. Bunlar sırasıyla:

1. Test ve eğitim veri seti görüntülerindeki tüm düğüm ve kenar özniteliklerinin çıkarılması, (Bu özniteliklerden T ve L köşeleri, test resmi için ilk etiketlendirme amacıyla da kullanılacaktır.)
2. Eğitim veri seti ile ŞRA modelinin oluşturulması,
3. Test görüntüsünden çıkarılan sınır sahipliği önsel olasılıklarının ŞRA modeli ile iyileştirilmesidir.

Algoritmanın ilk adımında, sınırları işaretlenmiş ve etiketlenmiş test görüntüsünde sınırlar üzerindeki T ve L köşeleri çıkarılır. Bulunan T ve L köşeleri yönleri, üzerinde buldukları sınırın hangi görüntü alanına ait olduğunu belirlemede kullanılmaktadır. Örnek bir görüntü üzerinde bu köşelerin sınırlar üzerinde nerelere denk geldiği, türleri ve yönleri ile Şekil 21 üzerinde detaylı olarak gösterilmiştir. L köşesi yönündeki alanlar ile T köşesi zıt yönündeki alanlar bize çoğunlukla sınır sahibi alanı vermektedir. L köşesi, 2 kenar kesişiminden oluşmakta olup, aralarındaki açı yaklaşık olarak en fazla 100-110 dereceyi geçmemelidir. T köşesi ise, birbirine dik 2 kenardan oluşup 3 ayrı bölge arasında sınır oluşturmaktadır. Bu çalışmada yapılan veri analizleri ve ilgili literatürdeki çalışmalar (örn., Leichter ve Lindenbaum, 2009) özellikle T köşesinin performans değerlerini önemli ölçüde arttırdığını göstermektedir. Görüntü alan sınırları hazır olarak mevcut olduğundan, bu sınırlar üzerindeki T ve L köşelerini bulmak için basit morfolojik operasyonlar yeterli olmuştur. Görüntü alan sınırlarının işaretlenmiş olduğu örnek bir veri üzerindeki T ve L köşeleri, Şekil 22'da gösterilmiştir. Bu örnek resim üzerinde T köşeleri yeşil, L köşeleri ise kırmızı renkte işaretlenmiştir.



Şekil 21. T ve L köşeleri hakkında görsel bilgi



Şekil 22. T ve L köşeleri örnek sonucu

T köşelerinin L köşelerine oranla daha ayırt edici bir öznelik olmasından dolayı, test ve eğitim verisindeki sınırlara görüntü alanı aidiyet değeri atanırken öncelikle T köşeleri göz önünde bulundurulmakta olup, T köşelerinden aidiyet değeri atanamaması durumunda L köşeleri üzerinden çıkarım yapılmaktadır. Özetle, iki komşu alan arasındaki sınır, T köşe sayısı fazla olan alana atanmakta olup, bu köşe sayısının eşitliği doğrultusunda L köşe sayısına bakılmaktadır.

Köşe sayısına göre önsel olasılıkları atanan ŞRA modelinin eğitimi için düğüm ve kenar öznitelikleri çıkarılır. Düğüm öznitelikleri ve özniteliklerin ayırt edici yönleri şunlardır:

- **Kontrast oranı:** Sınır etrafındaki görüntü alanı parçasının kontrast ortalama değerinin tüm görüntü alanının kontrast ortalama değerine oranıdır.
- **Entropi:** Görüntü alanı ortalama entropi değeridir. Çalışma süresince yapılan deneysel çalışmalar göstermiştir ki, arka plandaki görüntü alanları öndeki alanlara göre genelde daha az doku ve rastgelelik içermektedir.
- **Paralel T köşe sayısı:** Görüntü alanı sınırları üzerinde bulunup, geniş kenarı sınır ile paralel olan toplam T köşe sayısıdır.

- **L köşe sayısı:** Alan sınırları üzerinde bulunan toplam L köşe sayısıdır. L köşeleri, genellikle önde bulunan, yani sınırın sahibi olan görüntü alanları üzerinde bulunmakta olup, sınır sahibi alanların ayırt edici bir özelliğidir.
- **Alt alan özelliği:** Görüntü alanının görüntü üzerindeki pozisyonu, sınır sahipliği için bir diğer önemli şekilsel ipucudur. Üstte kalan, yani sınır sahibi olan alan, genellikle diğerine oranla, görüntüde dikey ekseninde daha aşağıda bulunur. Bu özellik, çalışmamızda, görüntü alanının en düşük dikey koordinatının resmin boyuna oranı olarak alınarak normalize edilmiştir.

Kenar özniteliği olarak ise, çoğu ŞRA modelinde de kullanıldığı üzere, kenarın iki ucundaki düğüm öznitelikleri kullanılmıştır. Model parametre tahmininden sonra, değişkenlerin ortak olasılığının en yüksek değerini bulabilmek için düğüm çözme (ing. decoding) işlemi uygulanır. Test aşaması olan düğüm çözme işlemi sonucunda görüntü alanlarının yen, sınır sahipliği bilgileri edinilmektedir.

6.2 Deneyler ve Sonuçlar

Algoritma testi sonucunda elde edilen performans değerleri **Tablo 4**'te görülebilir. Sonuçlara bakıldığında, iç-alanda başarı oranının dış-alana göre daha yüksek olduğu görülmektedir. Bunun en önemli nedeni, iç-alanda T ve L köşelerinin daha fazla olması ve düzenli yapıların sınır sahipliğinde T ve L köşelerinin daha belirleyici/düzenleyici olmasıdır. Örnek bir resim üzerinde algoritma sonucu ise **Şekil 23**'te görülebilir. Bu resim üzerinde sınır sahipliği doğru görüntü alanına atanan sınırlar yeşil, yanlış atananlar ise kırmızı olarak renklendirilmiştir.

Tablo 4. ŞRA yöntemi ile elden edilen iç-alan ve dış-alan başarımların yüzdeleri.

	Başarım (%)
İç-Alan	78.9
Dış-Alan	70.7
Ortalama	74.8



Şekil 23. ŞRA yönteminin örnek çıktısı. Kırmızı yanlış, yeşil doğru sınır sahipliği tespitlerini

göstermektedir.

7. LİTERATÜRDEKİ BİLİŞİMSEL YÖNTEMLERİN KIYASLANMASI

Proje kapsamında literatürde önerilmiş bilişimsel yöntemler gerçekleştirilmiş ve bu bölümde, bu yöntemlerin kıyaslaması yapılmaktadır. Bu kapsamdaki çalışmalarımız, aşağıdaki yayınlara konu olmuştur:

- Akkuş, M. A., Olgunsoylu, S., Topuz, G., Kalkan, S. 2015. "Analysis of Visual Cues and Computational Models for Border Ownership", Computer Vision and Image Understanding, gönderildi.

7.1 Kıyaslanan Yöntemler

Kıyaslanan yöntemler aşağıda ayrı alt-bölmeler altında özetlenmiştir.

7.1.1 Naif İpucu Birleştirme

Naif İpucu Birleştirme, Bölüm 4'te aktarılan görsel ipuçlarını birleştirme yöntemidir. Kolay erişim için tekrarlamak gerekirse, özetle, görsel ipuçlarının kestirimlerinin en fazla oylama yöntemi ile birleştirilmesidir. Bir başka ifade ile, b sınırına ait alan, $\hat{r}_{comb}(b)$, en çok oy alan olarak hesaplanır:

$$\hat{r}_{comb}(b) = \arg \max_{r \in \{r_a, r_b\}} \sum_{c \in C} 1_{[\hat{r}_c(b)=r]}, \quad (12)$$

ki burada C , birleştirilecek ipuçları kümesini göstermektedir; $1_{[\hat{r}_c(b)=r]}$ ise, c ipucunun b sınırı üzerindeki tahmini r alanı ise 1, aksi halde 0'dır.

7.1.2 Zıtlık Çevre Modülasyonu

Sakai vd. (2012), şekil-alan ayrımı için zıtlık bilgisini belirli bölgeler içerisinde simetrik olmayan bir biçimde birleştiren bir yöntem önermiştir. Yöntem, üç aşamadan oluşmaktadır: (i) Gabor filtreleri kullanarak zıtlık belirleme, (ii) çevresel birleştirme (ing. surround modulation), (iii) sınır sahipliği belirleme. Yöntemde, tüm görüntü (I), yapay sinir hücreleri matrisi ile modellenmektedir, öyle ki, bir piksel 0.125° görsel açıya denk gelmektedir. Yöntemde, i aşamasındaki bir sinir hücresinin ori yönelimindeki tepkisi $O_{ori}^i(x, y)$ ile gösterilmektedir, ki burada (x, y) hücrenin 2B Kartesyen koordinatını ifade etmektedir.

Zıtlık Belirleme

İlk aşamada, görüntüde zıtlık hesaplanır ve normalize edilir. Zıtlık hesabı, pikselleri farklı eğilimlerdeki Gabor filtreleri ile evriştirerek (ing. convolution) elde edilir:

$$T_{ori}(x_0, y_0) = \begin{cases} I_0 * G_{ori}, & T_{ori} > 0 \\ 0, & \text{değilse} \end{cases} \quad (13)$$

ki burada I_0 , merkezi (x_0, y_0) olan bir alt-pencereyi göstermektedir. G_{ori} Gabor filtresinin eğilimi ori ; standart sapması, dalga boyu ve fazı sırasıyla 1.25, 1.25 ve 90 derecedir. Sakai vd. tarafından sekiz farklı eğilim (0, 45, 90, 135, 180, 225, 270 ve 315 derece) değerleri kullanılmıştır. Zıtlık hesabından sonra, aşağıdaki gibi normalize edilir:

$$D_{ori}(x_0, y_0) = \frac{c_1 T_{ori}(x_0, y_0)}{1 + c_2 T_{all}(x_0, y_0)}, \quad (14)$$

ki c_1, c_2 , değerleri 10.0 ve 0.01 olan iki sabittir; $T_{all}(x_0, y_0)$ ise yazarlar tarafından aşağıdaki gibi tanımlanmıştır:

$$T_{all}(x_0, y_0) = \sum_{ori; (x,y) \in I_1} I_1(x, y) * T_{ori}(x, y), \quad (15)$$

ki burada I_1 , merkezi (x_0, y_0) olan, Gauss dairesel bir alan (standart sapması 0.75 derecedir). Hücrenin tepkisi, hücrenin komşuluğu içindeki tüm sekiz eğilimdeki zıtlık tepkisi ile normalize edilir, ve lineer olmayan bir sıkıştırma fonksiyonu ile sıkıştırılır:

$$O_{ori}^1(x_0, y_0) = s(D_{ori}(x_0, y_0)), \quad (16)$$

ve $s(x)$ fonksiyonu aşağıdaki gibi tanımlanmıştır:

$$s(x) = \frac{k}{1 + \exp(c_{slope}(c_{thres} - x))}, \quad (17)$$

öyle ki c_{thres} ve c_{slope} sabitleri yazarlar tarafından 9.0 ve 2.0 olarak seçilmiştir.

