



Derin Öğrenme ile Mobil Cihazlar üzerinde bir Fiyat Etiket Tespit Sisteminin Geliştirilmesi

Melek Turan¹, Musa Peker^{2*}, Hüseyin Özkan³, Cevat Balaban⁴, Nadir Kocakır⁵, Önder Karademir⁶

¹ Özdilek Ev Tekstil Sanayi ve Ticaret A.Ş., Özveri Ar-Ge Merkezi, Bursa, Türkiye, Orcid Id: 0000-0002-1873-4980, melek.turan@ozdilek.com.tr

² Özdilek Ev Tekstil Sanayi ve Ticaret A.Ş., Özveri Ar-Ge Merkezi, Bursa, Türkiye, Orcid Id: 0000-0002-1445-7410, musa.peker@ozdilek.com.tr

³ Özdilek Ev Tekstil Sanayi ve Ticaret A.Ş., Özveri Ar-Ge Merkezi, Bursa, Türkiye, Orcid Id: 0000-0003-4169-4259, huseyin.ozkan@ozdilek.com.tr

⁴ Özdilek Ev Tekstil Sanayi ve Ticaret A.Ş., Özveri Ar-Ge Merkezi, Bursa, Türkiye, Orcid Id: 0000-0002-5165-3082, cevat.balaban@ozdilek.com.tr

⁵ Özdilek Ev Tekstil Sanayi ve Ticaret A.Ş., Özveri Ar-Ge Merkezi, Bursa, Türkiye, Orcid Id: 0000-0001-7421-0631, nadir.kocakir@ozdilek.com.tr

⁶ Özdilek Ev Tekstil Sanayi ve Ticaret A.Ş., Özveri Ar-Ge Merkezi, Bursa, Türkiye, Orcid Id: 0000-0001-5757-7335, onder.karademir@ozdilek.com.tr

* Sorumlu Yazar: musa.peker@ozdilek.com.tr

(First received September 18, 2022 and in final form December 26, 2022)

2nd International Conference on Design, Research and Development
December 14 - 17, 2022

Reference: Turan, M., Peker, M., Özkan H., Balaban C., Kocakır, N., Karademir, Ö. Derin Öğrenme ile Mobil Cihazlar üzerinde bir Fiyat Etiket Tespit Sisteminin Geliştirilmesi. Orclever Proceedings of Research and Development,1(1), 178-187.

Özet

Perakende sektöründe müşteri memnuniyetini sağlamak önemli bir konudur. Bu memnuniyeti sağlamanın yolu ise kaliteli bir hizmet sunmaktan geçer. Ürün raflarında bulunan fiyat etiketlerindeki veriler sık sık güncellenmektedir. Bu verilerin güncel haliyle fiyat etiketleri üzerinde yer alması gerekmektedir. Müşteriler, alışveriş yerlerindeki fiyat etiketlerinde yanlış bilgilerle karşılaşabilmekte ve bu da müşteri sadakati ve memnuniyeti açısından olumsuz sonuçlara neden olmaktadır. Fiyat etiketleri üzerindeki veriler çoğunlukla manuel olarak kontrol edilmekte ve bu da insan kaynaklı hatalara neden olabilmektedir. Bu çalışmada fiyat etiket alanının hızlı ve yüksek doğruluk değerlerinde tespiti için derin öğrenme tabanlı bir çözüm önerilmektedir. Derin öğrenme tabanlı fiyat tanıma sisteminin ilk ve önemli aşamalarından biri fiyat



etiket alanının doğru tespit edilmesidir. Bu aşamanın başarılı bir şekilde gerçekleştirilmesi, sonraki süreçlerin de (barkod okuma, fiyat okuma) başarılı bir şekilde gerçekleştirilmesi için önem taşımaktadır. Önerilen yöntem mobil telefonlar üzerinde test edilmiştir. Önerilen yöntemin mevcut haliyle uygulanabilir olduğu ve perakende endüstrisindeki benzer problemler için teknik bir referans olabileceği öngörülmektedir.

