

Farklı Sınıflandırma Yöntemlerinin Çoklu Benzer Perakende Ürünlerin Sınıflandırılması Problemi için Karşılaştırılması

On Comparison of Different Classification Techniques for the Fine-Grained Retail Product Recognition Problem

Osman Berk Şatır, İpek Baz, Ertunç Erdil ve Müjdat Çetin
Mühendislik ve Doğa Bilimleri Fakültesi
Sabancı Üniversitesi
İstanbul, Türkiye

obsatir@sabanciuniv.edu, ibaz@sabanciuniv.edu, ertuncerdil@sabanciuniv.edu, mctetin@sabanciuniv.edu

Özetçe—Günümüzde, otomatik perakende ürün sınıflandırma sistemleri gün geçtikçe önem kazanmaktadır. Perakende ürün sınıf sayısının çok fazla ve bu ürünlerin birbirine benzer olması pek çok uygulama alanı olan bu tip ürün tanıma sistemlerinin tasarımı zor ve karmaşık bir problem haline getirmektedir. Bu bildiriye, bilgisayarlı görü alanında görüntü sınıflandırma için sıklıkla kullanılan farklı sınıflandırma tekniklerinin, süpermarkette akıllı telefon ile çekilmiş raftaki perakende ürünlerin tanınması problemi üzerindeki başarımlarının karşılaştırmasını içeren bir çalışma sunulmaktadır.

Anahtar Kelimeler—Çoklu benzeyen ürünlerin sınıflandırılması, sınıflandırma, destek vektör makineleri, softmax bağlantısı, k en yakın komşuluk, evrimsel sinir ağları.

Abstract—Classification systems of retail products have recently been gaining more importance. There are many classes of retail products and the resemblance of these products makes the design of product recognition systems, which have many application areas, more challenging. In this paper, we present a comparison of different classification techniques that are widely used in computer vision for image classification on retail product images taken by smart-phones.

Keywords—Fine-grained retail product recognition, classification, support vector machines, softmax regression, k nearest neighbors, convolutional neural networks.

I. GİRİŞ

Günümüzde, görüntü sınıflandırma birçok farklı uygulamada sıklıkla kullanılmaktadır. Bu uygulamalardaki genel amaç görüntü içinde bulunan nesnenin sınıfını tanımaya çalışmaktır. Literatürde görüntü sınıflandırma problemine çoklu ikili sınıflandırıcıları veya çok sınıflı sınıflandırıcıları eğiterek farklı çözüm önerileri sunulmuştur [1], [2].

Son zamanlarda, perakende ürünleri tanıma uygulamaları ilginç hale gelmiştir. Bu uygulamaların, perakende ürünlerinin incelenmesi, fiyat bilgilerinin alınması, süpermarketlerdeki navigasyona ve görme engelli kişilere alışverişte yardımcı olması ve üreticiler için ürün takip sistemleri kurulması gibi çok geniş yelpazede kullanım alanları vardır. Bu problemde görüntüler birçok bilgisayarlı görme uygulamalarında olduğu gibi ideal stüdyo ortamında değil, mağazalarda cep telefonlarıyla çekilen gerçek dünya görüntüleridir. Bu nedenle, toplanan ürün görüntüleri bulanıklık, alışılmadık görüş açısı, arka planda dağınıklık ve çok farklı aydınlatma koşulları gibi problemleri içermektedir. Ayrıca marketlerde çok sayıda farklı perakende ürün sınıfları vardır ve farklı sınıflara ait ürünler birbirlerine çok benzemektedir. Tüm bunlar perakende ürün sınıflandırma problemini daha da zor hale getirmektedir.

Sistemimiz çoklu benzer kategorili sınıflandırma sorunu ile ilgilidir. Bilgisayarla görme alanında birbirine benzeyen ürün sınıflarını tanımak için farklı yöntemler uygulanmaktadır. Literatürdeki kuş türleri, çiçek ve yaprak çeşitlerini sınıflandırma uygulamaları gibi uygulamalar da birbirine benzeyen sınıflardan oluştuğu için perakende ürün tanıma problemine benzerlik göstermektedir. Perakende ürün tanıma problemi bilgisayarlı görme teknikleriyle otomatik olarak çözülebileceği için son bir kaç yılda konu ile ilgili çalışmalar hız kazanmıştır [3]–[5].

