

# Çizgisel Raf Modeli ile Perakende Ürün Tanıma Retail Product Recognition with a Graphical Shelf Model

İpek Baz<sup>1</sup>, Erdem Yoruk<sup>2</sup>, Müjdat Çetin<sup>1</sup>

<sup>1</sup> Mühendislik ve Doğa Bilimleri Fakültesi, Sabancı Üniversitesi, İstanbul, Türkiye

<sup>2</sup> Vispera Bilgi Teknolojileri, İstanbul, Türkiye

Email: ibaz@sabanciuniv.edu, e.yoruk@vispera.co, mctetin@sabanciuniv.edu

**Özetçe** —Son zamanlarda, görüntüden perakende ürün tanıma bilgisayarla görme alanında ilginç bir araştırma konusu haline gelmiştir. Ürün sınıflarının çoğu görsel olarak şekil, renk, doku ve boyut açısından birbirine benzediği için mağaza raflarında bulunan ürünlerin sınıflandırılması zor ve karmaşık bir sınıflandırma problemidir. Market raflarında, aynı veya benzer ürünlerin yan yana bulunma olasılığı daha yüksektir ve ürünler rastgele olmayan belli bir düzene göre dizilirler. Raflardaki ürün dizilimleri hem marka ve hem de ürün boyutu açısından devamlılığa sahiptir. Bu bağlam bilgisi kullanılarak, ürünlerin birlikte bulunması ve ürünler arasındaki komşuluk ilişkileri istatistiksel olarak modellenilebilir. Bu çalışmada, kolay ayırt edilemeyecek kadar birbirine benzeyen ürün sınıfı tanıma sorunu için ürün dizilimlerinin farkında olan hibrit bir sınıflandırma sistemi sunulmaktadır. Önerilen hibrit yöntem, ürün diziliminden bağımsız görüntü sınıflandırıcının doğruluğunu, onu raftaki ürün dizilimlerini istatistiksel olarak modelleyen saklı Markov modeli ile birleştirerek artırır. Bu çalışmanın temel amacı raflardaki bağlamsal ilişkileri kullanarak perakendece ürün sınıflandırıcının doğruluğunu arttırmaktır.

**Anahtar Kelimeler**—Bağlam Bilgisi Kullanan Sınıflandırma, Olasılıksal Çizgisel Modelleme, Saklı Markov Modeli.

**Abstract**—Recently, retail product recognition has become an interesting computer vision research topic. The classification of products on shelves is a very challenging classification problem because many product classes are visually similar in terms of shape, color, texture, and metric size. In shelves, same or similar products are more likely to appear adjacent to each other and displayed in certain arrangements rather than at random. The arrangement of the products on the shelves has a spatial continuity both in brand and metric size. By using this context information, the co-occurrence of the products and the adjacency relations between the products can be statistically modeled. In this work, we present a context-aware hybrid classification system for the problem of fine-grained product class recognition. The proposed hybrid approach improves the accuracy of the context-free image classifiers, by combining them with a probabilistic graphical model based on Hidden Markov Models. The fundamental goal of this paper is to use contextual relationships in retail shelves to improve accuracy of the product classifier.