Anahtar Kelimeler: Fiyat etiket tespiti, Derin öğrenme, Nesne tespiti, Akıllı uygulamalar

Development of a Price Tag Detection System on Mobile Devices using Deep Learning

Abstract

Ensuring customer satisfaction is an important issue in the retail industry. The way to achieve this satisfaction is to provide a quality service. The data on the price tags on the product shelves are frequently updated. These data should be included on the price tags in their current form. Customers may encounter inaccurate information on price tags in shopping places, which causes negative results in terms of customer loyalty and satisfaction. The data on the price tags is mostly checked manually, which can cause human errors. In this study, a deep learning-based solution is proposed for fast and high accuracy detection of price tag area. One of the first and important stages of a deep learning-based price recognition system is the correct detection of the price tag area. The successful execution of this stage is important for the successful execution of the next processes (barcode reading, price reading). The proposed method has been tested on mobile phones. It is envisaged that the proposed method is applicable in its current form and can be a technical reference for similar problems in the retail industry.

Keywords: Price tag detection, Deep learning, Object detection, Intelligence applications

1. Giriş

Perakende sektöründe müşteri memnuniyeti açısından önemli bir veri de fiyat etiketleridir. Fiyat etiketi üstündeki veriler sık sık değiştiği için bu bilgilerin güncel olması önem taşımaktadır (Laptev et al., 2022). Fiyat etiketleri hakkında takip edilmesi gereken önemli bilgiler genellikle fiyat, ürün adı ve ürün özellikleridir. Fiyat etiketleri üzerindeki barkod verisi, barkod okuyucular ile okunarak ürünün gerçek fiyatına ulaşılmaktadır. Göz kontrolü ile de etiket üzerindeki fiyat bilgisi okunmakta ve barkod okuyucusundan elde edilen gerçek fiyat değeri ile karşılaştırma yapılmaktadır. İnsan kontrolünden kaynaklı hatalı kontrollerden dolayı bu işlemin otomatik olarak gerçekleştirilmesi önem arz etmektedir. Bu problemin çözümü için geliştirilen çözümler vardır. Örneğin elektronik raf etiketleri, fiyat etiketi veri doğrulama sorununa potansiyel bir çözümdür, fakat maliyetler incelendiğinde pahalı bir çözüm olduğu görülmektedir (Allegro Logistics, 2022). Ayrıca dijital etiketlerdeki aşınma ve yıpranmanın yanı sıra yazılım güncellemeleri de dâhil olmak üzere düzenli bakımları da ekstra bir maliyete



neden olmaktadır. Bu nedenle perakende sektöründe hala klasik kâğıt fiyat etiketleri ile çalışılmaktadır. Bu çalışmada derin öğrenme teknolojilerinden yararlanarak fiyat okuma otomasyonunun ilk aşaması olan fiyat etiketlerinin tespit edilmesine odaklanılmaktadır. Geliştirilen sistemin katkıları aşağıda listelenmiştir:

- Önerilen yöntem ile bir raf üzerindeki birden fazla fiyat etiketi aynı anda tespit edilebilmektedir. Bu da zaman açısından önemli bir avantaj sağlamaktadır.
- Mobil telefonlar üzerinde derin öğrenme algoritmasının hızlı ve yüksek doğruluk değerlerinde çalıştırılması sağlanmıştır.
- Fiyat tanıma sistemi için 50000 görüntüden oluşan özgün bir veri seti oluşturulmuştur. Veri seti farklı özelliklere ve zorluk seviyelerine (aydınlatma eksikliği, farklı stil ve farklı çekim açıları gibi) sahip fiyat görüntülerinden oluşmaktadır.

Çalışmanın geri kalanı şu şekilde düzenlenmiştir: Bölüm 2’de literatür araştırması özetlenmektedir. Bölüm 3’de önerilen yöntem ile ilgili bilgiler paylaşılmaktadır. Bölüm 4’de deneysel sonuçlar ve tartışma paylaşılmıştır. Bölüm 5’de elde edilen sonuçların özeti paylaşılmaktadır.