Çevresel Birleştirme

Yöntemin ikinci aşamasında, eş-yönelime sahip sinyaller bastırılır, farklı-eğilime sahip sinyaller ise birbirini besler:

$$O_{ori}^2(x_0, y_0) = (F_i * O_{cross}^1)(x, y) - (S_i * O_{iso}^1)(x, y), \quad (18)$$

ki burada F_i ve S_i , besleyen (ing. facilitatory) ve bastıran (ing. suppressive) bölgeleri ifade etmektedir, ve O_{cross}^1, O_{iso}^1 aşağıdaki gibi tanımlanmıştır:

$$O_{cross}^1(x, y) = \sum_{o \notin \{ori, ori+180\}} O_o^1(x, y) , \quad (19)$$

$$O_{iso}^1(x, y) = \sum_{o \in \{ori, ori+180\}} O_o^1(x, y) . \quad (20)$$

Sakai vd. (2012) tarafından her bir bölge, 2 boyutlu bir Gauss olarak düşünülmüştür, ki merkezleri ve standart sapmaları fizyolojik değerler içerisinde rastgele seçilmiştir. 40 adet besleyen ve bastıran bölge vardır. Sekiz farklı eğilimde 40 adet bölge, bir nokta için toplamda 320 adet hücre tepkisi anlamına gelmektedir.

Sınır Sahipliğini Belirleme

Bastırma ve besleme işlemlerinden sonra, son aşamada sınır sahipliği bilgisi belirlenir. (x_0, y_0) noktasının tepkisi aşağıdaki gibi hesaplanır:

$$O_{ori,i}^3(x_0, y_0) = O_{ori}^1(x_0, y_0) \left(O_{ori}^1(x_0, y_0) + k_{nat} O_{ori,i}^2(x_0, y_0) \right) , \quad (21)$$


ki burada k_{nat} çevresel birleştirmenin katkısını kontrol etmektedir ve Sakai vd. (2012) çalışmasında 1.0 olarak belirlenmiştir. $O_{ori,i}^3(x_0, y_0) < 0$ ise, $O_{ori,i}^3(x_0, y_0) = 0$ olarak alınır. Sınır sahipliğinin şiddeti, sekiz yönelimde, her bir F, S bölge çifti için hesaplanır:

$$BO_{dir,i}(x_0, y_0) = O_{ori,i}^3(x_0, y_0) - O_{ori+180,i}^3(x_0, y_0) . \quad (22)$$

Her noktadaki 320 hücrenin tepkisi üzerinden vektör toplama işlemi yapılarak o noktadaki son sınır sahipliği bilgisi belirlenir.

7.1.3 Şekilcikler Üzerinde Şartlı Rastgele Alan

Ren vd. (2006) tarafından önerilen Şartlı Rastgele Alan (ŞRA), Bölüm 6'da anlatılan yöntem ile çok benzerdir. Aradaki en belirgin fark, yerel görsel ipuçları yerine, **Şekil 24**'teki gibi şekilcik (ing. shapeme) olarak isimlendirdikleri yerel öznitelikler üzerinden yerel kestirimleri yapmaları ve bu kestirimleri ŞRA ile düzenlemeleridir.



Şekil 24. Şekilciklerden bir kısmının görsel gösterimi. Kaynak: Ren vd. (2006).

7.1.4 Görsel İpuçları Üzerinde Şartlı Rasgele Alan

Görsel ipuçları üzerinden ŞRA uygulanması, projenin özgün katkılarından bir tanesidir ve Bölüm 6'da anlatılmıştır.

7.1.5 Spektral Öznitelikler Üzerinden Destek Karar Makineleri

Ramenahalli vd. (2012), bir sınırın iki yanındaki alana ait spektral öznitelikler çıkarılmasını ve bu öznitelikler üzerinden Karar Destek Makinesi (KDM – ing., Support Vector Machines) eğitilmesini önermiştir. Bu yöntemde, sınır üzerindeki bir nokta (x, y) üzerine oturtulan $N \times N = 36 \times 36$ ebatında pencere \mathbf{p} üzerinden kestirim yapılır. Bu pencereler seçilirken, bir yarısında bir alanın, diğer yarısında ise diğer alanın olması sağlanır. Daha sonra, eğitim aşamasında, şeklin alt tarafta, alanın ise üst tarafta olacak şekilde pencerenin döndürülmesi sağlanır. Bunu sağladıktan sonra, (şekile veya alana ait) bir bölgenin sınıra paralel eğilimli enerjisi, aşağıdaki gibi hesaplanır:

$$E_f^{\parallel}(u, y) = \frac{1}{K} \sum_{y=0}^{K-1} \left| \mathbf{P}_f^{\parallel}(u, y) \right|^2, \quad (23)$$

burada y sınıra dik olarak değişmektedir, ve $\mathbf{P}_f^{\parallel}(u, y)$, sınıra paralel yönde alınan 1 boyutlu ayrık Fourier dönüşümüdür. Benzer bir biçimde, sınıra dik enerji; diğer alan içinse hem paralel hem dik enerji hesaplanır. Yani, toplamda, sınırın iki yönüne ait hem paralel hem de dik ortalama enerjiler hesaplanır. Bu dört değerın yanyana getirilmesi ile de öznitelik vektörü oluşturulur. Bu öznitelik vektörü üzerinden de KDM eğitilir.

7.1.6 Öznitelikler Üzerinden AdaBoost Yöntemi

Literatürde Chen vd. (2013) AdaBoost yöntemini yerel ipuçları (pozisyon, sıklık, görünüm, köşe, zıtlık, şekil) ve alanların semantik bilgisi (bknz. **Şekil 25**) üzerinde çalıştırmıştır. Yazarlar göstermiştir ki semantik bilgi en belirleyici ipucudur (%91.67 başarımlı sağlamaktadır) ve diğer yerel ipuçlarının pek bir katkısı olmamaktadır (başarımlı %92.53'e çıkmaktadır).



Şekil 25. Chen vd. (2013) tarafından kullanılan semantik bilgiler.

Proje kapsamında, AdaBoost yöntemini semantik bilgi gibi çok üst seviye bir bilgi olmadan, tamamen yerel ipuçları ile eğittik. İpuçları olarak, Bölüm 4'te kullanılan ipuçları kullanılmıştır, ve bunların üzerine AdaBoost yöntemi (**Şekil 26**'deki gibi) eğitilmiştir.

girdi: Eğitim kümesi: $\{(x_i, l_i)\}$, $i = 1, \dots, N$, öyle ki pozitif örnekler için $l_i = 1$, negatifler için ise $l_i = 0$.
çıkış: Zayıf sınıflandırıcıların birleşiminden oluşan güçlü sınıflandırıcı, $h(x)$.

1 - Örneklerin ağırlıklarına ilk değerlerini ver:

$$w_{1,i} = \frac{1}{2m} \text{ pozitif örnekler için, ve } w_{1,i} = \frac{1}{2o} \text{ negatif örnekler için.}$$

2 for $t = 1$ 'den T 'e kadar do

3 - Ağırlıkları w_t toplamı 1 olacak şekilde normalize et:

$$\hat{w}_{t,i} = \frac{w_{t,i}}{\sum_{j=1}^n w_{t,j}}. \quad (1)$$

4 for $f \in \mathcal{F}$, tüm öznitelikler içindeki her bir öznitelik için do

- Sadece f özniteliğinden zayıf sınıflandırıcı h_f öğren. - Sınıflandırıcının hatasını hesapla:

$$\epsilon_f = \sum_{i=1}^n \hat{w}_{t,i} |h_f(x_i) - l_i|. \quad (2)$$

5 - Zayıf sınıflandırıcılar, $h_f, \forall f \in \mathcal{F}$, arasından, en az hataya (ϵ_t) sahip olanı seç:

$$h_t = \arg \min_{f \in \mathcal{F}} \epsilon_f. \quad (3)$$

- Ağırlıkları güncelle:

$$w_{t+1,i} = \hat{w}_{t,i} \left(\frac{\epsilon_t}{1 - \epsilon_t} \right)^{e_i}, \quad (4)$$

öyle ki, x_i doğru sınıflandırılmışsa $e_i = 1$, aksi halde 0'dir.

6 - Nihai sınıflandırıcı, zayıf sınıflandırıcıların birleşimi olarak şu şekilde belirlenir:

$$h(x) = \begin{cases} 1 & \text{eğer } \sum_{t=1}^T \alpha_t h_t(x) \geq \frac{1}{2} \sum_{t=1}^T \alpha_t \text{ ise,} \\ 0 & \text{aksi halde} \end{cases} \quad (5)$$

öyle ki $\alpha_t = \log \frac{1-\epsilon_t}{\epsilon_t}$.

Şekil 26. AdaBoost sınıflandırıcı.


7.2 Deneyler ve Sonular

Literatürdeki alıřmalar önerdikleri yöntemlerin önemli parametrelerini detaylı bir şekilde irdelenmemiřtir. Proje kapsamında yaptığımız detaylı incelemenin bir parası olarak, ilk önce, yöntemlerin en iyi alıřtığı parametreler belirlenmiřtir.