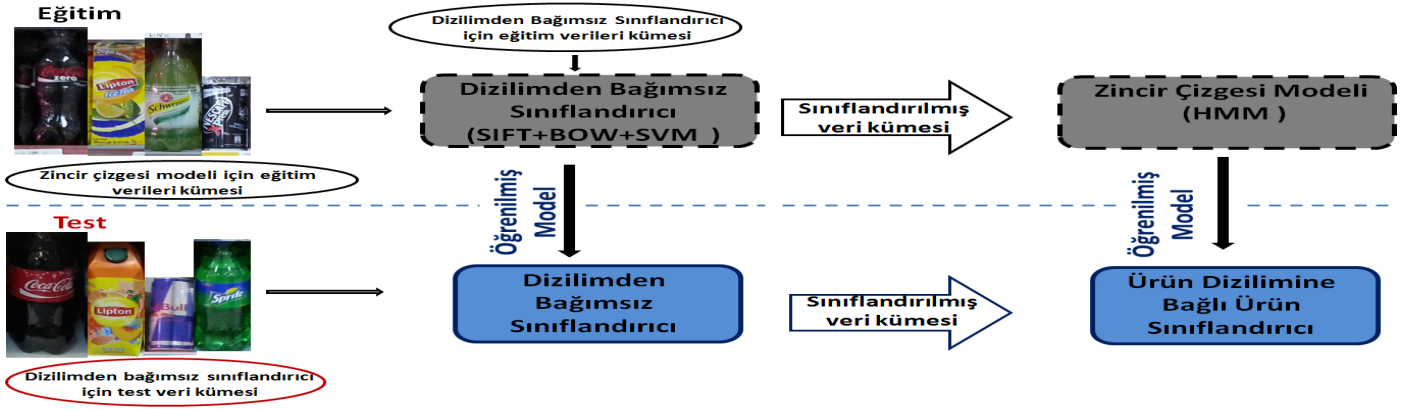
**Keywords**—Context-aware Classification, Probabilistic Graphical Model, Hidden Markov Model.

## I. GİRİŞ

Bilgisayarla görme yöntemleri ile tasarlanan perakende ürün tanıma uygulamalarına olan ilgi gün geçtikçe artmaktadır. Perakende ürün tanıma sistemi müşteriler tarafından önceden hazırlanan listeye göre yardımcı alışveriş mekanizmasında kullanılabileceği gibi aynı zamanda üreticiler için de önem taşımaktadır. Üreticiler, market raflarındaki ürün düzenlemelerinin takibi, envanterin gerçek zamanlı yönetimi, stok fazlası ve biten ürünlerin tespiti gibi birçok konuda otomatik perakende ürün tanıma sistemlerine ihtiyaç duyarlar.

Birbirine çok benzeyen nesnelerin sınıflandırılması bilgisayarlı görme alanındaki zorlayıcı problemlerden biridir [1], [2]. Marketlerde, çok sayıda şekil, renk, doku ve boyut açısından benzer görünüme sahip ürün sınıfları vardır. Ayrıca, ürün görüntülerinin ideal stüdyo ortamında değil de akıllı telefonlarla market ortamında toplanması farklı görüş açılarından görüntü toplama, bulanıklık, çeşitli engellerle ürünün kapanması, beklenmeyen arka plan parçaları ve farklı aydınlatma koşulları gibi pek çok sorunları da beraberinde getirmektedir. Toplanan görüntülerdeki bu gibi karmaşıklıklar ürün tanıma problemini daha da zor hale getirmektedir. Bu nedenle, sadece ürün görüntüsünden elde edilen bilgiye dayalı tasarlanan ürün sınıflandırma sistemleri bu problem için yeterli olamayabilir. Perakende sektöründe, raflardaki ürünler rastgele değil belli bir düzene göre sıralanır. Market ve satış potansiyelini en üst düzeye çıkarmak için ürün dizilimlerini içeren planogram olarak adlandırılan bir diyagram kullanılır. Planogram, ürünlerin raflarda nasıl ve nerede bulunacağını gösterir. Genel olarak, planogramlarda, aynı veya benzer ürünlerin birbirine komşu olma olasılığı daha yüksek olduğu görülmektedir. Ürün yerleştirmelerde hem marka hem de ürün boyutu açısından belli bir düzen ve devamlılık vardır. Bu bağlam bilgisi bize belirli ürünlerin birlikte bulunma ihtimali ve ürün dizilimlerinin olasılıksal modelinin oluşturulması hakkında bilgi verir. Özellikle veri zorlu olduğunda, bu olasılıksal model perakende ürün sınıflandırma sistemlerinin performansını artırabilir.