Bu çalışmalardan [3]'te görüntü alımı yöntemi uygulanmaktadır. Görsel olarak sisteme gelen perakende ürün görüntüsünün sorgu görüntülerine benzerliği hesaplanır ve buna göre sınıflandırma gerçekleştirilir. [4]'te önerilen yöntemde 120 sınıftan oluşan GROZL-120 veri kümesi üzerinde çalışmalar yapılmıştır. Her test görüntüsü raf görüntüsünden elle ayrılmış tek bir ürün görüntüsünden oluşur. Bu çalışmada ölçekten bağımsız öznitelik (SIFT), renk histogramı ve Haar yöntemleriyle öznitelikler oluşturulmuş ve öznitelik eşleştirmesi ile sınıflandırma gerçekleştirilmiştir. [5]'te 26 perakende ürün sınıfından

oluşan veri kümesi üzerinde çalışma yapılmıştır. Bu çalışmada ürün görüntüleri üzerinde ayrıştırıcı parçalar tanımlanmaktadır. Buna ilaveten ürün ambalajlarının üzerindeki yazıları tanıyan bir sistemle sınıflandırıcılarının başarısını arttırmaktadırlar.

Bu çalışmada gerçekleştirilen, softmax bağlantı yöntemi, k en yakın komşuluk yöntemi, destek vektör makineleri ve evrişimsel sinir ağları (ESA) gibi sınıflandırıcıların çoklu benzer kategorili sınıflandırma problemindeki başarılarının elde edilmesi ve karşılaştırılmasıdır. Perakende ürün sınıflandırma problemi çok sayıda farklı sınıftan oluşan ve farklı sınıflardaki ürünlerin birbirine görsel olarak çok benzediği karmaşık bir problemdir. Klasik tek katmandan oluşan sınıflandırıcıların yanı sıra günümüzde sıklıkla kullanılmaya başlanılan derin öğrenme metodlarından olan ESA metodu karşılaştırmalarda kullanılmıştır. Çalışmanın sonucunda evrişimsel sinir ağlarının diğer sıkça kullanılan sınıflandırıcılara göre daha başarılı olduğu gözlenmiştir. Bildirimizin özgün katkısı derin öğrenme bakış açısını temsil eden evrişimsel sinir ağları yönteminin birbirine benzeyen sınıflar içeren perakende ürün tanıma problemine ilk defa uygulanması ve bu problem üzerinde çeşitli sınıflandırıcıların başarılarının karşılaştırmalı analizinin gerçekleştirilmesidir.

Bildirinin geri kalan kısmı aşağıdaki şekilde düzenlenmiştir. 2. Bölümde önerilen perakende ürün sınıflandırıcıları sunulmaktadır. 3. Bölümde veri kümesi ile ilgili bilgi ve deney sonuçlarımız verilmektedir.

II. YÖNTEMLER

Bu bölümde, performansını karşılaştırdığımız sınıflandırma yöntemlerinden ve çoklu benzer kategorili sınıflandırma problemine nasıl uygulandıklarından kısaca bahsetmekteyiz.

A. Softmax bağlantı yöntemi

Softmax bağlantı (SB) yöntemi [2], lojistik bağlantı yönteminin birden fazla sınıfa ait verilerden oluşan bir eğitim kümesinden öğrenebilecek şekilde genelleştirilmiş halidir. Bir başka ifadeyle, verilere ait etiketler K adet farklı değer olabilir. Böylece, $x^{(i)} \in \mathcal{R}^n$ olmak üzere, m adet örnekten oluşan bir $\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$ eğitim veri kümesi için sınıf etiketleri $y^{(i)} \in \{1, 2, \dots, K\}$ olmaktadır. Softmax bağlantı yöntemi, $h_\theta(x)$ hipotez fonksiyonunun, verilen bir x test verisi için, o verinin her bir k sınıfında ($k = 1, \dots, K$) bulunma olasılığını hesaplar. Buna göre hipotez fonksiyonu $h_\theta(x)$ K -boyutlu bir fonksiyon olup

$$h_\theta(x) = [p(y = 1|x; \theta), \dots, p(y = K|x; \theta)] \\ = \frac{1}{\sum_{j=1}^K \exp(\theta^{(j)T} x)} [\exp(\theta^{(1)T} x), \dots, \exp(\theta^{(K)T} x)]^T \quad (1)$$

denklemleriyle hesaplanır. Burada, $\theta^{(1)}, \dots, \theta^{(K)} \in \mathcal{R}^n$ eğitim veri kümesinden öğrenilen model parametreleridir. Model parametreleri

$$H(y, z) = - \sum_{i=1}^m y^{(i)} \log(z_i) \quad (2)$$

çapraz entropi fonksiyonunun en küçüklenmesiyle bulunur. Burada $y^{(i)}$, $x^{(i)}$ eğitim örneğinin doğru etiketini gösteren ve z_i ise öğrenilen model tarafından tahmin edilen ($z_i = h_\theta(x^{(i)})$), $x^{(i)}$ verisinin her bir sınıfta bulunma olasılığını

gösteren K boyutlu birer vektördür. Bu bildirideki deneylerde x imge piksellerine karşılık gelen bir vektör olup, y ise x verisinin her bir sınıfa ait olma olasılıklarını gösteren K boyutlu bir vektör olarak alınmıştır.