7.2.1 Yöntemlerin En İyilenmesi

En İyileme: Spektral Öznitelikler üzerinden Karar Destek Makineleri

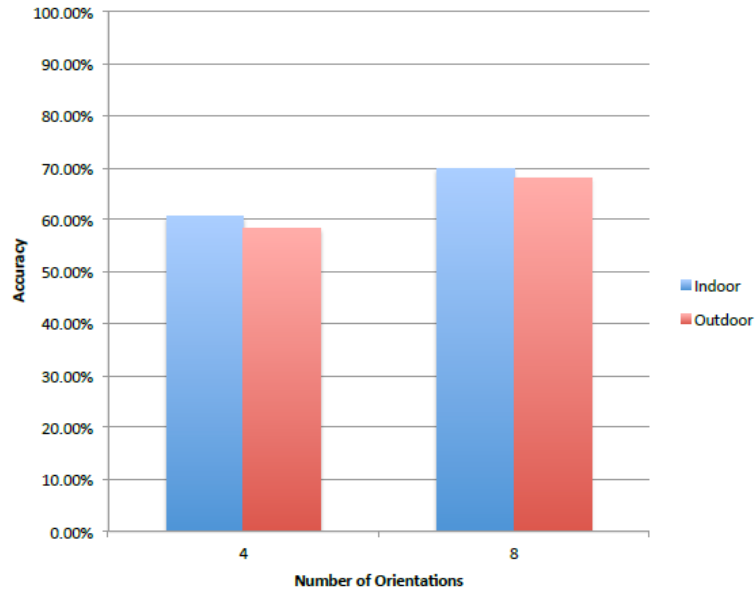
Bu yöntemin en önemli parametresi, spektral özniteliklerin ıkarıldığı pencerenin ebatıdır. Ramenahalli vd. (2012), yeterli dayanak sunmadan pencere boyutu olarak 36×36 seçmiřtir, biz ise farklı pencere ebatlarının performan üzerindeki etkisini incelemekteyiz. **Şekil 27**'de sunulan sonuçlara göre, hem iç-alan görüntülerinde hem de dış-alan görüntülerinde 36×36 ebatının en iyi değeri verdiđi gözlenmiřtir, bu da Ramenahalli vd. (2012) tarafından yapılan ebat tercihini dođrulamaktadır.



Şekil 27. Spektral Öznitelikler üzerinden Karar Destek Makineleri yönteminde pencere ebatının performansa etkisi.


En İyileme: Zıtlık Çevre Modülasyonu

Bölüm 7.1.2'de aktarıldığı gibi, bu yöntemde Gabor filtreleri kullanarak farklı eğilimlerde zıtlık değışimi hesaplanır. Gabor filtelerinin ebatı ve eğilimleri, performansı etkileyebilecek önemli faktörler olarak göze arpmaktadır. Ayrıca, çevre modülasyonunun katkısı k_{nat} sabiti (Sakai vd. (2012) tarafından 1 olarak alınmiřtır) tarafından kontrol edilmektedir ve bu sabitin farklı değerlerinin performans üzerindeki etkisi incelenmelidir.




Şekil 28. Zıtlık Çevre Modülasyonu yönteminde Gabor filtresinin kullandığı eğilim sayısının etkisi.

Gabor filtrelerin eğilim sayısının ve ebatının etkisi sırasıyla **Şekil 28** ve **Şekil 29**'da sunulmuştur. Bu değerlere göre, eğilim sayısının 8, filtre ebatının ise 24 olması en iyi performansı sağlamaktadır. Ayrıca **Şekil 30**'da sunulan değerlere göre, k_{nat} sabiti için en uygun değer 1 olduğu teyit edilmiştir.



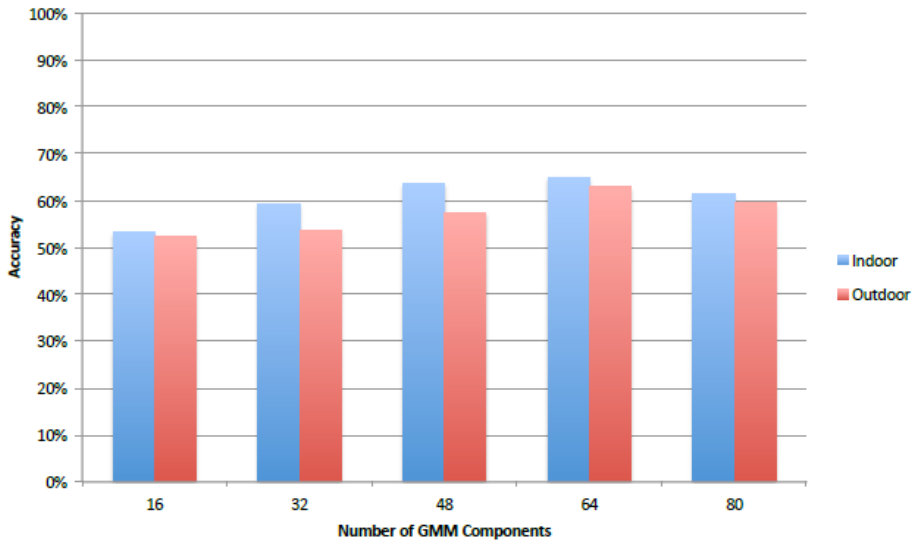
Şekil 29. Zıtlık Çevre Modülasyonu yönteminde Gabor filtrelerinin ebatının performansa etkisi.



Şekil 30. Zıtık Çevre Modülasyonu yönteminde çevre modülasyonunun performansa etkisi.


En İyileme: Şekilcikler Üzerinde Şartlı Rastgele Alan

Bu yöntemde en kritik parametrelerden bir tanesi, şekilciklerin sınıflandırılmasında kullanılan Gaussian Mixture Model (GMM) sayısıdır. **Şekil 31**'de sunulan değerlere göre, GMM sayısının 64 olması en iyi başarıyı sağlamaktadır.



Şekil 31. Şekilcikler Üzerinde Şartlı Rastgele Alan yönteminde Gaussian Mixture Model sayısının performansa etkisi.

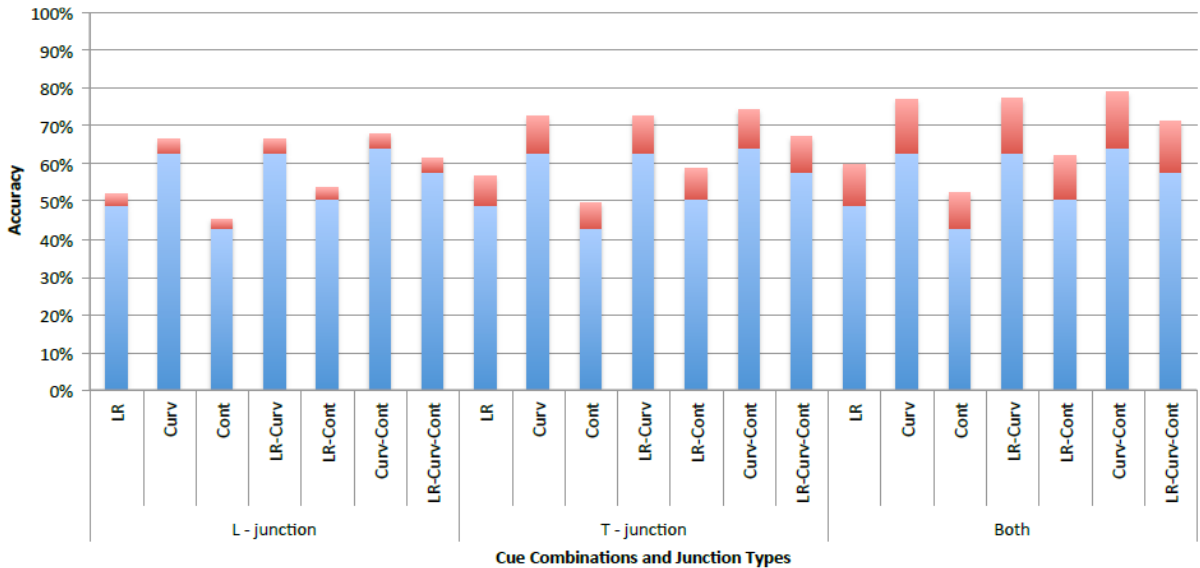
Ayrıca, köşe türlerinin Şartlı Rastgele Alan yönteminde tutarlılığı artırmak için ne kadar etkisi olduğunu incelediğimizde (**Şekil 32**), T köşelerinin daha önemli olduğu, T ve L köşelerini beraber kullanınca en iyi performansın elde edildiği görülmüştür.

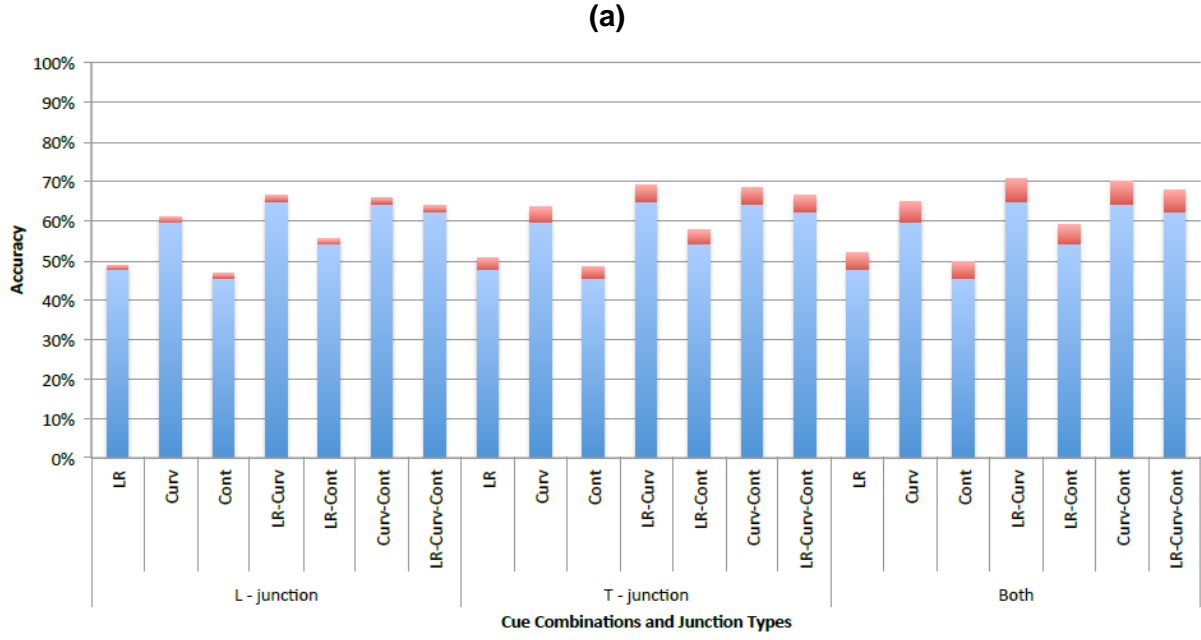


Şekil 32. Şekilcikler Üzerinde Şartlı Rastgele Alan yönteminde köşe türlerinin performansa etkisi

En İyileme: Görsel İpuçları Üzerinde Şartlı Rastgele Alan

Hangi görsel ipuçlarının, hangi köşeler ile daha iyi performans verdiğini incelediğimizde (**Şekil 33**), iç-alanda T ve L köşelerinin eğrilik ve zıtlık ile en iyi performansı verdiği, dış-alanda ise T ve L köşelerinin alt-alan ve eğrilik ile daha iyi sonuç verdiği gözlenmektedir.