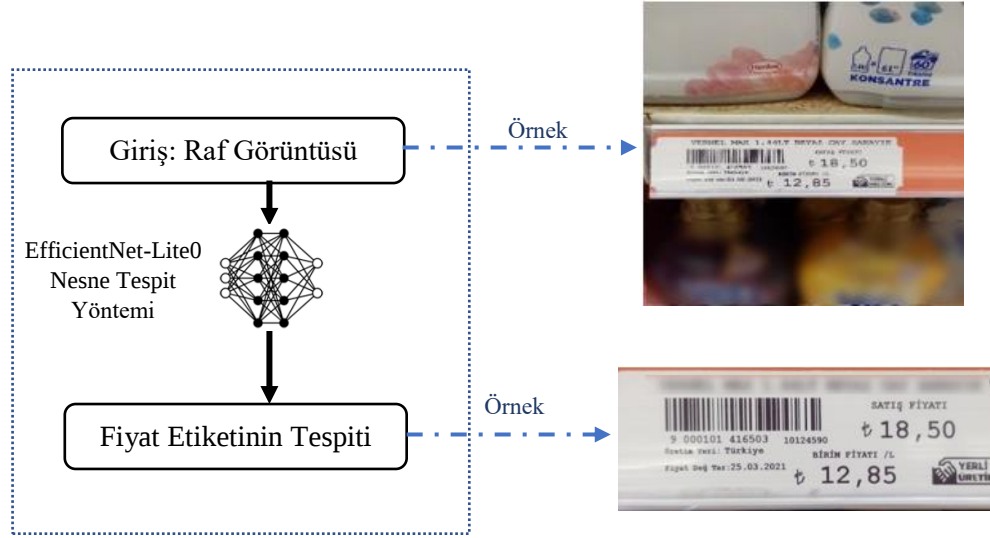
2. Literatür Araştırması

Fiyat etiketlerinin tespiti ile ilgili mevcut çalışmalar incelendiğinde, Laptev ve arkadaşları fiyat etiketlerinin analizi için görüntü segmentasyonu kapsamında çeşitli yaklaşımları incelediler (Laptev et al., 2022). Segmentasyon için Unet, MobileNetV2, VGG16 ve YOLOv4-Tiny algoritmalarını kullandılar. Araştırmacılar, segmentasyon için en uygun ağı %96.92 doğruluk oranına sahip YOLOv4-Tiny olduğunu raporladılar. Hussin ve arkadaşları fiyat etiketini tespit etmek için renk ve kontur tespiti olmak üzere iki farklı görüntü işleme tekniği kullanmıştır (Hussin et al., 2017). Renk filtreleme için HSV (hue, saturation and value) renk modelini kullandılar. Bu çalışmada fiyat etiketini kapsayan dikdörtgen alanının tespiti için kontur tespit yöntemi kullanılmıştır. Kontur algılama esnasında siyah ve beyaz gürültülerden görüntüyü arındırmak için medyan filtresi kullanılmıştır. Geliştirilen fiyat etiket tespit yöntemi ile 3 farklı etiket tipinde sırasıyla %59.4, %92.3 ve %90.6 doğruluk oranı elde edilmiştir. Kovtunenko ve arkadaşları fiyat etiketi üzerindeki barkod, logo, sembolik bilgiler ve diğer sembolleri içeren görüntülerin tanınmasına yönelik bir çalışma gerçekleştirdiler (Kovtunenko et al., 2020). Görüntüler üzerinde 2 farklı yöntem ile deneysel gerçekleştirildi. Bu yöntemler morfolojik yöntemler ve evrimsel sınır ağıdır. Çalışma sonucunda morfolojik yöntemlerin, sınır ağına göre daha düşük tespit doğruluk oranı sağladığı, ancak sınır ağından çok daha hızlı olduğunu raporladılar. Fomenko ve arkadaşları, bir raf görüntüsünde fiyat etiketleri ve bu etiketlerdeki fiyat bilgisi bölgesinin tespiti için bir

sistem geliřtirdiler (Fomenko et al., 2018). Tam evriřimsel sinir ağı kullanarak fiyat bilgisinin tespit edilmesinde transfer öğrenmesinin etkisini arařtırdılar.