B. k en yakın komşuluk yöntemi

k en yakın komşuluk sınıflandırıcısı (k EYK) en temel sınıflandırma yöntemlerinden biridir [6]. $x^{(i)} \in \mathcal{R}^n$ ve K etiket sayısı olmak üzere, $\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$, $y^{(i)} \in \{1, 2, \dots, K\}$, eğitim veri kümesinin verildiğini kabul edelim. Buna göre k en yakın komşuluk sınıflandırıcısı yönteminde, verilen bir x test verisinin her bir $x^{(i)}$, $1 \leq i \leq m$ eğitim verisine uzaklığı bir uzaklık metriği ile hesaplanır. Bu metriğe göre, eğitim veri kümesindeki x test verisine en yakın k adet eğitim verisi, $\{x^{(u_1)}, \dots, x^{(u_k)}\}$ ($\{u_1, \dots, u_k\} \subseteq \{1, \dots, m\}$ olmak üzere) bulunur. Son olarak, $\{y^{(u_1)}, \dots, y^{(u_k)}\}$ kümesinde en çok tekrarlanan etiket, x test verisinin etiketi olarak karar verilir.

C. Destek vektör makineleri

Destek vektör makineleri (DVM), sıkça kullanılan bir sınıflandırma yöntemidir [7]. Elimizde $x^{(i)} \in \mathcal{R}^n$ olmak üzere $\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$, $y^{(i)} \in \{1, -1\}$ şeklinde bir eğitim veri kümesi olduğunu kabul edelim. Bu durumda eğitim verilerinin bir kısmı pozitif, geriye kalan kısmı ise negatif sınıfa ait olarak kabul edilebilir. Pozitif olanları, negatif olanlardan ayıran bir ayırıcı düzlem olduğunu varsayarsak ve d_+ ve d_- sırasıyla ayırıcı düzleme en kısa mesafede olan pozitif ve negatif örnek olarak tanımlanırsa, destek vektör algoritması, $d_+ + d_-$ toplamının en fazla olduğu ayırıcı düzlemi arayarak verileri iki ayrı sınıf olacak şekilde sınıflandırma yapar [8].

Destek vektör makineleri, iki sınıf için sınıflandırma yapmaya olanak sağlar. Ancak uygulamada genellikle ikiden fazla sınıf arasında sınıflandırılma yapılması gerekebilir. Bunun için kullanılan yaklaşımlardan bir tanesi bire-karşı-kalanı yaklaşımıdır [2]. Toplamda K tane sınıf olduğunu varsayarsak bu yaklaşıma göre K tane destek vektör makinesi oluşturulup her sınıf için o sınıfa ait eğitim verileri pozitif, geriye kalan veriler negatif olarak etiketlenilerek ikiden fazla sınıf için sınıflandırma yapılır. Bu çalışmada doğrusal çekirdek ile bire-karşı-kalanı yaklaşımı kullanılmıştır.

D. Evrişimsel sinir ağları

Evrişimsel sinir ağları (ESA), pek çok katmandan oluşan ve sinir ağlarının ızgara benzeri topolojiye sahip verinin işlenmesi için özelleşmiş şeklidir. Evrişimsel ağların, sinir ağlarından en temel farkı, en az bir katmanında matris çarpımı yerine evrişim işleminin kullanılmasıdır. Resim verisi, bu tarz veri çeşidi olarak örnek verilebilir ve evrişimsel sinir ağları ile işlenebilir. Evrişimsel ağlar, uygulamalarda oldukça başarılı bir yöntem olarak nitelendirilmektedir [9].

