

NESNE TESPİTİ İÇİN KULLANILAN ŞABLON EŞLEME YÖNTEMİNİN KOMŞULUK HAVUZU TEKNİĞİ İLE GÜÇLENDİRİLMESİ

Asiye Rümeyza ÜNSAL *^{ID}
Serkan DERELİ **^{ID}

Alınma: 25.12.2023 ; düzeltme: 20.10.2024 ; kabul: 24.11.2024

Öz: Bu çalışmada görüntü işleme alanında nesne tespiti yapan yöntemlerden biri olarak literatürde kabul gören şablon eşlemeyi güçlendirmek amacıyla Komşuluk Havuzu Algoritması önerilmiştir. Bu yeni teknik ile şablon eşleme işleminin gerçekleştirildiği uygulamalarda en büyük eşleşme derecesinin yanı sıra sahte eşleşmelerin kolaylıkla tespit edilmesi sağlanmıştır. Klasik bir görüntü işleme tekniği olan şablon eşleme, küçük boyutlu olan şablon görüntüyü daha büyük bir kaynak görüntüde piksel bazlı arar ve piksellerin benzerlik derecesini matematiksel olarak hesaplar. Bu hesaplama işlemi neticesinde kaynak görüntüde elde edilen eşleşmeler gerek benzeyen/benzemeyen gerekse de zayıf/orta/güçlü benzerlik dereceleriyle ortaya konabilmektedir. Ancak, bu teknik görüntü tarama yöntemini kullandığından hem oldukça yavaş ve hem de sahte eşleşmelere neden olduğundan doğruluğu düşüktür. Önerilen komşuluk havuzu fikri sahte eşleşmelerin önüne geçmekle birlikte en yüksek benzerlik derecesine sahip eşleşmenin daha kolay elde edilmesini de sağladığından şablon eşleme yönteminin doğruluğunu da artırmıştır. Deneyler üç farklı görüntü üzerinde, görüntü boyutu, benzerlik eşik değeri, komşuluk büyüklüğü ve hesaplama süresi olmak üzere dört farklı parametre temelinde gerçekleştirilmiştir. Tüm deneylerde iki farklı benzerlik eşik değeri kullanılarak eşik değerinin doğruluğa ve hesaplama süresine etkilerinin incelenmesinin yanı sıra farklı boyutlarda görüntüler kullanılarak görüntü boyutunun hesaplama süresine olan etkileri de incelenmiştir. Sonuçta önerilen yöntemin sahte eşleşmelerin önüne geçme geçtiği deneylerle kanıtlanmıştır.

Anahtar Kelimeler: Komşuluk Havuzu Algoritması, Şablon Eşleme, Görüntü İşleme, Nesne Tespiti

Enhancement of Template Matching Method Used for Object Detection with Neighborhood Pooling Technique

Abstract: In this study, Neighborhood Pooling Algorithm is proposed in order to strengthen template matching. With this new technique, in applications where template matching is performed, in addition to the highest match degree, fake matches can be easily detected. Template matching searches the small-sized template image in a larger source image on a pixel-by-pixel basis and mathematically calculates the similarity degree of pixels. As a result of this calculation process, the matches obtained in the source image can be presented with similar/dissimilar or weak/medium/strong similarity degrees. However, since this technique uses the image scanning method, it is both very slow and causes fake matches, so its accuracy is low. The proposed neighborhood pooling idea prevents fake matches and also increases the accuracy of the template matching method since it provides easier obtaining of the match with the highest similarity degree. Experiments were carried out on three different images based on four different parameters: image size, similarity threshold value, neighborhood size and calculation time. In all experiments, two different similarity threshold values were used to examine the effects of the threshold value on accuracy and computation time. As a result, it was proven through experiments that the proposed method prevents false matches.