3. Metot ve Yöntemler


Şekil 1’de, bu çalışmada hedeflenen fiyat etiket alanı tespit sisteminin akış şeması görölmektedir. Bir kamera ile market raflarına bakıldığında, alanda bulunan fiyat etiketlerinin otomatik olarak tespit edilmesi hedeflenmiştir.



Şekil 1 Fiyat etiketi tanıma sistemi

3.1. Veri toplama ve etiketleme


Veri seti, 30'dan fazla mağaza ve marketlerden elde edilen 50000 raf görüntüsünden oluşmaktadır. Görüntüler aydınlatma eksikliği, farklı boyut ve farklı çekim açıları gibi farklı zorluk seviyelerini içermektedir. Veri setine ait bazı örnek görüntüler Şekil 2’de sunulmuştur. Veri setinin %20’si test ve %80’i eğitim verisi olacak şekilde ikiye ayrılmıştır.



Şekil 2 Veri setinde yer alan bazı örnekler

3.2.EfficientNet-Lite-0 nesne tespit algoritması

EfficientNet, evrimsel sinir ağlarında model ölçeklendirme için yeni ve basit bir yaklaşımdır (Tan & Le, 2019). Bileşik katsayı kullanarak model ölçeklendirme gerçekleştirir. Bu yeni ölçeklendirme yöntemi geleneksel yaklaşımlara oranla 10 kat daha iyi verimlilik sağlar. EfficientNet, AutoML MNAS çerçevesini kullanılarak verimliliği optimize etmektedir. EfficientNet modelinin mimarisi Şekil 3’de görülmektedir. EfficientNet, 3×3 ve 5×5 derinlik tabanlı ayrıştırılabilir evrimsel (depthwise convolutions), sıkma ve uyarma bloğu (squeeze-and-excitation) ve swish aktivasyonu ile aynı MBConv yapı taşlarını kullanır. ImageNet üzerinde gerçekleştirilen farklı evrimsel sinir ağı (CNN) tabanlı yöntemler ile kıyaslandığında yüksek doğruluk, yüksek verim, düşük parametre boyutu elde edilmiştir (Tan & Le, 2019).



Şekil 3 EfficientNet-B0 modelinin mimarisi (Tan & Le, 2019)

EfficientNet-Lite-0, orijinal EfficientNet'ten sıkma ve uyarma (squeeze-and-excitation) bloğunu modülünü çıkarır ve daha verimli bir nicelleştirmeye izin vermek için ReLU6 aktivasyon fonksiyonu yerine Swish aktivasyon fonksiyonunu yerleştirir (Qian et al., 2022).

4. DeneySEL Sonuçlar ve Tartışma

Geliştirilen sistemin başarısını değerlendirmek için farklı tespit yöntemleri de kullanılarak karşılaştırmalı analizler yapılmıştır. Bu yöntemler Google Tensorflow Object Detection API versiyon 1 ve 2'de bulunan yöntemlerdir (TensorFlow Object Detection API, 2022). Kullanılan yöntemlere ait bilgiler Tablo 1'de sunulmuştur.


Tablo 1 Karşılaştırma amaçlı kullanılan nesne tespit yöntemleri

Model ve Kullanılan Mimari		Model Adı	Çözünürlük
Mobilenet v1 ($\alpha=0.75$)	SSD	SSD_Mobilenet_V1 (0.75_Quantized)	300 x 300
Mobilenet v1 ($\alpha=1$)	SSD+PPN	SSD_Mobilenet_V1_PPN	300 x 300
Mobilenet v2 ($\alpha=1$)	SSDLite	SSDLite_Mobilenet_V2	300 x 300
Mobilenet v2 ($\alpha=1$)	SSD	SSD_Mobilenet_V2	320 x 320
Mobilenet v2 ($\alpha=1$)	SSD+FPNLite	SSD_Mobilenet_V2_FPNLite	320 x 320
Mobilenet v2 ($\alpha=1$)	SSD (Quantized)	SSD_Mobilenet_V2_Quantized	300 x 300