Evrişimsel sinir ağları, pek çok katmana sahip olabilir. Bu katmanlara örnek olarak evrişim işleminin gerçekleştiği evrişim katmanı ve örnek seyretmenin gerçekleştiği havuzlama katmanı örnek verilebilir. Bu çalışmada kullanılan derin mimaride [10] ilk katman olan girdi katmanında eğitim verileri bulunmaktadır. Daha sonrasında gelen evrişim katmanı ile resimdeki anlamlı öz nitelikler elde edilmektedir. Evrişim katmanından sonra gelen havuzlama katmanı ile de resim boyutu

yarıya düşürülerek tekrar bir evrişim katmanına verilmektedir. Sonraki katmanda tekrar 2 çarpanıyla örnek seyreltme gerçekleştirildikten sonra en son katmanda tamamen bağlı bir ağ bulunur. ESA'nın en son katmanı, her görüntünün hangi sınıfa ait olduğunu çıktı olarak verir.

III. DENEYSSEL SONUÇLAR

Bu bölümde, gerçekleştirilen testler ve onların sonuçlarından bahsetmekteyiz. Tüm deneylerde meşrubat ürünleri veri kümesi kullanılmıştır [11]. Veri kümesi market raflarından toplanan 3920 adet perakende ürün görüntüsünden oluşmaktadır. Görüntüler 8MP akıllı telefon kamerasıyla toplanmıştır. Veri kümesi ürün sınıf etiketleri ve sınırlayıcı kutularla çevrelenmiş ürünleri içeren perakende raf görüntülerinden oluşmaktadır. 794 farklı sınıfı içeren toplam 108090 adet meşrubat ürün görüntüsü bulunmaktadır.

Bu çalışmada, Bölüm 2'de bahsedilen sınıflandırıcılar ile dört değişik durumda testler gerçekleştirilmiştir. Bu testler, rastgele seçilmiş 5 ve 15 sınıf ile birbirine çok benzeyen 5 ve 15 sınıf içeren problemlerde, bahsedilen sınıflandırıcıların çoklu benzer kategorili sınıflandırmadaki başarımlarının ölçülmesini ve karşılaştırılmasını kapsamaktadır. Birbirine benzeyen ve rastgele seçilmiş 5 sınıftan örnek görüntüler Şekil 1 ve Şekil 2'de gösterilmektedir. Her test için sınıfların seçilmesinden sonra bu sınıfa ait resim verilerinin yüzde 70'i eğitim, geriye kalan yüzde 30'u ise test verisi olarak 5 kez rastgele seçilmiş ve sınıflandırıcıların başarımları değişik eğitim ve test verilerinde gözlemlenmiştir. Birbirine çok benzeyen 5 sınıf için toplamda 3213 eğitim ve 1381 test verisi, 15 sınıf için 7740 eğitim ve 3325 test verisi kullanılmıştır. Rastgele seçilen 5 sınıfta ise 1868 eğitim ve 776 test verisi, 15 sınıfta ise 5625 eğitim ve 2379 test verisi kullanılmıştır.

Softmax bağlanımı yöntemi, k en yakın komşuluk yöntemi ve destek vektör makinelerinde eğitim ve test verisi olarak kullanılan resimler 190×190 boyutunda iken evrişimsel sinir ağlarının başarımları ölçmek için kullanılan resimler 28×28 boyutundadır. Bunun sebebi, büyük resimlerde evrişimsel sinir ağlarının bilinen bir problemi olan yavaş çalışması ve yüksek başarımlı sonuçlar elde edilebilmesi için daha fazla eğitilmesi gerekliliğidir. k en yakın komşuluk yöntemi ile yaptığımız deneylerimizde $k = 5$ olarak alınmıştır.

Bütün test sonuçları incelendiğinde, evrişimsel sinir ağlarının diğer sınıflandırıcılara göre çoklu benzer kategorili sınıflandırmada daha başarılı olduğu gözlemlenmiştir. Tablo 1'de birbirine benzeyen 5 sınıf için sınıflandırıcıların başarımlarını sunulmuştur.



Şekil 1: Birbirine benzeyen 5 perakende ürün sınıfı.

TABLO I: Birbirine benzeyen 5 sınıf için sınıflandırıcıların başarımları.