Son zamanlarda, perakende raflarda bulunan ürünlerin tanınması bilgisayarlı görme alanında popüler bir araştırma ko-



Şekil 1: Önerilen sistemin akış şeması.

nusu haline geldi [3]–[8]. Diğer uygulama alanlarında bağlam ve görüntüden elde edilen bilgiyi birleştiren hibrit yaklaşımlar olmasına rağmen, [9], [6]–[8] hariç literatürdeki perakende ürün sınıflandırma çalışmalarının birçoğunda ürün dizilimlerinden elde edilen olasılıksal model dikkate alınmamıştır. Bu bildiri de önerilen metodun ana amacı perakende ürün sınıflandırma probleminde olasılıksal ürün dizilim bilgisini kullanmak olduğu için önerilen yöntem literatürdeki diğer çalışmalardan ayrılmaktadır. [3]’teki çalışmada perakende ürün sınıflandırılması için hiyerarşik bir algoritma önerilmiştir. İlk olarak, bir test görüntüsünün ait olabileceği olası sınıflar basit bir sınıflandırıcı ile filtrelenir. Sonra, test görüntüsü ve filtrelenmiş olası sınıflar arasında hızlı yoğun piksel eşleştirmesi uygulanır. Bu çalışma ürün dizilimlerini istatistiksel olarak modellemek yerine benzer ürünlerin yan yana geldiği varsayımında bulunmaktadır. Bu çalışmadaki deneysel sonuçlar ürün dizilimleriyle alakalı bilginin perakende ürün sınıflandırma üzerinde olumlu etkisi olduğunu göstermektedir. [7]’deki yaklaşımda, sahnedeki perakende ürünler arasındaki bağı modelleyen bir çıkarım grafiği modeli, Vi-Co-Net, önerilmiştir ve 62 farklı perakende üründen oluşan bir veri kümesi kullanılmıştır. Bu çalışmanın asıl amacı sınıflandırıcı doğruluğundan çok verimliliği üzerinedir. Bizim yaklaşımımızın aksine, bu yöntemde birbirine çok benzeyen ürünler seviyesinde değil de farklı kategorilere ait ürünlerin sınıflandırılması amaçlanmıştır.

Bu bildiri de, birbirine çok benzeyen perakende ürünleri sınıflandıran hibrit bir bilgisayarlı görme sistemi öneriyoruz. Önerilen sınıflandırma sistemi, sadece ürün görüntüsünden bilgiyi değil aynı zamanda ürün dizilimleri arasındaki olasılıksal çıkarımı da kullanarak sınıflandırma sonucunu iyileştirmeyi amaçlamaktadır. Raftaki perakende ürünleri bir dizi olarak görülebilir. Ancak, literatürdeki perakende ürün tanıma sistemlerinin ürün dizilim bilgisinin kullanılması çok sınırlıdır. Önerilen hibrit yaklaşım bağlam bilgisi kullanmayan sınıflandırıcıyı ürün dizilimlerini grafiksel olarak modelleyen saklı Markov (HMM) modelleri ile birleştirir. Önerilen ürün sınıflandırma sistemi hem ürün görüntüsünden gelen bilgiden hem de raftaki komşu ürün dizilimleri arasındaki ilişkiden elde edilen bilgiden yararlandığı için geleneksel yöntemlere göre daha başarılı sonuçlar verdiği görülmektedir. Bu çalışmanın erken bir sürümü İngilizce olarak [10]’da sunulmuştur.

Bildirinin geri kalan kısmı aşağıdaki şekilde düzenlenmiştir: Bölüm II’de önerilen perakende ürün sınıflandırıcı ayrıntılarıyla açıklanmaktadır. Bölüm III’te deneylerde kullanılan zengin veri kümesi ve deney sonuçlarımız anlatılmaktadır.