Deney aşamasında tüm modeller, Intel Core işlemci i9 ve 32 GB RAM, Nvidia RTX 3080 Ti grafik işlem birimi (GPU), ve 11 GB RAM özelliklerine sahip bir bilgisayarda eğitilmiştir. Bütün modellerde eğitim süreci için 300000 iterasyon, Adam optimizer ($\beta_1 = 0.9$, $\beta_2 = 0.999$), 0.0001 öğrenme oranı, 0.05 ağırlık azalması (weight decay) and 16 batch boyutu kullanılmıştır.


4.1. Performans Değerlendirme

Eğitim sürecinde, test verileri üzerinde model başarıları değerlendirildi. Şekil 4-(a)'da Efficientnet-Lite-0 modelinin eğitim işlemi sonucunda elde edilen hata değerleri görülmektedir. Şekil 4-(b)'de ise Tablo 1'de belirtilen modeller ile elde edilen sonuçlar görülmektedir. 150.000. adım sayısına ait sonuçlar incelendiğinde en düşük hata



Model Adı	Hata Değeri
EfficientNet-Lite-0	0.0433

(a)



Model Adı	Hata Değeri
SSD_Mobilenet_V1_0.75_Quantized_300x300	5.6447
SSD_Mobilenet_V1_PPN_300x300	3.0074
SSDLite_Mobilenet_V2_300x300	2.4272
SSD_Mobilenet_V2_320x320	0.0981
SSD_Mobilenet_V2_FPNLite_320x320	0.0625
SSD_Mobilenet_V1_Quantized_300x300	0.6448

(b)

değerinin Efficientnet-Lite-0 ile elde edildiği görülmektedir. Ardından SSD_Mobilenet_V2_FPNLite modeli ile iyi sonuçlar elde edilmiştir. En kötü sonuç ise SSD_Mobilenet_V1_0.75_Quantized_300x300 modeline aittir. Şekil 4 Derin öğrenme

modellerinin iterasyon-hata grafikleri (a) EfficientNet-Lite-0 hata grafiği (b) Tensorflow Object Detection API modellerinin hata grafiği

Gerçek zamanlı gerçekleştirilen testlerde EfficientNet-Lite-0 modelinin daha doğru, daha hızlı ve kararlı sonuçlar verdiği gözlemlenmiştir. Float16 ve int8 niceleme yöntemlerinin kullanımına da olanak sağlamasıyla EfficientNet-Lite-0 performans yönünden en öne çıkan model olmuştur.

4 farklı mobil telefon üzerinde önerilen yöntem gerçek zamanlı olarak 1000 farklı görsel üzerinde test edilmiştir. Test sürecinde elde edilen bazı sonuçlara ait görseller Şekil 5’de sunulmuştur. Sonuçlar hız ve doğruluk yönüyle incelendi. 10 teste ait sonuçlar ve tüm sonuçlara ait ortalama değerler Tablo 2’de sunulmuştur. Sonuçlar incelendiğinde genel olarak ortalama hesaplama süresinin düşük olduğu görülmektedir. Ortalama 45 ms civarında bir hesaplama süresinin gerçek zamanlı bir sistem için yeterli olduğu düşünülmektedir. Ortalama doğruluk oranları ise %98’in üzerindedir.