Şekil 33. Görsel İpuçları Üzerinde Şartlı Rastgele Alan yönteminde köşe türlerinin ve görsel ipuçlarının performansa etkisi. (a) İç-alan. (b) Dış-alan.

7.2.2 Yöntemlerin Kıyaslanması

Yöntemlerin kritik parametrelerini de belirledikten sonra, veriseti üzerinde tüm sonuçları irdeleyebiliriz. **Tablo 5**, yöntemlerin iç-alan ve dış-alan başarımları listelemektedir. Bu sonuçlara göre, görsel ipuçları üzerinden ŞRA yöntemi en iyi sonucu üretmektedir.

Tablo 5. Yöntemlerin iç-alan ve dış-alan başarımları.

	İç-alan	Dış-alan	Toplam
Naif ipucu birleştirme	72.5%	68.7%	70.6%
Spektral üznitelikler üzerine KDM	73.2%	66.8%	70.1%
Zıtlık Çevre Modülasyonu	69.7%	68.1%	68.8%
AdaBoost	72.4%	69.2%	70.8%
Şekilcikler üzerine ŞRA	75.5%	70.5%	73.0%
Görsel ipuçları üzerine ŞRA	78.9%	70.7%	74.8%

8. SINIR SAHIPLİĞİNİ KULLANARAK GÖRSEL BİLGİYİ İYİLEŞTİRME

Projenin hedeflerinden bir tanesi, sınır sahipliği bilgisinin görsel bilgiyi iyileştirdiğini göstermek idi. Bu kapsamda yaptığımız çalışmaları bu bölümde aktarmaktayız. Bu kapsamdaki çalışmalarımız, aşağıdaki yayınlara konu olmuştur:

- Akkuş, M. A. 2014. “Analysis of border ownership cues and improvement of depth prediction using border ownership”, Yüksek Lisans tezi, Bilgisayar Mühendisliği, ODTÜ.


8.1 Yayınım teknikleri ile kenarlardaki stereo ve optik akış bilgisinin ilgili alana aktarılması

Bu kolda, görüntü yayılımı (ing. image diffusion – Weickert, 1998) tekniklerinden esinlenerek, kenarlardaki doğru ve güvenilir bilgiyi, kenara ait olan alana yayma yöntemi geliştirilecektir. Yayınım yöntemleri genel olarak bir noktada biriken yoğunluğun zaman içerisinde çevresinde belirli bir yönde (yoğunluğun yönüne uygun olsun veya olmasın) bir akış oluşturacağı fiziksel olgusuna dayanmaktadır (Weickert, 1998):


$$\frac{\partial I}{\partial t} = \text{div}(D \cdot \nabla I), \quad (24)$$

ki burada I , görüntüyü, D yayılımı control eden tensörü ve $\text{div}(\cdot)$ ise yayılma (ing. divergence) operatörünü ifade etmektedir. Buradaki D tensörü sayesinde yayılım görüntünün meyiline (∇I) farklı bir yönde sağlanabilir. Bu sayede, kenardaki değerli bilgi, ilgili alana doğru yayılabilir.


Proje kapsamında, içeriye doğru aktarma yapmak için Telea'nın iç-boyama (ing. Inpainting) yöntemini baz aldık (Telea, 2004) ve onu, renkler arası farkları dikkate alarak, derinliği içeriye boyayan bir yöntem haline getirdik. Elde ettiğimiz sonuçlar (**Şekil 34**) ümit verici olmadığı için bu yönde projede ilerlenmemiştir.




(a) Örnek görüntü




(b) Görüntünün bilinen derinlik haritası.



(c) Kenarlardaki derinlik bilgisi



(d) Kenar yüzeydeki içeri doldurulan derinlik



(e) Üst yüzeydeki içeri doldurulan derinlik


Şekil 34. Örnek bir görüntüden elde edilen içeriye doldurma sonuçları.

8.2 Markov Rastgele Alan (MRA) yöntemi ile bölütleme ve sınır sahipliği kestirimini beraber çözmeye

Proje kapsamında, sınır sahipliği bilgisinin bölütleme ile eş-çözümünün mümkün olup olmadığını araştırdık. İnsan görme sisteminde ikisi de ilk aşamalarda işlendiği ve birbirini beslediği için, bunun değerli bir katkı olduğu düşünülmüştür.

Markov Rastgele Alan (, ing. Markov Random Field) ile imge bölütleme ve sınır sahipliği tespiti problemlerini eş zamanlı çözmek amacı ile **Şekil 35b**'deki gibi bir yöntem kullanılmıştır. Bu grafikte, komşu iki süper piksel, s_i ve s_j arasındaki sınır p_{ij} kırmızı düğüm ile gösterilmiştir. Mavi düğümler alan düğümleri, kırmızı düğümler sınır düğümleridir ve veri terimi hem mavi hem de kırmızı düğümleri içermektedir. Akıcılık (ing. smoothness) teriminde ise süper pikseller arasındaki komşuluk ilişkisinin yanı sıra, herbir sınır ile o sınıra komşu olan süper pikseller arasındaki ilişki yer almaktadır. Enerji fonksiyonu aşağıdaki gibidir:

$$\begin{aligned}
U(w) = & \sum_{s_i \in S} \psi_i(s_i) + \sum_{p_{ij} \in P} \psi_i(p_{ij}) + \sum_{s_i \in S, s_j \in N_{s_i}} \psi_{ij}(s_i, s_j) \\
& + \sum_{s_i \in S, s_j \in N_{s_i}} \psi_{ij}(s_i, p_{ij}) + \psi_{ij}(s_j, p_{ij}).
\end{aligned} \tag{25}$$



Şekil 35. (a) MRA ile Bölütleme Yapısı (b) MRA ile Bölütleme ve Sınır Sahipliği Tespiti Yapısı (en iyi renkli görünür).

Bu formülasyon MRA ile Bölütleme ve Sınır Sahipliği Tespiti Temel ($MRABSS_{temel}$) olarak adlandırılmıştır. Bu yöntem, sınır düğümlerinin komşu oldukları alan düğümlerinden farklı etiketleri alabilmesine izin vermektedir. Sınır düğümlerinin komşu alan düğümlerinden birisinin etiketini almasını sağlamak amacı ile MRA enerjisi güncellenmiştir. Bu amaçla, enerji fonksiyonunda sınır düğümlerine ait very terimlerini temsil eden ikinci terim sıfır olarak belirlenmiştir. Bu durumda sınır düğümlerinin etiketlenmesi sadece akıcılık terimine göre belirlenmektedir. Sınırın düğümünün, komşu alan düğümlerinden hangisinin etiketini alacağını belirlemek üzere, kontrast bilgisi kullanılmış ve MRA enerjisi aşağıdaki gibi güncellenmiştir:

$$U(w) = \sum_{s_i \in S} \psi_i(s_i) + \sum_{s_i \in S, s_j \in N_{s_i}} \psi_{ij}(s_i, s_j) \tag{26}$$

$$+ \sum_{s_i \in S, s_j \in N_{s_i}} [c_{s_i, p_{ij}} \times \psi_{ij}(s_i, p_{ij}) + c_{s_j, p_{ij}} \times \psi_{ij}(s_j, p_{ij})].$$

Bu formülde, $c_{s_i, p_{ij}}$, süper piksel s_i ile kendisine komşu olan sınır süper pikselinin p_{ij} arasında Potts Model ile tanımlanan akıcılık teriminin ağırlığını belirler. Ağırlık terimi, s_i süper pikselinin kontrastı k_{s_i} ile p_{ij} sınır süper pikselinin kontrastı $k_{p_{ij}}$ kullanılarak aşağıdaki gibi hesaplanır:

$$c_{s_i, p_{ij}} = 1 + \exp(-1 \times |k_{s_i} - k_{p_{ij}}|). \quad (27)$$

Bu denklem ağırlık teriminin [1,2] aralığında bir değer almasını sağlar. Eğer süper piksel ile kendisine komşu olan sınır süper pikselinin arasındaki kontrast farkı az ise iki süper piksel arasındaki akıcılık teriminin ağırlığı daha yüksek bir değer olacaktır. Benzer şekilde, iki süper pikselin kontrast farkı çok ise, akıcılık teriminin ağırlığı daha az olacaktır. Bölütleme ve sınır sahipliği tespiti problemlerini eş zamanlı olarak çözebilen bu yöntem Sınır Sahipliği Tespiti Gelişmiş (*MRABSSgelişmiş*) olarak isimlendirilmiştir.