## II. YÖNTEM

Önerilen sistemin amacı raflardaki ürün dizilimleri arasındaki ilişkileri kodlayan bir olasılıksal model oluşturmak ve bu modeli literatürde var olan bilgisayarlı görmedeki sınıflandırma yöntemiyle birleştirmektir. Önerilen sistem gelen raf sahnesinde, raftaki ürün dizilimlerini yatay komşuluk ilişkilerine göre bir zincir yapısıyla modeller. Şekil 1, sistemimizin genel akışını göstermektedir; önerilen sistem iki ana bölümden oluşur. Birinci bölümde, perakende ürünün görselinden elde edilen bilgiler kullanılarak sınıflandırma yapılır. İkinci bölümde ise, birinci bölümde elde ettiğimiz sınıflandırıcı sonucu ile, öğrenilen istatistiksel ürün dizilim modeli birleştirilerek ürün sınıfları çıkarılır. Önerilen ürün dizilim modeli zincir yapılı bir grafiksel modeldir; burada her düğüm bir ürünü temsil eder ve ayrıtlar ise komşu ürünler arasındaki ilişkileri kodlar. Bu çalışmada, raftaki zincir şeklindeki ürün dizilimleri olasılıksal grafiksel bir model olan HMM ile modellenir. Olasılık modelleri bağımsız sınıflandırıcının yaptığı hatalar ve perakende ürünler arasındaki komşuluk ilişkileri kullanılarak eğitilir.

### A. Dizilimden Bağımsız Sınıflandırıcı

Önerilen dizilimden bağımsız, sadece ürün görüntüsünden elde edilen özniteliklere göre sınıflandıran yöntem dört adımdan oluşmaktadır. Bunlar sırasıyla öznitelik çıkarımı, kelime öğrenme, mekansal histogram hesaplama ve sınıflandırıcının eğitilmesidir. Öznitelik çıkarım adımında, yoğun çoklu ölçekli (8 12 16 24) Ölçekten Bağımsız Öznitelik Dönüşümü (SIFT), VLFEAT araç kutusu kullanılarak uygulanır [11]. İkinci adımda, kelime öğrenmesi K-ortalama algoritması ile büyük öznitelik kümelerini 256 görsel kelimedenden oluşan sözlüğe dönüştürerek gerçekleştirilir. Uzaysal histogram hesaplamasında, Kd-ağacı algoritması kullanılır, elde edilen görsel kelimeler biraraya getirilerek histogramlar oluşturulur ve sonra doğrusal olmayan  $\chi^2$  ön dönüşümü uygulanır. Böylelikle çıkarılan özniteliklerin daha iyi bir şekilde doğrusal olarak sınıflandırılması sağlanır. Son adımda çok sınıflı doğrusal Destek Vektör Makinesi (SVM) sınıflandırıcı olarak kullanılır [12].

## B. Saklı Markov Modeli

Raftaki ürün dizilimlerini kullanan sistem, ürün dizilimlerini modelleyen HMM ile Bölüm II-A'da anlatılan görsel sınıflandırıcının birleştirilmesiyle oluşturulur. Raftaki ürün dizilim ilişkilerini modelleyen birinci mertebeden saklı Markov modeli Bölüm II-A'daki dizilimden bağımsız sınıflandırıcının sonucunu doğrulamak ve düzeltmek için eğitilir. Birinci mertebeden Markov zincirinde, gelecek düğüm geçmişteki bütün düğümlerden bağımsızdır sadece o anki düğüme bağlıdır [13].

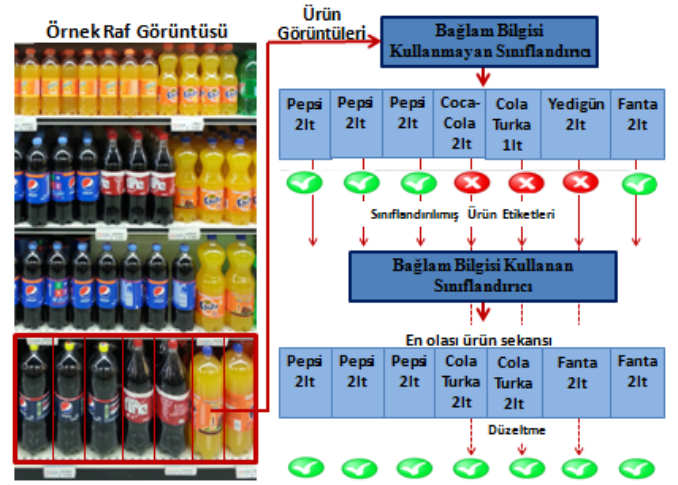
$$P(Y_t = j | Y_{t-1} = i) = \frac{\sum_{t=1}^T \mathbb{1}_{\{Y_{t-1}=i\}} \mathbb{1}_{\{Y_t=j\}}}{\sum_{t=1}^T \mathbb{1}_{\{Y_{t-1}=i\}}} \quad (1)$$