Keywords: Neighborhood Pool Algorithm, Template Matching, Image Processing, Object Detection

* Sakarya Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi Elektrik-Elektronik Mühendisliği

** Sakarya Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği

İletişim Yazarı: Serkan Dereli (dereli@subu.edu.tr)

1. GİRİŞ

Günümüzde sistemleri belli düzeyde bozmayı, zarar vermeyi hedefleyen ve sistemin düzenli çıktığı üretmesine engel olmaya çalışan anomali tespiti pek çok disiplinde sıklıkla kullanılmaktadır (Canay ve Kocabıçak, 2024). Robot planatörleri, uzay ve havacılık, savunma teknolojileri ve sağlık alanları anomali ve hedef tespitinde yaygın olarak kullanılmaktadır (Can ve Canay, 2016). Bir anomali tespit yöntemi olarak da kullanılan şablon eşleme literatürde nesne takibinde, hastalıklı bölge, hedef, kusurlu ürün tespitinde sıklıkla kullanılan bilgisayarlı görme tekniğidir (Alemdar ve Avcı, 2019). En temel haliyle şablon olarak adlandırılan küçük bir görüntünün kaynak olarak adlandırılan büyük bir görüntü içinde tarama şekliyle aranması işlemidir (Yaşar ve Alaybeyoğlu, 2018). Tarama işleminde şablon görüntü ile seçilen çerçeve arasındaki ilişki matematiksel olarak hesaplanarak belli oranda bir benzerlikle ifade edilir. Bu matematiksel ilişki için literatürde Pearson çapraz korelasyon (Pearson's cross correlation), mutlak farkların toplamı (Sum of Absolute Difference) (Atallah, 2001), farkların kareleri toplamı (Sum of Squared Difference - SSD) (Chantara, vd., 2015) ve normalleştirilmiş çapraz korelasyon (Normalized Cross Correlation - NCC) (Di Stefano, vd., 2005) gibi çok farklı hesaplama teknikleri bulunmaktadır (Hisham, vd., 2015). Ancak bu durum her iki görüntünün de boyutuna bağlı olarak uzun işlem süresine sahip olduğundan laboratuvar ortamında güçlü bilgisayarlarda kolaylıkla gerçekleştirilebilmesine rağmen gömülü sistemlerde gerçek zamanlı çalışmasının önünde en büyük engeldir. Bu nedenle araştırmacılar şablon eşleşme tekniği temelinde gerçekleştirilen çalışmalarda eşleşme süresini ele almışlardır. Jiano ve arkadaşları bu nedenle hızlı şablon eşleme tekniğini literatüre kazandırmışlardır. Bunun için kaynak görüntüden şablon boyutunca elde edilen çerçeve görüntüsündeki farklı özellikler çıkarılarak 30 FPS hızındaki bir akışı %95 performansla işleyebilmişlerdir (Jiao, vd., 2018). Yan ve arkadaşları nesne izleme sistemi için geleneksel şablon eşleme tekniğini paralel tarama işlemiyle hızlandıran bir yöntem önermişlerdir (Yan, vd., 2019). Aqel ve arkadaşları otonom araçlardaki kameralardan elde edilen görüntüler üzerinden gerçekleştirilen şablon eşleme yöntemindeki matematiği normalize edilmiş çapraz korelasyon ile gerçekleştirerek yeni bir uyarlanabilir şablon eşleme tekniği önermişlerdir. Bu teknik ile %87 oranında hesaplama hızı artırılmıştır (Aqel, vd., 2016). Bir diğer araştırmacı eşleşmelerdeki dairesel ve açısız özellikleri kullanan RST (rotation, scaling and translation) şablon eşleşme işlemi geliştirmek için NCC formülünün hesaplama süresini azaltmıştır (Kim, 2010). Hsu ve Shen gerçek zamanlı, çok çekirdekli ve paralel çalışabilen gömülü bir sistem tasarımı ile otomatik entegre devre işaretleme ve tespit işlemini şablon eşleme yöntemiyle gerçekleştirmişlerdir. Kaynak görüntülerde 640x480 ve şablon görüntülerde 80x100 boyut kullanarak test ettikleri sistemi hesaplama süresi açısından klasik şablon eşleme tekniğine göre 20x kat iyileştirmişlerdir (Hsu ve Shen, 2018). Annaby ve arkadaşları yaptıkları çalışmada PCB (printed-circuit boards) hatalarını tespit etmek amacıyla kullandıkları şablon eşleme yönteminde korelasyon ilişkisi için kullanılan NCC formülünün hesaplama süresini azaltmak için ayrık kosinüs dönüşümünü (DCT) hesaplamaya entegre etmişlerdir (Annaby, vd., 2019). Yan ve arkadaşları görsel nesne izleme sistemi için kullandıkları şablon eşleşme yöntemini adaptif hale getirerek geliştirmişlerdir (Yan, vd., 2019). Lai ve arkadaşları hedefin şablona göre belli bir açıyla dönmüş olması, arka plan bozulmaları ve görüntüdeki gürültülerin artması durumunda da daha iyi benzerlik ortaya koymak adına güçlü ve hızlı çalışan bir şablon eşleme yöntemi önermişlerdir (Lai, vd., 2020).