8.2.1 Deneyler ve Sonuçlar

Yöntemlerin performansını incelemek için aşağıdaki ölçütleri kullandık:

Rand Olasılık İndeksi: Rand Olasılık İndeksi (ROI – Unnikrishnan ve Hebert, 2005), pikselleri ikiye bölünmüş gruplar halinde alıp, verilen iki bölütlemeye bu iki pikselin aynı şekilde bölütlenip bölütlenmediğini kontrol eder. Verilen bir grup referans (ing. ground-truth) bölütleme S_k ile elde edilen bölütlemeye S_{test} benzer şekilde gruplanmış piksellerin oranını aşağıdaki formül ile hesaplar:

$$ROI(S_{test}, S_k) = \frac{1}{\binom{N}{2}} \sum_a [c_{ij} p_{ij} + (1 - c_{ij})(1 - p_{ij})]. \quad (28)$$

Küresel Tutarlılık Hatası: Küresel Tutarlılık Hatası (Martin vd., 2001) verilen iki bölütleme arasındaki tutarlılığı hesaplamaya yönelik bir ölçüttür. Bu yöntemde öncelikle, verilen iki bölütlemeye piksel p_i 'a sahip olan iki bölüt S_1 ve S_2 arasındaki tutarlılık hatası aşağıdaki formül ile hesaplanır:

$$H(S_1, S_2, p_i) = \frac{|R(S_1, p_i) \setminus R(S_2, p_i)|}{R(S_1, p_i)}. \quad (29)$$

Bu denklem kullanılarak Küresel Tutarlılık Hatası aşağıdaki gibi tanımlanmıştır:

$$KTH(S_1, S_2) = \frac{1}{n} \min \left\{ \sum_i H(S_1, S_2, p_i), \sum_i H(S_2, S_1, p_i) \right\}. \quad (30)$$

KTH ve ROI, [0 – 1] arasında değerler alır. Bölütleme performansı iyileştikçe, KTH değeri düşüş, ROI değeri ise artış gösterir.

Bölütleme Derecesi ROI ve KTH ölçütlerini birarada kullanarak performans analizi yapmak amacı ile önerilen Bölütleme Derecesi denklemi aşağıdaki gibidir:

$$\text{Bölütleme Derecesi} = \frac{2 \times RO \times (1 - KTH)}{RO + (1 - KTH)}. \quad (31)$$

Bu ölçütlere göre elde ettiğimiz sonuçlar, **Tablo 6**'da listelenmiştir. Bu tablodaki sonuçlara göre, *MRABSS_{temel}*'in bölütleme performansının düşmesine sebep olduğu ancak *MRABSS_{gelişmiş}*'in bölütleme performansını düşürmeden, hem bölütleme hem de sınır sahipliği problemlerini eş zamanlı olarak çözebildiği görülmüştür.

Tablo 6. MRA ile Bölütleme, *MRABSS_{temel}* ve *MRABSS_{gelişmiş}* yöntemlerinin ROI (Rand Olasılık İndeksi), KTH (Küresel Tutarlılık Hatası) ve Bölütleme Derecesi ölçütlerine göre bölütleme performanslarının karşılaştırılması

	ROI	KTH	Bölütleme Derecesi
<i>MRA ile Bölütleme</i>	0.76	0.21	0.77
<i>MRABSS_{temel}</i>	0.75	0.22	0.76
<i>MRABSS_{gelişmiş}</i>	0.75	0.19	0.78

Bu sonuçlar umut verici olsa da, gelişime açık yönleneri bulunmaktadır. Öncelikle ek sınır sahipliği ipuçlarının eklenmesi, proje sonrasında çalışacağımız konulardan birisi olacaktır.


8.3 Derinlik Kestirimini İyileştirme

Proje yürütücüsünün doktora çalışması kapsamında geliştirdiği homojen alanlarda derinlik kestirimi yöntemi (kısaca **eski-yöntem** diyelim), proje kapsamında sınır sahipliği bilgisi kullanılarak (kısaca **yeni-yöntem** diyelim) iyileştirilmiştir.

8.3.1 Yöntem


Kabaca, eski-yöntemin dayandığı prensip (bknz. **Şekil 36**), homojen yeğinliğe sahip bir alanda derinlik, kenarlardaki derinlik bilgisi kullanılarak öngörülebileceğidir (tabi ki başka derinlik ipuçları da kullanılabilir). Eski-yöntemde önerilen, her bir homojen bölgecik için, onu çevreleyen kenarcıkları bulmak ve o kenarcıklardan ikili eşler oluşturarak, ikili eşlerin

homojen bölgecik için bir kestirimde bulunmasını sağlamaktır. Problem şu ki, **Şekil 36(b)**'de de görüldüğü gibi, bir homojen bölgeciği çevreleyen kenarlar, o bölgeye/alana ait olmayabilir, ki bunun çözümü, sınır sahipliği bilgisi kullanmaktır. Bunun için eski-yöntemde yapılması gereken tek değişiklik, homojen bir bölgeciği çevreleyen kenarları bulurken, sadece o bölgenin sahip olduğu kenarlara bakmaktır.



(a)

(b)

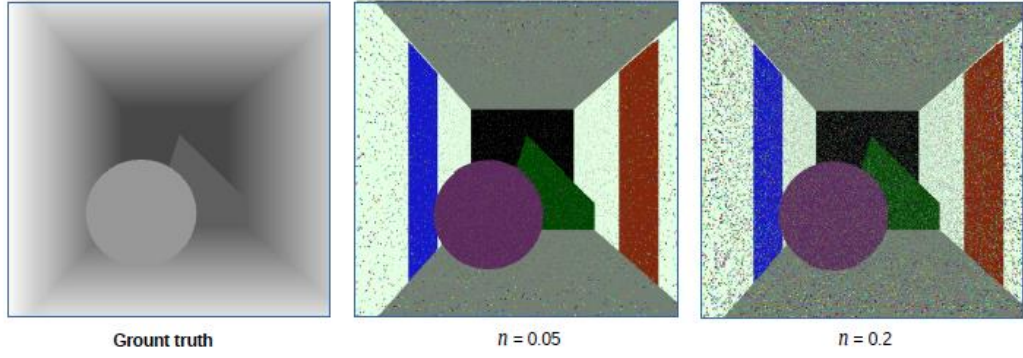


(c)

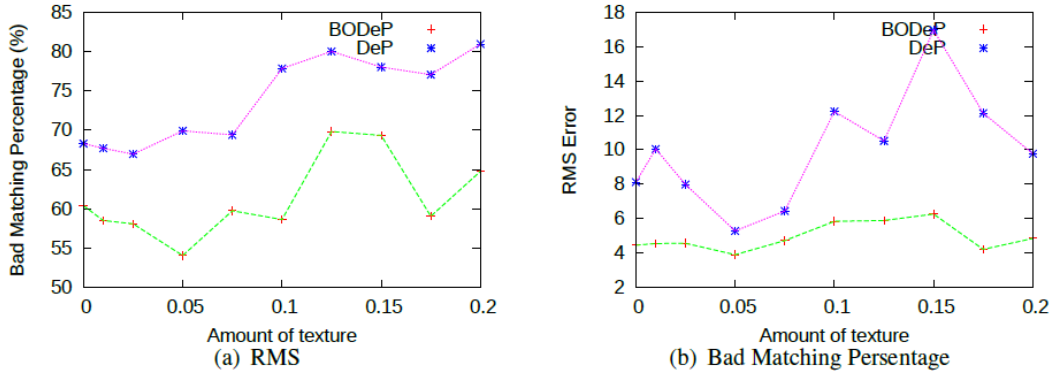
Şekil 36. Eski yöntemin çalışma prensibi. (a) Homojen yeğimliğe sahip bir alanda derinlik, kenarlardaki derinlik bilgisi kullanılarak öngörülebilir (tabi ki başka derinlik ipuçları da kullanılabilir). (b) Eski-yöntemde önerilen, her bir homojen bölgecik için, onu çevreleyen kenarcıkları bulmak ve o kenarcıklardan ikili eşler oluşturarak, ikili eşlerin homojen bölgecik için bir kestirimde bulunmasını sağlamak (c). Problem şu ki, (b)'de de görüldüğü gibi, bir homojen bölgeciği çevreleyen kenarlar, o bölgeye/alana ait olmayabilirler, ki bunun çözümü, sınır sahipliği bilgisi kullanmaktır.

8.3.2 Sonuçlar

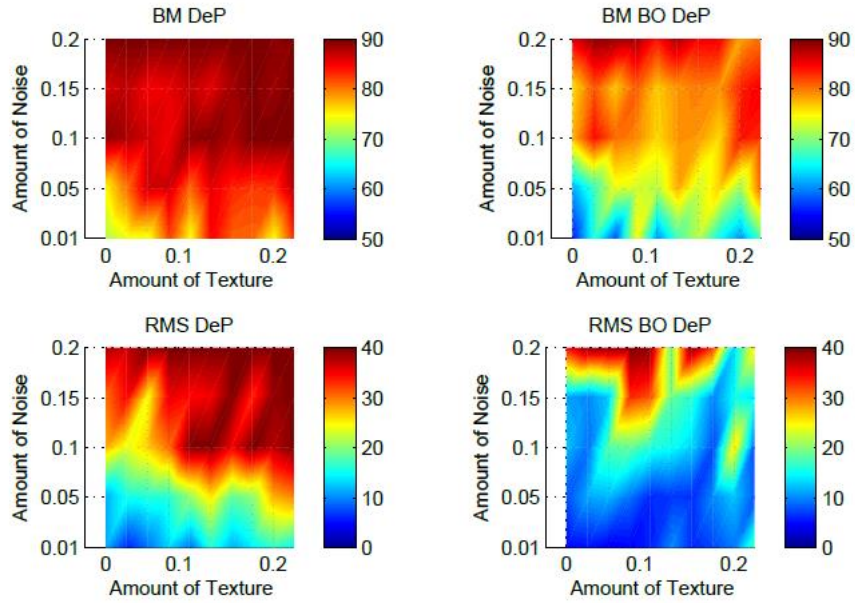
Bu sayede elde edilen sonuçlar (**Şekil 37**) sınır sahipliği bilgisinin kenarlardan derinlik kestirimi yapan eski yöntemin performansını iyileştirmektedir. Şimdiye kadar yapay bir düzende çalıştık, önümüzdeki dönemde gerçek görüntüler üzerinde çalışacağız.