$$P(X = j | Y = i) = \frac{\sum_{t=1}^T \mathbb{1}_{\{Y_t=i\}} \mathbb{1}_{\{X_t=j\}}}{\sum_{t=1}^T \mathbb{1}_{\{Y_t=i\}}} \quad (2)$$

Bir HMM'yi öğrenmek için model parametrelerinin hesaplanması gerekir. Bunlar; geçiş matrisi, emisyon matrisi ve başlangıç durumlarının ön olasılıklarıdır. İlk olarak, durum geçiş olasılıkları,  $P(Y_t | Y_{t-1})$ ,  $Y_{t-1}=i$  sınıfındaki ürünün  $Y_t=j$  ürününe geçiş olasılığı, deneysel olarak Denklem 1'de gösterildiği gibi gözlemlenen perakende ürün dizileri üzerinde göreceli ürün geçiş frekansı hesaplanarak bulunur. İkinci olarak, emisyon olasılıkları  $P(X=j|Y=i)$  Denklem 2'ye göre deneysel olarak hesaplanır. Denklem 2'de  $X=j$  dizilimden bağımsız sınıflandırıcının sonucunu gösterirken,  $Y=i$  ise gerçek ürün sınıfını temsil etmektedir. Dolayısıyla, emisyon olasılık matrisi dizilimden bağımsız sınıflandırıcı tarafından elde edilen hata matrisini kullanarak hesaplanabilmektedir. Hata matrisi normalde sınıflandırıcının doğruluğunu ölçmek için kullanılsa da önerilen yöntemde yanlış sınıflandırılmış örnekleri yani emisyon olasılıklarını öğrenmede kullanılmaktadır. Öncül olasılıklar ise yine deneysel olarak başlangıç durumlarının frekansı hesaplanarak çıkarılır. Önerilen sınıflandırma algoritması dizilimden bağımsız sınıflandırıcı çıktısından bir dizi gözlemi girdi olarak alır. Aldığı bu dizi halindeki gözlemleri raftaki ürün dizilimlerinin istatistiksel modeline göre test eder. Eğitilmiş HMM ve Viterbi algoritması kullanılarak, en olası perakende raf dizileri dizilimden bağımsız sınıflandırıcının sonucunda gözlemlenen ürün sınıfları için çıkarılır. Önerilen yaklaşımın, ürün sınıflandırma sisteminin başarısını arttırdığı görülmüştür.

### 1) Saklı Markov Model Parametrelerinin İyileştirilmesi:

Olasılıkların ampirik olarak tahmin edilmesinde, bazı sınıflar için olasılıkların sıfır olarak hesaplanması problemi ile karşılaşılabilir. Laplace'ın Başarı Kuralına göre sıklıkla kullanılan en basit çözüm gözlemlenen her olaya sıfır olasılığına sahip olanlara dahil olmak üzere, 1 eklemektir. Ama az gözlemlenen durumlar için doğrudan 1 eklemek parametrelerin yanlış hesaplanmasına neden olabilmektedir. Bu problemten kaçınmak için olasılık hesaplamalarında her sınıf için ortak sabit bir sayı belirleyip bunu eklemek yerine her bir parametreyi öğrenmek için hesaplanan frekansa göre yüksek olasılıkla gözlemlenen durumları etkilemeyecek şekilde sapmalar hesaba dahil edilmiştir. HMM model parametreleri doğrudan veri kümesinden öğrenildiği için az örneğe sahip ürün sınıflarına bağlı