	Test 1	Test 2	Test 3	Test 4	Test 5	Ortalama
SB	%88.56	%91.96	%90.51	%91.45	%91.38	%90.77
k EYK (Öklit)	%76.88	%81.17	%82.62	%81.25	%80.96	%80.58
k EYK (Spearman)	%90.22	%92.25	%92.61	%92.61	%92.18	%91.97
DVM	%86.75	%88.56	%88.49	%88.34	%88.05	%88.03
ESA	%94.57	%94.42	%95.51	%95.87	%93.99	%94.87

Birbirine benzeyen 5 sınıf için bahsedilen sınıflandırıcılarla sınıflandırma yapıldığında evrişimsel sinir ağlarının başarımlarının ortalama olarak yüzde 95'e yakın olduğu görülmektedir. k en yakın komşuluk yönteminin başarımları ise kullanılan uzaklık metriğine göre değişmekte olup, Spearman uzaklık metriği kullanıldığında ortalama yüzde 92'ye yakın bir başarımlar elde edilmiştir. Öklit uzaklık metriği kullanıldığında ise bu başarımlar değişik eğitim ve test verileriyle yüzde 76 ve 83 arasında değişmektedir. Softmax bağlanımı yöntemi ve destek vektör makinelerinin başarımları sırasıyla ortalama yüzde 91 ve yüzde 88 olarak gözlenmektedir.

Tablo 2'de birbirine benzeyen 15 sınıf için bahsedilen sınıflandırıcıların başarımları gözlemlenebilir.

TABLO II: Birbirine benzeyen 15 sınıf için sınıflandırıcıların başarımları.

	Test 1	Test 2	Test 3	Test 4	Test 5	Ortalama
SB	%85.20	%80.30	%79.70	%85.62	%79.85	%82.13
k EYK (Öklit)	%70.29	%74.38	%75.04	%75.55	%74.62	%73.98
k EYK (Spearman)	%86.50	%87.94	%87.97	%87.43	%88.09	%87.59
DVM	%74.26	%74.29	%75.34	%74.44	%75.70	%74.80
ESA	%90.62	%91.49	%90.86	%91.49	%91.67	%91.22

Sınıf sayısı 5'ten 15'e çıkartıldığında, beklenildiği üzere bütün sınıflandırıcıların başarımlarında azalma gözlenmiştir. Daha önce bahsedildiği gibi, evrişimsel sinir ağlarının yüzde 90'ın üzerinde bir başarı oranıyla sıkça kullanılan diğer sınıflandırıcılara kıyasla daha başarılı olduğu görülmektedir. k en yakın komşuluk yönteminde uzaklık metriği Öklit uzaklığı olarak seçildiğinde başarı oranı ortalama olarak yüzde 74 olmaktadır.

Tablo 3'te sınıflandırıcıların rastgele seçilmiş 5 sınıf üzerindeki başarımlarını sunulmaktadır.



Şekil 2: Rastgele seçilmiş 5 perakende ürün sınıfı.

Tablo 3'e bakıldığında, 5 sınıfın rastgele seçildiği durumda bütün sınıflandırıcıların başarımlarının bazı testlerde yüzde 90'ın üzerinde olduğu görülmektedir. Evrişimsel sinir ağlarının bu

TABLO III: Rastgele seçilmiş 5 sınıf için sınıflandırıcıların başarımları.

	Test 1	Test 2	Test 3	Test 4	Test 5	Ortalama
SB	%94.20	%92.78	%92.27	%92.65	%93.3	%93.04
<i>k</i> EYK (Öklit)	%89.30	%90.08	%89.69	%90.21	%90.72	%90.00
<i>k</i> EYK (Spearman)	%94.07	%92.91	%94.20	%94.07	%94.07	%93.86
DVM	%90.21	%87.89	%86.60	%90.85	%88.27	%88.76
ESA	%97.42	%97.16	%96.91	%97.81	%97.55	%97.37

testlerdeki başarımının ise yine diğer sınıflandırıcılara kıyasla oldukça yüksek olduğunu söylemek mümkündür.

Tablo 4'te, sınıflandırıcıların rastgele seçilmiş 15 sınıf üzerinde test edildiklerindeki başarım yüzdeleri görülmektedir.

TABLO IV: Rastgele seçilmiş 15 sınıf için sınıflandırıcıların başarımları.

	Test 1	Test 2	Test 3	Test 4	Test 5	Ortalama
SB	%81.42	%80.45	%79.61	%79.27	%81.55	%80.46
<i>k</i> EYK (Öklit)	%74.40	%80.45	%79.40	%78.81	%78.86	%78.38
<i>k</i> EYK (Spearman)	%79.95	%82.72	%83.27	%84.20	%84.32	%82.89
DVM	%66.08	%67.30	%67.72	%67.63	%67.89	%67.32
ESA	%88.02	%87.18	%86.76	%86.04	%85.29	%86.65

Tablo 4'te, daha önce olduğu gibi, sınıf sayısı 5'den 15'e çıkartıldığında başarım yüzdelerinin düştüğünü görmek mümkündür. Evrimsel sinir ağları, yine en yüksek başarıma sahip sınıflandırıcı olup, Test 1'deki eğitim ve test verileri üzerinde yüzde 88.02 başarım yüzdesine sahiptir. Bunun yanında benzer uygulamalarda sıkça kullanılan destek vektör makinesi, aynı verilerle yalnızca yüzde 66.08 başarım yüzdesine sahiptir.