(a)



(b)



(c)

Şekil 37. Eski yöntem (DeP) ve yeni yöntemin (BO DeP) kıyaslanması. (a) Yöntemleri kıyaslamak için kullandığımız yapay düzenek. OpenGL ortamında oluşturduğumuz düzenek sayesinde doğru derinlik bilgisini elde edebiliyoruz ve görüntüye farklı oranda

doku ve gürültü ekleyebiliyoruz. (b) Farklı doku miktarlarında ve (c) farklı gürültü ve doku miktarlarında RMS (root-mean-squared hatası) ve BM (bad-matching percentage hatası – hesaplanan disparitesi doğru değerden farklı olan piksellerin oranı).

8.4 Markov Rastgele Alan ile Stereo Bilgisinin İyileştirilmesi

Bu bölümde, sınır sahipliği bilgisi kullanarak stereo ayırım (ing. disparity) bilgisini iyileştirmeye çalıştık.

8.4.1 Yöntem

Markov Rastgele Alan (MRA) yöntemi kullanılarak stereo ayırım bilgisi aşağıdaki enerji fonksiyonunu en iyileyerek hesaplanabilir (Scharstein ve Szeliski, 2002):

$$U(w) = \sum_i C(x_i, d_i) + \sum_{i, j \in N_i} |d_i - d_j|, \quad (32)$$

ki burada x_i , i nci pikseli; $C(x_i, d_i)$, x_i için d_i ayırım masrafını; N_i , x_i pikselinin komşularını göstermektedir. Birinci terim, efektif olarak basit olarak pikselin farklı ayrımlara göre masrafını hesaplamakta (bunun için, mutlak-farklar-toplamı, normal-çapraz-korelasyon vb. yöntemler kullanılır); ikinci terim ise, kestirimi yapılan ayrımlar arasında pürüzsüzlük sağlamaktadır.

Proje kapsamında, sınır sahipliği bilgisini eklemek için, ikinci terim, bir sınır sadece kendisine ait alana etki edecek biçimde değiştirilmiştir:

$$U(w) = \sum_i C(x_i, d_i) + \sum_{i, j \in N_i^b} |d_i - d_j|, \quad (33)$$

ki burada N_i^b , sınır bölgelerinde sınırın sahip olduğu alanı dikkate alan bir komşuluk tanımlamaktadır.

Bu enerji formülasyonu, Döngüsel Bilgi Aktarımı (DBA, ing. Loopy Belief Propagation) yöntemi kullanılarak çözülmüştür.


8.4.2 Sonuçlar

Middlebury Stereo Verikümesinden elde edilen görüntülerde yaptığımız inceleme sonuçları **Tablo 7**'de, görsel sonuçlar ise **Şekil 38**'de sunulmuştur. Sonuçlara baktığımızda, bazı görsellerde sınır sahipliği bilgisinin %29'lara varan iyileştirme sağlayabildiğini, ancak bazı görsellerde hiç iyileştirme yapamadığını, hatta bazı durumlarda (ortalama hatayı) daha kötü

sonular rettiđi gzlenmiřtir. **řekil 38**'de sunulan rnek grsele baktıđımızda, sınır sahipliđinin daha keskin ve dođruya yakın kenarlar rettiđi gzlenmektedir.

Tablo 7. Stereo ayırım kestiriminin sınır sahipliđi eklendiđinde elde edilen sonular (K: Kazanım, SS: Sınır Sahipliđi).

Grnt	Kt Eřleřme Yzdesi (Bad Matching Percentage - %)				Ortalama Hata (Root-Mean-Squared)			
	LBP	LBP +SS	K	K (%)	LBP	LBP +SS	K	K (%)
teddy	27.21	26.32	0.89	3.3	39.594	39.875	-0.280	-0.7
tsukuba	4.98	3.51	1.47	29.5	19.626	16.584	3.042	15.5
venus	11.28	10.84	0.44	3.9	19.338	19.148	0.189	1.0
sawtooth	20.43	19.71	0.72	3.5	20.768	20.354	0.414	2.0
cones	21.32	20.32	1.00	4.7	43.225	44.615	-1.391	-3.2
aloe	99.78	99.83	-0.05	-0.1	49.166	48.324	0.841	1.7
bowling	94.85	94.64	0.21	0.2	67.648	66.907	0.741	1.1
	Ortalama			6.4	Ortalama			2.5



řekil 38. rnek bir grsel zerinde sınır sahipliđi bilgisinin kullanılarak stereo ayırım bilgisinin nasıl deđiřtiđi. (a) Beklenen sonu. (b) DBA ile elde edilen sonu. (c) Sınır sahipliđi eklenince elde edilen sonu.

8.5 Markov Rastgele Alan ile Optik Akıř Bilgisinin İyileřtirilmesi

Bu kısımda, MRA kullanarak optik akıř bilgisini iyileřtirip-iyileřtiremediđimizi test ettik.

8.5.1 Yntem

Bu ama iin, Blm 8.4'teki ynteme benzer bir yntem kullandık. Aradaki en nemli fark, her bir piksel iin kestirimi yapılan deđerın bir boyutlu deđer, iki boyutlu olmasıdır:

$$U(w) = \sum_i C(x_i, \mathbf{f}_i) + \sum_{i, j \in N_i^b} \|\mathbf{f}_i - \mathbf{f}_j\|_2, \quad (34)$$

ki burada $f_i = (u_i, v_i)$, x_i pikselinin optik akış değerini ifade etmektedir; ve N_i^b , Denklem (33)'teki gibi, sınır bölgelerinde sınırın sahip olduğu alanı dikkate alan bir komşuluk tanımlamaktadır.


Bu enerji formülasyonu, yine Döngüsel Bilgi Aktarımı (DBA)yöntemi kullanılarak çözülmüştür.

8.5.2 Sonuçlar

Middlebury Stereo Verikümesinden elde edilen görüntülerde yaptığımız inceleme sonuçları **Tablo 8**'de, görsel sonuçlar ise **Şekil 39**'da sunulmuştur. Sonuçlara baktığımızda, bazı görsellerde sınır sahipliği bilgisinin %17'lere varan iyileştirme sağlayabildiğini, ancak bazı görsellerde hiç iyileştirme yapamadığını, hatta bazı durumlarda (ortalama hatayı) daha kötü sonuçlar ürettiği gözlenmiştir. **Şekil 39**'da sunulan örnek görsele baktığımızda, stereo kestiriminde olduğu gibi, sınır sahipliğinin daha keskin ve doğruya yakın kenarlar ürettiği gözlenmektedir.

Tablo 8. MRA yöntemi kullanarak optik akış kestiriminin sınır sahipliği eklendiğinde elde edilen sonuçlar (K: Kazanım).

Görüntü	Ortalama Hata (Root-Mean-Squared)				Kötü Eşleşme Yüzdesi (Bad Matching Percentage - %)			
	LBP	LBP +SS	K	K (%)	LBP	LBP +SS	K	K (%)
Rubber-whale	0.512	0.474	0.038	7.4	1.79	1.5	0.29	16.2
Hyrangea	0.996	0.998	-0.002	-0.2	4.87	4.8	0.07	1.4
Dimetrodon	0.497	0.498	-0.001	-0.2	0.76	0.73	0.03	3.9
Venus	1.181	1.347	-0.166	-14.1	3.45	2.86	0.59	17.1
	Ortalama			-1.8	Ortalama			9.7



Şekil 39. Örnek bir görsele sınır sahipliği bilgisinin optik akış kestirimine katkısı. (a)

Beklenen sonuç. (b) DBA ile elde edilen sonuç. (c) Sınır sahipliği eklenince elde edilen sonuç.

8.6 İyileştirmelerin Genel Değerlendirmesi

Bu bölümde, sınır sahipliği bilgisinin sağlayabileceği iyileştirmeleri farklı problemler üzerinde inceledik. Sınır sahipliği bilgisinin, derinlik kestirimi, stereo görme ve optik akış problemlerine değişen miktarlarda katkı sağlayabileceğini gösterdik.

Ancak, özellikle stereo ayrımı ve optik akış bilgilerinin bazen iyileşmediğini gözlemledik. Sınır sahipliğinin sağlamadığı görsellere baktığımızda, bunun nedeninin oklüzyon bölgesi **olmayan** kenarlarda sınır sahipliğinin pürüzsüzleştirmeye izin vermemesi ve bu nedenle, aslında birbirini iyileştirebilecek kestirimleri kendi bölgelerinde tutmasıdır. Bu nedenle, sınır sahipliği bilgisi ile birlikte, görüntüde oklüzyon bölgelerinin de kestiriminin yapılması ve sadece oklüzyon olan bölgelerde sınır sahipliği ile iyileştirmeye gidilmesi daha doğru olacağı değerlendirilmiştir.

9. SONUÇ

3 senelik bu proje kapsamında sınır sahipliği probleminin çözümüne önemli katkılar sağlanmış ve bu konuda literatüre, geniş bir veritabanı, farklı bilişimsel yöntemler, yöntemlerin kıyaslanması ve sınır sahipliği bilgisinin kullanımı üzerine katkılar sağlanmıştır.