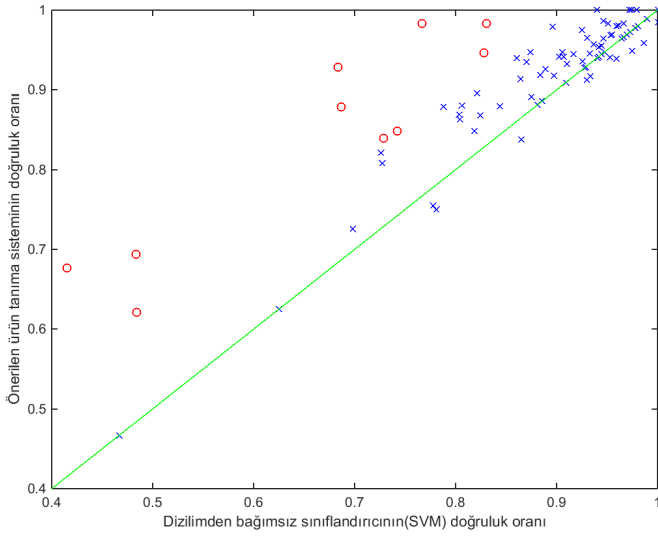


Şekil 2: Sol: Örnek raf görüntüsü, Sağ: İlk adımda, dizilimden bağımsız sınıflandırma uygulanır. İkinci adımda, ilk adımdan gelen sınıflandırma sonucu grafiksel ürün dizilim modeline göre başarıyı arttırmak için yeniden sınıflandırılır.

parametreler tam olarak doğru öğrenilememiş olabilmektedir. Yapılan analiz sonucu, sınıflandırma başarısını arttırmak için bu gibi az örneklili sınıflarda parametreleri öğrenirken veri kümesinden elde edilen bilgiye ek olarak perakende ürün dizilimleri ile ilgili aynı markanın benzer kategorisindeki aynı ebat ve paket tipine sahip olan ürünlerin yan yana gelmesinin daha olası olma bilgisi kullanılarak bu parametreler düzeltilmiştir.

## III. VERİ KÜMESİ VE DENEY SONUÇLARI

Bu çalışmada, 8MP akıllı telefon kamerasıyla toplanan toplam 11557 birbiriyle çakışmayan yatay raf dizilimine ait 794 farklı sınıfı içeren toplam 108090 adet meşrubat ürün görüntüsünden oluşan bir veri kümesi kullanılmıştır [14]. Her bir ürün sınıfına ait 10 ile 1154 arasında görüntü vardır. Veri kümesindeki ürün görüntülerinin %20'si dizilimden bağımsız sınıflandırıcıyı eğitmek için, %70'i dizilimden bağımsız sınıflandırıcının test veri kümesi ve aynı zamanda raf ürün dizilimlerini istatistiksel olarak modelleyen HMM'nin öğrenme veri kümesi olarak ve %10'u ise grafiksel model tabanlı sınıflandırıcıyı test etmek için kullanılır. Bu bildiride üç farklı deney gerçekleştirilmiştir. İlk deneyde veri kümesindeki 794 farklı perakende ürün sınıfı kullanılmış ve bu küme 'A veri kümesi' olarak adlandırılmıştır. 2. deneyde veri kümesindeki birbirine benzerliği yüksek olan 93 sınıf seçilmiştir ve bu küme 'B veri kümesi' olarak tanımlanmıştır. Son deneyde B veri kümesindeki ürün görüntüleri Gauss filtresi ile bulanıklaştırarak deney tekrarlanmıştır. Tablo 1'de yukarıda belirtilen deneyler için ürün diziliminden bağımsız sınıflandırıcı ile önerilen yöntemin karşılaştırmaları gösterilmektedir. Deney sonuçlarına göre önerilen yöntemin dizilimden bağımsız sınıflandırıcıya göre ürünleri daha doğru sınıflandırdığı ve HMM tabanlı yöntem kullanılarak dizilimden bağımsız sınıflandırıcının doğruluk oranında A veri kümesi için %9.95 iyileşme sağladığı görülmektedir. Bölüm II-B1'de anlatıldığı gibi HMM model parametreleri doğrudan veri kümesinden öğrenildiğinden, deney sonuçlarına göre, az örneğe sahip perakende ürün sınıflarına bağlı parametreler tam olarak doğru öğrenilememiş olabilmektedir. Yapılan deneyde, parametreleri öğrenirken veri kümesinden elde edilen bilgiye ek olarak kullanılan ürün dizilimleri ile ilgili aynı