Bu çalışmada ise klasik şablon eşleme tekniğinin piksel piksel tarama esnasında gerçekleştirdiği sahte eşleşmelerin önüne geçme ve eşleşmenin en yüksek eşleşme katsayı (r) değeriyle elde edilmesine odaklanılmış olup ayrıca endüstriyel ortamda kullanılan görüntüler kullanılarak test ve analizler gerçekleştirilmiştir. Çalışmanın bundan sonraki bölümlerinde hem komşuluk havuzu yöntemi kapsamlı şekilde ele alınmış ve hem de bu yöntemin literatüre kazandırdığı avantajlar çeşitli deneylerle kanıtlanmıştır. Deneylerde iki veri kümesi arasındaki

ilişkiyi güçlü şekilde temsil edebilen Pearson Korelasyon Katsayısı eşleşme katsayısı olarak kullanılmıştır.

2. MATERYAL VE METOT

Şablon eşleme yöntemi kaynak bir görüntünün belli büyüklükte şablon görüntü boyutuyla taranması işleminden ibarettir. Tarama neticesinde her iterasyonda kaynak görüntüden şablon görüntü büyüklüğünde yeni bir çerçeve alınır ve bu çerçeve şablon görüntüyle matematiksel korelasyon işlemine tabi tutularak 0 – 1 aralığında bir eşleşme derecesi hesaplanır (Efeoğlu ve Gürkan, 2021). Yıllarca bu şekilde farklı mühendislik problemlerinde kullanıldıktan sonra son on yılda gömülü sistemlerle birlikte kullanımıyla hem donanımsal maliyet hem de yavaş çalışma durumu dezavantaj haline gelmiştir (Yan, vd., 2019). Buna binaen literatürde şablon eşleme tekniğini hızlandırma noktasında araştırmalar yoğunlaşmıştır ve genel başlıklar halinde öne çıkan yöntemler şu kapsamda toplanmıştır: Hızlı tarama, hiyerarşik tarama, arama noktalarını azaltma, eşleşme kriterlerini basitleştirme (Huang, vd., 2006).

Şekil-1’de verilen $[M \times N]$ boyutundaki bir kaynak görüntüde $[m \times n]$ boyutundaki bir şablon tarandığında Denklem-1’de verilen piksel sayısı sistem tarafından işlenecektir. İşleme süresi hem kaynak hem de şablonun boyutuna bağlı olmakla birlikte günümüz uçta çalışan gömülü sistemler için bu durum oldukça sıkıntı oluşturmaktadır (Le, vd., 2020).


$$\text{Piksel Sayısı} = (M - m + 1)(N - n + 1)n^2 \quad (1)$$

Tablo-1’de farklı kaynak ve şablon görüntü boyutlarına göre işlenecek piksel sayısı karşılaştırması görülmektedir. Kaynak görüntü veya şablon görüntülerden herhangi biri büyüdükçe ister istemez işlenecek piksel sayısı artacağından dolayı bu tekniğin işlem süresi de ona paralel olarak artacaktır (Aktaş, 2015).

Tablo 1. Farklı kaynak ve şablon görüntü büyüklüklerine göre işlenecek piksel sayısı karşılaştırması (Aktaş, 2015)

Kaynak Görüntü Boyutu $S = M \times N$	Şablon Görüntü Boyutu $T = m \times n$	İşlenecek Piksel Sayısı
1024 x 1024	32 x 32	~1 milyar
	64 x 64	~3.7 milyar
	128 x 128	~13 milyar
512 x 512	32 x 32	~237 milyon
	64 x 64	~826 milyon
	128 x 128	~2.5 milyar
256 x 256	32 x 32	~51 milyon
	64 x 64	~152 milyon
	128 x 128	~272 milyon

Şekil-1’de, A şablon görüntü ve B’de kaynak görüntü olmak üzere iki görüntüyü göstermektedir. Klasik şablon eşleme tekniğinde A’nın boyutu kadar çerçeveler B kaynak görüntüsünden seçilerek çerçevenin A şablon görüntüyle korelasyon ilişkisi matematiksel olarak hesaplanmaktadır. Bu işlem kaynak görüntünün başından sonuna kadar piksel piksel kaydırmak suretiyle gerçekleştirildiğinden yöntem tarama yöntemi ismi verilir (Ouyang, vd., 2011).