9.1 Projenin Bilimsel Sonuçları

Proje kapsamında üretilen sonuçlar, aşağıdaki gibi özetlenebilir:

- **Sınır sahipliği için kapsamlı bir veritabanının oluşturulması:** Literatürde elle işaretlenmiş sınır sahipliği içeren veritabanları bulunsa da, bu veritabanları görüntü sayısı ve türü bakımından kısıtlıdır. Proje kapsamında 500 iç-alan ve 500 dış-alan görüntüsü 3'er denek tarafından işaretlenmiş ve bu kapsamlı veritabanı bu konuda çalışan araştırmacılar ile paylaşılmıştır.
- **Görsel ipuçlarının incelenmesi:** Sınır sahipliği için farklı görsel ipuçlarının değerli bilgi taşıdığı Psikoloji, Sinirbilim ve bilişimsel çalışmalarda vurgulanmış idi. Ancak, bu ipuçlarının bir veriseti üzerinde detaylı incelenmesi şimdiye kadar yapılmamış idi. Projenin önemli katkılarından bir tanesi, görsel bilgilerin sınır sahipliğini belirlemede ne kadar faydalı oldukları, hangi ipuçlarının birbiri ile zıtlaştığı ve bu zıtlama durumlarında hangilerinin belirleyici olduğu gibi önemli konuların incelenmesi olmuştur.
- **Bilişimsel yöntem geliştirilmesi:** Proje kapsamında farklı karmaşıklıklarda ve başarımlarında bilişimsel yöntemler geliştirilmiştir. Bu yöntemler şunlardır: Tekrarlamalı Vektör Oylama, Görsel İpuçları Üzerinden Şartlı Rastgele Alan, Görsel İpuçları Üzerinden AdaBoost. Projenin bitiminden sonra da yeni yöntemlerin geliştirilmesine devam edilecektir.
- **Literatürdeki yöntemlerin kıyaslanması:** Literatürdeki önemli eksiklerden bir tanesi, yöntemlerin birbiri ile yeterli detayda kıyaslanmamış olmasıdır. Bu kapsamda, literatürden seçilmiş 3 yöntem, ve bunların özgün 3 uyarlaması kıyaslanmıştır.
- **Görsel bilgilerin sınır sahipliği ile iyileştirilmesi:** Sınır sahipliği bilgisinin farklı görme problemlerine etkisi bulunmaktadır. Tüm etkilerini proje kapsamında gösteremesek de, stereo ve optik akış bilgisine katkısı, ayrıca bölütleme problemi ile eş-çözümü proje kapsamında çalışılmıştır.

9.2 Projenin Etkisi

Projenin çıktılarının etkisi aşağıdaki yönlerden irdelenebilir:

- **Proje yürütücüsünün kariyerine etkisi:** Proje yürütücüsü, bu proje sayesinde erken görme problemleri konusundaki birikimini artırmış, sınır sahipliği konusunda çalışan araştırmacılarla da iletişim halinde olarak ve proje kapsamında üretilen veritabanı sayesinde, bu konuda daha görünür bir araştırmacı olmuştur.
- **Ulusal etkisi:** Projenin çıktıları ulusal konferanslarda sunulmuş ve oldukça olumlu tepkiler almıştır. Ayrıca, bu konuda üç lisansüstü tez yapılarak, Türkiye’de bu konuda önemli bir bilgi birikimi sağlanmıştır.
- **Uluslararası etkisi:** Projenin çıktıları uluslararası dergilerde yayınlanmakta ve yayınlanacaktır. **Ayrıca, kıyaslanmış olan yöntemlerin kaynak kodları kullanımı ve genişletmesi kolay bir biçimde camia ile paylaşılacak, bu sayede sınır sahipliği problemi araştırmalarının bir üst seviyeden devam etmesi sağlanacaktır.**

9.3 Projenin Geleceği

Projede üretilen bilimsel sonuçlar, pek çok yönden devam ettirilebilir ve bunları bir kısmı gerek Avrupa Birliği H2020 proje teklifleri hazırlanarak, gerekse TÜBİTAK proje teklifleri hazırlanarak değerlendirilmektedir. Olası yönlerden bir kısmı şöyle özetlenebilir:

- Bilişimsel yöntemlerin sonuçları %80’i geçememektedir. Bu, yeni bilişimsel yöntemler için zorlayıcı bir hedef olmaktadır ve yeni bilişimsel yöntemlerin geliştirilmesi için teşvik edicidir.
- Özellikle stereo, bölütleme, optik akış gibi diğer erken görme problemleri ile sınır sahipliği probleminin uygun bir çerçeve içerisinde formüle edilmesi ve çözülmesi, projenin en uygun devam projelerinden birisi olacaktır.
- “Derin öğrenme” ile elde edilen başarılı sonuçları da hesaba katınca, insan görme sistemine benzer bir biçimde giderek karmaşıklaşan öznitelikler ve gösterimlerden oluşan hiyerarşik yapılar içerisinde sınır sahipliğinin çalışılması, değerlendirilebilecek önemli problemlerden bir tanesidir.

10. KAYNAKÇA

- Albert M. K. 2001. "Cue interactions, border ownership and illusory contours", *Vision Research*, 41:2827-2834.
- Anderson B.L., Singh M., Fleming R.W. 2002. "The interpolation of object and surface structure", *Cognitive Psychology*, 44(43):148-190.
- Bakin J. S., Nakayama K., Gilbert C. D. 2000. "Visual responses in monkey areas v1 and v2 to three-dimensional surface configurations", *Journal of Neuroscience*, 20:8188-8198.
- Barrow H. G., Tenenbaum J. M. 1981. "Interpreting line drawings as three-dimensional surfaces", *Artificial Intelligence*, 17:75-116.
- Bayerl P., Neumann H. 2007. "Disambiguating Visual Motion by Form-Motion Interaction-a Computational Model", *International Journal of Computer Vision*. Vol. 72, no. 1, pp. 27-45.
- Brown M. Z., Burschka D., Hager G. D. 2003. "Advances in computational stereo", *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol. 25, no. 8, pp. 993-1008.
- Chen, X., Li, Q., Zhao, D., and Zhao, Q. 2013. "Occlusion cues for image scene layering", *Computer Vision and Image Understanding*, 117(1):42 – 55.
- Collett T. S. 1985. "Extrapolating and Interpolating Surfaces in Depth", *Royal Society of London Proceedings Series B*, 224:43-56.
- Craft, E., Schutze, H., Niebur, E., Von Der Heydt, R. 2007. "A neural model of figure-ground organization", *Journal of neurophysiology*, 97(6):4310–4326.
- Dellen B., Wörgötter F. 2009. "Disparity from stereo-segment silhouettes of weakly-structured images", *British Machine Vision Conference*.
- Fang, F., Boyaci, H., Kersten, D. 2009. "Border ownership selectivity in human early visual cortex and its modulation by attention", *The Journal of Neuroscience*, 29(2):460–465.
- Finkel L. H., Sajda P. 1992. "Object discrimination based on depth-from occlusion", *Neural Comput.*, 4(6):901-921.
- Fowlkes, C. C., Martin, D. R., and Malik, J. 2007. "Local figure-ground cues are valid for natural images", *Journal of Vision*, 7(8):1–9.

- Froyen, V., Feldman, J., Singh, M. 2010. "A bayesian framework for figure-ground interpretation", In *Advances in neural information processing systems*, pages 631–639.
- Grimson, W. E. L. 1982. "A Computational Theory of Visual Surface Interpolation", *Royal Society of London Philosophical Transactions Series B*, 298:395-427.
- Hegde, J., Van Essen, D. C. 2007. "A comparative study of shape representation in macaque visual areas v2 and v4", *Cerebral Cortex*, 17(5):1100–1116.
- Ince S., Konrad J. 2008. "Occlusion-Aware Optical Flow Estimation", *IEEE Transactions on Image Processing*, Vol. 17, No. 8. pp. 1443 – 1451.
- Julesz, B. 1971. "Foundations of Cyclopean Perception". Univ. of Chicago Press, Chicago, IL.
- Kienker, P. K., Sejnowski, T. J., Hinton, G. E., and Schumacher, L. E. 1986. "Separating figure from ground with a parallel network", *Perception*, 15(2):197–216.
- Kikuchi, M., Akashi, Y. 2001. "A model of border-ownership coding in early vision", In *International Conference on Artificial Neural Networks*, pages 1069–1074.
- Kikuchi, M., Fukushima, K. 2003. "Assignment of figural side to contours based on symmetry, parallelism, and convexity", In *Knowledge-Based Intelligent Information and Engineering Systems*, pages 123–130.
- Koffka, K. 1935. *Principles of Gestalt Psychology*. Harcourt. Brace.
- Kogo, N., van Ee, R. 2014. "Neural mechanisms of figure-ground organization: Border-ownership, competition and perceptual switching", In Wagemans, J., editor, *The Oxford Handbook of perceptual organization*. Oxford University Press.
- Komatsu, H. 2006. "The neural mechanisms of perceptual filling-in", *Nature Reviews Neuroscience*, 7:220-231.
- Layton, O. W., Mingolla, E., Yazdanbakhsh, A. 2012. "Dynamic coding of border-ownership in visual cortex". *Journal of Vision*, 12(13):1–21.
- Leichter, I., Lindenbaum, M. 2009. "Boundary ownership by lifting to 2.1d", In *IEEE 12th International Conference on Computer Vision*, pages 9–16. IEEE.

- Liu, B., Gould, S., Koller, D. 2010. "Single Image Depth Estimation From Predicted Semantic Labels", International Conference on Computer Vision and Pattern Recognition (CVPR).
- Liu, C., Yuen, J., Torralba, A., Sivic, J., & Freeman, W. T. 2008. Sift flow: Dense correspondence across different scenes. In *Computer Vision–ECCV 2008* (pp. 28-42). Springer Berlin Heidelberg.
- Lowe, D. G. 1999. Object recognition from local scale-invariant features. In *proceedings of the seventh IEEE international conference on computer vision*, 2, pp.1150-1157, IEEE.
- Martin, D., Fowlkes, C., Tal, D., Malik, J. 2001. "A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics," in *Proc. 8th Int'l Conf. Computer Vision*, pp. 416–423.
- Mordohai, P., Medioni, G. 2006. "Tensor voting: a perceptual organization approach to computer vision and machine learning", *Synthesis Lectures on Image, Video, and Multimedia Processing*, 2(1), 1-136.
- Neumann H., Yazdanbakhsh A, Mingolla E. 2007. "Seeing surfaces: The brain's vision of the world", *Physics of Life Reviews*, 4:189-222.
- Nishimura H., Sakai K. 2004. "Determination of border ownership based on the surround context of contrast", *Neurocomputing*, 58-60:843-848.
- Pessoa L., Thompson E., Noe A. 1998. "Finding out about filling-in: A guide to perceptual completion for visual science and the philosophy of perception", *Behavioral and Brain Sciences*, 21(06):723-748.
- Peterson, M. A., Harvey, E. M., Weidenbacher, H. J. 1991. "Shape recognition contributions to figure-ground reversal: which route counts?" *Journal of Experimental Psychology: Human Perception and Performance*, 17(4):1075–1089.
- Peterson, M. A. 1999. "What's in a stage name? comment on vecera and o'reilly (1998)", *Journal of Experimental Psychology: Human Perception and Performance*, 25(1):276–286.
- Peterson, M. A. and Salvagio, E. 2008. Inhibitory competition in figure-ground perception: Context and convexity. *Journal of Vision*, 8(16):1–13.
- Qiu, F. T., Sugihara, T., von der Heydt, R. 2007. "Figure-ground mechanisms provide structure for selective attention", *Nature Neuroscience*, 10(11):1492–1499.