Rastgele seçilmiş 15 sınıf için sınıflandırıcıların başarımı, birbirine benzeyen 15 sınıf için sınıflandırıcıların başarımından daha yüksek olması beklenirken bu durumun tam tersinin gerçekleştiği gözlemlenmiştir. Bu durumun sebebi, rastgele seçilmiş 15 sınıfın içindeki bazı ürünlerin boyutlarının normalde birbirinden farklı olmasına rağmen görüntüler market ortamında elde edildiği için aradaki farkın ayırt edilmesinin zorlaşmasıdır. Şekil 3'te sırasıyla 450 mililitre ve 1 litre hacimli iki ürünün resimlerini görmek mümkündür.



Şekil 3: Aynı ürünün farklı boyutlarının (sol: 450 mililitre, sağ: 1 litre) bulunduğu iki farklı sınıftan birer örnek.

IV. VARGILAR

Bu bildiriye, çoklu benzer kategorili sınıflandırma problemi için softmax bağlantımı, k en yakın komşuluk, destek vektör makineleri ve evrimsel sinir ağları olmak üzere dört değişik sınıflandırıcı karşılaştırılmıştır. Bildiri dahilinde gerçekleştirilen deneylerin sonuçlarına bakılarak, evrimsel sinir ağları gibi derin mimariye sahip olan sınıflandırıcıların çoklu benzer kategorili sınıflandırma probleminde, klasik sınıflandırıcılara kıyasla daha başarılı olabileceği söylenebilir. Evrimsel sinir ağlarının, klasik sınıflandırıcılara kıyasla çoklu benzer kategorili sınıflandırma probleminde daha başarılı olmasının sebebi, diğer sınıflandırıcılara göre daha karmaşık yapıları öğrenilmesi olarak söylenebilir. Evrimsel sinir ağlarının bu problemdeki başarımı, daha çok katmanlı ve daha gelişmiş bir derin mimariye sahip bir ağ ile daha da yükseltilebilir. İleride gerçekleştireceğimiz çalışmaların temeli, kullandığımız derin mimariyi daha gelişmiş hale getirmek, kullanılan veri kümesindeki sınıf ve görüntü sayısını artırmak olacaktır.

TEŞEKKÜR

Bu bildiriye çalışmalarda 'Vispera Bilgi Teknolojileri' kurumu tarafından sağlanan veri kümesi kullanılmıştır. Vispera Bilgi Teknolojileri'ne ve Dr. Erdem Yoruk'a katkılarından dolayı teşekkür ederiz.

KAYNAKLAR

- [1] R. Jain, R. Kasturi, and B. G. Schunck, *Machine vision*. McGraw-Hill New York, 1995, cilt. 5.
- [2] C. M. Bishop, "Pattern recognition and machine learning," 2006.
- [3] M. George and C. Floerkemeier, "Recognizing products: A per-exemplar multi-label image classification approach," in *European Conference on Computer Vision*. Springer, 2014, sayfa 440-455.
- [4] M. Merler, C. Galleguillos, and S. Belongie, "Recognizing groceries in situ using in vitro training data," in *Computer Vision and Pattern Recognition*,. IEEE, 2007, sayfa1-8.
- [5] M. George, D. Mircic, G. Soros, C. Floerkemeier, and F. Mattern, "Fine-grained product class recognition for assisted shopping," in *Proceedings of the IEEE International Conference on Computer Vision Workshops*, 2015, sayfa 154-162.
- [6] V. Kumar, M. Steinbach, and P.-N. Tan, *Introduction to data mining*. Pearson Education India, 2006.
- [7] A. Ben-Hur and J. Weston, "A user's guide to support vector machines," 2010.
- [8] C. J. Burges, "A tutorial on support vector machines for pattern recognition," 1998.
- [9] Y. Bengio, I. J. Goodfellow, and A. Courville, *Deep learning*. MIT Press, 2016.
- [10] R. B. Palm, "Prediction as a candidate for learning deep hierarchical models of data," Master's thesis, 2012.
- [11] "Vispera Bilgi Teknolojileri, İstanbul, Turkey," www.vispera.co.