Şekil 3: Dizilimden bağımsız ve dizilime bağlı sınıflandırma yöntemlerinin karşılaştırması. Köşegenin üstündeki noktalar önerilen yöntemdeki iyileştirmelere karşılık gelmektedir.

markanın benzer kategorisindeki aynı ebat ve paket tipine sahip olan ürünlerin yan yana gelmesinin daha olası olma bilgisi doğru sınıflandırma oranını A veri kümesi için %78.02'den %78.4'e çıkardığı görülmüştür.

2. ve 3. deneylerde ürün sınıflandırmadaki iki temel probleme odaklanılmıştır. Problemlerin ilki sınıfların birbirine çok benzemesidir ve ikincisi ise raftaki ürünlerin dönmüş, devrilmiş olması veya çeşitli nedenlerden dolayı ürün görüntüsünün bozuk olmasıdır. B veri kümesi ile ilk sorun için deneyler yapılmıştır ve önerilen sistemin ayrıştırılması insanlar için dahi zor olabilecek sınıflarını düzgün bir şekilde sınıflandırdığı ve tüm sınıflar için ortalama %3'lük bir iyileşme sağlandığı görülmüştür. Ürün dizilim modelinin özellikle ayrıştırılması sorunlu olan sınıflar için sonucu iyileştirdiği görülmektedir. Örneğin B veri kümesinde bulunan, Coca-Cola'nın 1 lt ve 1.5 lt ürünlerini ayıran tek özelliklik 1.5 lt olan ürünün biraz daha büyük olmasıdır. Gözle bile ayırt edilmesi zor olan bu sınıflandırmanın telefonla çekilmiş ürün görüntüsünden yapılabilmesi çok daha zordur. Şekil 3'te farklı ürün sınıfları için önerilen ürün dizilimlerine bağlı ve dizilimden bağımsız sınıflandırıcıların her bir sınıf için verdiği doğruluk oranları gösterilmektedir ve kırmızı yuvarlak işaretler önerilen yöntem ile sınıflandırıcı doğruluk oranında %10'dan fazla artışa sahip sınıfları göstermektedir. Örneğin, dizilimden bağımsız sınıflandırıcı ile Coca-Cola'nın 1lt ürünü %48.3 oranla doğru sınıflandırılırken, önerilen raf dizilim modeli ile bu oran %68.9'a çıkmıştır. Bu deneyde, önerilen modeli, raftaki ürün dizilimlerinde marka ve ebat açısından devamlılık olduğunu veri kümesinden öğrendiği için ilk sınıflandırıcının hatalarını düzelttiği görülmektedir. Son deneyde, veri kümesinde en çok karşılaşılan bulanık ürün görüntülerinin sınıflandırılması problemi üzerinde çalışılmıştır. Birbirine benzeyen sınıflarda bir de bulanık görüntü sorunu eklenince 2. deneye kıyasla 3. deneyde dizilimden bağımsız sınıflandırıcı başarısı %6.77 düşmüştür. Önerilen sistemin öğrenmiş olduğu koşullardan sapmalar olduğu durumlarda bile yeterince iyi sonuç verdiği ve ürün tanıma sisteminin, sınıflandırma başarısı düştükçe daha

TABLO I: PERAKENDE ÜRÜN SINIFLANDIRICI BAŞARILARI

Metot	Farklı Veri Kümeleri İçin Test Doğruluğu		
	A veri kümesi	B veri kümesi	C veri kümesi
Dizilimden Bağımsız	%68.45	%91.93	%85.16
Dizilime Bağlı	%78.40	%94.92	%90.79

yüksek oranda iyileştirme sağladığı görülmektedir.