- Qiu, F. T., Von Der Heydt, R. 2005. "Figure and ground in the visual cortex: V2 combines stereoscopic cues with gestalt rules", *Neuron*, 47(1):155–166.
- Ramenahalli, S., Mihalas, S., Niebur, E. 2012. "Figure-ground classification based on spectral properties of boundary image patches", In 46th Annual Conference on Information Sciences and Systems, CISS 2012, Princeton, NJ, USA, March 21-23, 2012, pages 1–4.
- Ren, X., Fowlkes, C. C., Malik, J. 2006. "Figure/Ground assignment in natural images", In European Conference on Computer Vision, pages 614–627.
- Sabatini, S. P., Gastaldi, G., Solari, F., Diaz, J., Ros, E., Pauwels, K., Hulle, K. M. M. V., Pugeault, N., Kruger, N. 2007. "Compact and accurate early vision processing in the harmonic space", International Conference on Computer Vision Theory and Applications (VISAPP).
- Sajda, P., Finkel, L. H. 1995. "Intermediate-level visual representations and the construction of surface perception", *Journal of cognitive neuroscience*, 7(2):267–291.
- Sakai, K., Nishimura, H., Shimizu, R., Kondo, K. 2012. "Consistent and robust determination of border ownership based on asymmetric surrounding contrast", *Neural Networks*, 33:257–274.
- Scharstein D., Szeliski R. 2002. "A Taxonomy and Evaluation of Dense Two-Frame Stereo Correspondence Algorithms", *International Journal of Computer Vision*, Vol. 47 (1-3), 7 – 42.
- Telea, A. 2004. "An image inpainting technique based on the fast marching method", *Journal of graphics tools*, 9(1):23-34.
- Terzopoulos, D. 1988. "The computation of visible-surface representations", *IEEE Trans. Pattern Anal. Mach. Intell.*, 10(4):417-438.
- Treue S., Andersen R. A., Ando H., Hildreth E. C. 1995. "Structure-from motion: perceptual evidence for surface interpolation", *Vision Research*, 35(1):139-48.
- Unnikrishnan, R., Hebert, M. 2005. "Measures of similarity," 7th IEEE Workshop on Applications of Computer Vision / IEEE Workshop on Motion and Video Computing (WACV/MOTION), Breckenridge, CO, USA.

Vecera, S. P. O'reilly, R. C. 1998. "Figure-ground organization and object recognition processes: an interactive account". *Journal of Experimental Psychology: Human Perception and Performance*, 24(2):441–462.

Vecera, S. P. O'Reilly, R. C. 2000. "Graded effects in hierarchical figure-ground organization: reply to peterson (1999)", *Journal of Experimental Psychology: Human Perception and Performance*, 26(3):1221–1231.

Vecera, S. P., Vogel, E. K., Woodman, G. F. 2002. "Lower region: A new cue for figure-ground assignment", *Journal of Experimental Psychology-General*, 131(2):194–205.

Weickert, J. 1998. "Anisotropic diffusion in image processing", Vol. 1. Stuttgart: Teubner.

Weickert J., Bruhn A., Brox T., Papenberg N. 2006. "A Survey on Variational Optic Flow Methods for Small Displacements", *Mathematical Models for Registration and Applications to Medical Imaging*, vol 10, part-I, 103-106.

Zhou H., Friedman H. S., von der Heydt R. 2000. "Coding of Border Ownership in Monkey", *Visual Cortex. J. Neurosci.*, 20(17):6594-6611.

Zucker, S. W. 2012. "Local field potentials and border ownership: a conjecture about computation in visual cortex", *Journal of Physiology-Paris*, 106(5):297–315.

**TÜBİTAK
PROJE ÖZET BİLGİ FORMU**

Proje Yürütücüsü:	Yrd. Doç. Dr. SİNAN KALKAN
Proje No:	111E155
Proje Başlığı:	Sınır Sahipliği İle Görüntülerden Hassas Görsel Bilgi Edinimi
Proje Türü:	3501 - Kariyer
Proje Süresi:	36
Araştırmacılar:	
Danışmanlar:	ÖZGE ÖZTİMUR KARADAĞ
Projenin Yürütüldüğü Kuruluş ve Adresi:	ORTA DOĞU TEKNİK Ü. MÜHENDİSLİK F. BİLGİSAYAR MÜHENDİSLİĞİ B.
Projenin Başlangıç ve Bitiş Tarihleri:	01/04/2012 - 01/10/2015
Onaylanan Bütçe:	204016.0
Harcanan Bütçe:	111731.78
Öz:	<p>Tekdüze görüntü alanlarının neden olduğu eksik ve muğlak görsel bilginin düzeltilebilmesi, ilgili görüntü alanlarını çevreleyen sınırlardaki (görüntü işleme diliyle; kenarlardaki) güvenilir görsel bilgilerin ?içeriye doldurma? mekanizması kullanılarak görüntü alanlarının iç kısımlarına iletilmesiyle mümkün olabilir. Ancak, bu yöntemin kullanılabilmesi, görüntü alanlarının sınırlarının daha önceden belirlenmesini gerektirir; bir başka deyişle, görüntüdeki her kenara bir ?sınır sahipliği? bilgisi verilmiş olmalıdır. ?Sınır sahipliği? bilgisi, görüntüdeki kenarları ve alanları birbirine bağlar; böylece, kenarlardaki güvenilir görsel bilgi, doğru alanların içine doğru aktarılabilir.</p> <p>Bu projede üç hedefi gerçekleştirilmiştir: (1) Sınır sahipliğinin belirlenmesi için önemli mekanizmaları incelemek, (2) bu inceleme sonuçlarını kullanan bilişimsel (ing. computational) bir model geliştirmek ve (3) bu bilişimsel modeli, yerel mekanizmalar kullanan, önemli görme problemlerine uygulayarak, sınır sahipliği bilgisinin görsel bilginin kalitesi ve niceliği üzerindeki etkisini göstermek.</p> <p>İlk hedefimizde, insan denekler tarafından sınır sahipliği işaretlenecek ve incelememiz için temel oluşturacak görüntüler toplanmıştır. Sınır sahipliği işaretlenmiş bu görüntüleri kullanarak, sınır sahipliği bilgisi ve farklı görsel öğeler arasında inceleme yapılmıştır. Bu türden bir yaklaşımın, sınır sahipliği gibi henüz işleme mekanizması anlaşılammış bir problem için oldukça uygun olduğunu düşünüyoruz; çünkü insan görme sisteminin görüntülerdeki düzenliliği kullandığı ve bu düzenliliği (işaretlenmiş görüntüler üzerinden) incelemenin farklı algısal mekanizmaların çalışma prensipleri hakkında ipuçları taşıyacağı literatür tarafından yaygın olarak kabul görmektedir.</p> <p>İkinci hedefimiz için, sınır sahipliği bilgisi taşıyan farklı veri kaynaklarını ve bu kaynaklar arasındaki ilişkileri modellemek için farklı bilişimsel yöntemler geliştirdik. Bu yöntemler arasında, tensör oylama, olasılıksal rastgele alan, karar destek makineleri, Bayes sınıflandırma, AdaBoost sınıflandırma sayılabilir. Ayrıca, bu yöntemleri verisetimiz üzerinde detaylı bir biçimde kıyaslamış bulunmaktayız.</p> <p>Bilişimsel modeli geliştirdikten sonra, modelimizi yerel hesaplama yöntemleri kullanan üç önemli görme problemi olan, optik akış ve stereo görme hesaplamalarına ve kenarlardaki derinlik bilgisini kullanarak görüntü alanları içerisinde derinlik öngörme problemlerine uyguladık ve sınır sahipliği bilgisinin farklı seviyelerde katkı sağladığını gösterdik.</p>
Anahtar Kelimeler:	Bilgisayarlı Görme, Sınır Sahipliği, İçeri Doldurma Mekanizmaları
Fikri Ürün Bildirim Formu Sunuldu Mu?:	Hayır

Projenin Yapılan Yayınlar:	<p>1- Sınır Sahipliği İçin Kapsamlı Bir Veri Tabanı (Bildiri), 2- Şartlı Rastgele Alan Modeli ile Sınır Sahipliği Bilgisi Çıkarımı (Bildiri)1- Extraction of Border Ownership Information by Conditional Random Field Model (Makale - Diğer Hakemli Makale), 2- A Comprehensive Database for Border Ownership (Makale - Diğer Hakemli Makale), 3- MRA ile İmge Bölütleme ve Sınır Sahipliği Problemlerinin Eş Zamanlı Çözümü (Bildiri - Ulusal Bildiri - Sözlü Sunum), 4- A Comprehensive Database for Border Ownership (Bildiri - Ulusal Bildiri - Sözlü Sunum), 5- Extraction of Border Ownership Information by Conditional Random Field Model (Bildiri - Ulusal Bildiri - Sözlü Sunum), 6- ANALYSIS OF BORDER OWNERSHIP CUES AND IMPROVEMENT OF DEPTH PREDICTION USING BORDER OWNERSHIP (Tez (Araştırmacı Yetiştirilmesi) - Yüksek Lisans Tezi), 7- ESTIMATING BORDER OWNERSHIP USING ITERATIVE VECTOR VOTING AND CONDITIONAL RANDOM FIELDS (Tez (Araştırmacı Yetiştirilmesi) - Yüksek Lisans Tezi),</p>
----------------------------	--

TÜBİTAK