Tablo 2 Farklı akıllı telefon modellerinde önerilen sistemin test verileri üzerindeki performans analizi

	Samsung Galaxy S21	Xiaomi Redmi Note 9 Pro	iPhone 13	iPhone 11
Test Örnek - 1	44 ms	59 ms	35 ms	46 ms
Test Örnek - 2	44 ms	62 ms	34 ms	46 ms
Test Örnek - 3	45 ms	57 ms	35 ms	46 ms
Test Örnek - 4	43 ms	91 ms	35 ms	46 ms
Test Örnek - 5	42 ms	68 ms	34 ms	46 ms
Test Örnek - 6	45 ms	61 ms	34 ms	47 ms
Test Örnek - 7	42 ms	56 ms	35 ms	45 ms
Test Örnek - 8	43 ms	59 ms	35 ms	46 ms
Test Örnek - 9	44 ms	59 ms	35 ms	46 ms
Test Örnek - 10	45 ms	61 ms	35 ms	46 ms
En Uzun Hesaplama Süresi	47 ms	94 ms	36 ms	48 ms
En Kısa Hesaplama Süresi	35 ms	67 ms	34 ms	45 ms
Ortalama Hesaplama Süresi	43.7 ms	63.3 ms	34.7 ms	46 ms
Ortalama Doğruluk Oranı	% 98.5	%98.4	%99	%99.2

5. Sonuçlar

Bu çalışmada gerçek zamanlı olarak raf görüntüleri üzerindeki fiyat etiketlerinin otomatik tespitine yönelik bir sistem geliştirilmiştir. Geliştirilen sistem hafif ağırlıklı bir nesne tespit yöntemi olan EfficientNet-Lite-0 yöntemini kullanmaktadır. Farklı performans değerlendirme metriklerine göre yapılan deneysel çalışmalar neticesinde, önerilen yöntemin oldukça hızlı ve yüksek bir doğruluk değerinde çalıştığı gözlenmiştir.



(a)



(b)



(c)



(d)



(e)



(f)

Şekil 5 Geliştirilen sistem ile yapılan gerçek zamanlı testlerin görsel sonuçları

Müşteri memnuniyeti açısından önemli bir konu olan ve aynı zamanda günlük bir perakende operasyonu olan fiyat kontrolü işleminin hızlı ve doğru bir şekilde yapılması önemlidir. Bu çalışmada önerilen çözüm yöntemi ile elde edilen sonuçlar dikkat çekicidir. İleri ki çalışmalarda önerilen sistemde kullanılan derin öğrenme modelinin daha da



optimize edilmesi hedeflenmektedir. Bu şekilde donanımsal özellikleri çok iyi olmayan akıllı telefonlarda da ortalama tahmin süresinin düşürülmesi planlanmaktadır.

Referanslar

- [1] Allegro Logistics (2022), Are digital price tags worth the hype ?, <https://www.allegrologistics.co.uk/>, Erişim Tarihi: 15.10.2022
- [2] Fomenko, V., Botov, D., & Klenin, J. (2018). Text scene detection with transfer learning in price detection task. in 7th International Conference on. Analysis of Images, Social Networks, and Texts (AIST), pp. 173-178, Moscow, Russia.
- [3] Hussin, M.N.A., Ahmad, A.H., & Razak, M.A. (2017). Price tag recognition using HSV color space. Journal of Telecommunication, Electronic and Computer Engineering, 9(3-9), 77-84.
- [4] Kovtunenکو, A., Yakovleva, O., Liubchenko, V., & Yanholenko, O. (2020). Research of the joint use of mathematical morphology and convolutional neural networks for the solution of the price tag recognition problem. Bulletin of National Technical University KhPI Series System Analysis Control and Information Technologies. 1, 24-31.
- [5] Laptev, P., Litovkin, S., Davydenko, S., Konev, A., Kostyuchenko, & E., Shelupanov, A. (2022). Neural network-based price tag data analysis. Future Internet, 14(3), 1-14.
- [6] Qian, Y., Miao, Y., Huang, S., Qiao, X., Wang, M., Li, Y., ... & Cao, L. (2022). Real-Time Detection of Eichhornia crassipes Based on Efficient YOLOV5. Machines, 10(9), 754.
- [7] Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning pp. 6105-6114, PMLR.
- [8] TensorFlow, Tensorflow Object Detection API, https://github.com/tensorflow/models/tree/master/research/object_detection, Erişim Tarihi: 15.10.2022.