#### IV. SONUÇ

Raftaki ürün dizilimleri için uygun bir zincir yapıda grafiksel model kullanıldığı ve dizilimden bağımsız sınıflandırıcı hataları öğrenildiği takdirde perakende ürün tanıma sisteminin başarı oranının arttığı görülmüştür. Gelecekteki çalışmalarda, yatay düzlemde modellenen ürünlerin komşuluk ilişkilerini hem yatay hem de dikey düzlemde modelleyerek ürün tanıma sisteminin başarısını arttırmak hedeflenmektedir.

#### TEŞEKKÜR

Bu çalışma TÜBİTAK tarafından yurt içi doktora burs programı ile desteklenmiştir.

#### KAYNAKLAR

- [1] Yao, B., Khosla, A., and Fei-Fei, L. (2011, June). Combining randomization and discrimination for fine-grained image categorization. In *Conference on Computer Vision and Pattern Recognition (CVPR)*. 2011.
- [2] Berg, T., Liu, J., Lee, S. W., Alexander, M. L., Jacobs, D. W., and Belhumeur, P. N. Birdsnap: Large-scale fine-grained visual categorization of birds. In *Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2014.
- [3] M. George and C. Floerkemeier. Recognizing products: A per-exemplar multi-label image classification approach. In *ECCV*, 2014.
- [4] M. Merler, C. Galleguillos, and S. Belongie. Recognizing groceries in situ using in vitro training data. In *CVPR*, 2007.
- [5] S. S. Tsai, D. M. Chen, V. Chandrasekhar, G. Takacs, N. M. Cheung, R. Vedantham, R. Grzeszczuk, and B. Girod. Mobile product recognition. In *ACM Multimedia (ACM MM)*, 2010.
- [6] George, M., Mircic, D., Soros, G., Floerkemeier, C., and Mattern, F. (2015). Fine-Grained Product Class Recognition for Assisted Shopping. In *Proceedings of the IEEE International Conference on Computer Vision Workshops* (sayfa. 154-162).
- [7] Advani, S., Smith, B., Tanabe, Y., Irick, K., Cotter, M., Sampson, J., and Narayanan, V. (2015, October). Visual co-occurrence network: using context for large-scale object recognition in retail. In *Symposium on Embedded Systems For Real-time Multimedia (ESTIMedia)*. IEEE, 2015.
- [8] Marder, M., Harary, S., Ribak, A., Tzur, Y., Alpert, S., and Tzadok, A. (2015). Using image analytics to monitor retail store shelves. *IBM Journal of Research and D*.
- [9] Rabinovich, A., Vedaldi, A., Galleguillos, C., Wiewiora, E., and Belongie, S. (2007, October). Objects in context. In *Computer vision*, 2007. ICCV 2007. IEEE 11th international conference on (sayfa. 1-8). IEEE.
- [10] Baz, I., Yoruk, E., and Cetin, M. (2016, July). Context-aware hybrid classification system for fine-grained retail product recognition. In *Image, Video, and Multidimensional Signal Processing Workshop (IVMSP)*, 2016 IEEE 12th (sayfa. 1-5). IEEE.
- [11] Vedaldi, A., and Fulkerson, B. (2010, October). VLFeat: An open and portable library of computer vision algorithms. In *Proceedings of the 18th ACM international conference on Multimedia* (sayfa. 1469-1472).
- [12] Chang, C. C., and Lin, C. J. (2011). LIBSVM: a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2(3), 27.
- [13] Rabiner, L. R., and Juang, B. H. (1986). An introduction to hidden Markov models. *ASSP Magazine, IEEE*, 3(1), 4-16.
- [14] Vispera Bilgi Teknolojileri, İstanbul, Türkiye. [Online]. www.vispera.co