Şekil 1:

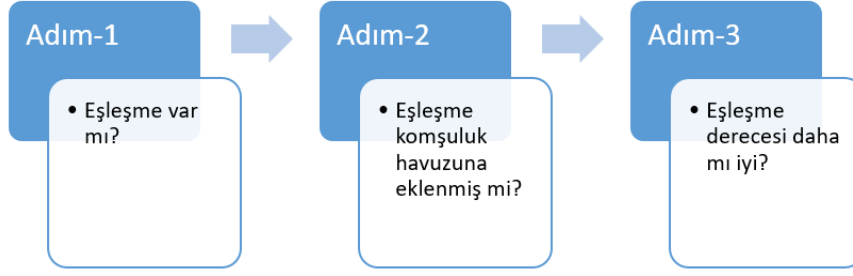
Kaynak görüntü (B) ve şablon görüntü (A) gösterimi

Şablon eşleme de tarama yöntemi kullanılarak nesne araması gerçekleştirildiğinden yöntemin bir sistemde kullanılmasıyla birlikte şu olumsuz durumlar ortaya çıkmaktadır:

1. Birbirine yakın bölgeden seçilen çerçeveler çok sayıda sahte eşleşmeye neden olmaktadır.
2. Pek çok sahte eşleşme gerçek eşleşme derecesinin tespitini önlemektedir.
3. Sürekli bir piksel bazlı tarama işlemi nedeniyle işlem süresi oldukça uzun sürebilmektedir.

Bu çalışmanın odak noktasını yukarıda maddeler halinde verilen problemler oluşturmaktadır. Bunun için oluşturulan algoritmanın temel bölümleri Şekil-2’te görüldüğü üzere üç adımdan oluşur. Birinci adımda kaynak görüntüde bir eşleşme olup olmadığı tespit edilir (Testlerde bu değer 0.5, 0.6 ve 0.8 olarak alınmıştır). İkinci adımda bu eşleşmenin daha önce komşuluk havuzuna eklenip eklenmediği sorgulanır. Komşuluk havuzu için x ve y eksenleri için ayrı ayrı birer değer belirlenir (Örneğin $[x=15$ ve $y=15]$). Eğer eşleşme işleminin gerçekleştiği çerçeve başlangıç konumları (hem x hem de y) bu değerlerden küçükse bu adım çalışmaktadır. Çünkü diğer durumda ilk defa gerçekleşen bir eşleşme olduğu kabul edilir. Son adımda ise komşuluk havuzunda tespit edilen eşleşmenin derece kontrolü yapılır. Güncel eşleşme derecesi kayıtlı olan eşleşme derecesinden daha yüksekse bu defa hem konum hem de eşleşme derecesi yenisiyle yer değiştirir.

Şekil-2’de de gösterildiği gibi “Komşuluk Havuzu” tekniği eşleşmeyi tespit ettiğinde eşleşmenin başladığı (x, y) konum bilgisini ve eşleşme derecesini (r) bir hafıza bölgesinde depolamaktadır. Aynı bölgede gerçekleşen sonraki eşleşmelerde eşleşme derecesinin büyüklüğüne göre bilgileri yenisiyle yer değiştirmektedir. Bu sayede iki önemli kazanım gerçekleşmektedir: Biri aynı bölgedeki en büyük eşleşme katsayısı elde edileceğinden dolayı eşleşmenin hangi oranda gerçekleştiği daha net bir şekilde ortaya konmaktadır. Diğeri ise eşleşme eşik değerinden büyük ve komşulukta bulunmayan eşleşmeler dikkate alındığından algoritmanın çalışma süresi düşecektir (Dereli ve Ünsal, 2023). Bu çalışmada her iki kazanım da deneylerde ortaya konmuştur.



Şekil 2:

Komşuluk havuzu algoritması işleyiş şekli

Şekil-2’de temel olarak gösterilen adımların sözde kod şeklinde ifade edildiği aşağıdaki bölümde 1 – 6 nolu satırlar Adım-1’i ifade eder. Algoritmadaki 7 – 10 nolu satırlar Şekil-3’te ki Adım-2 ile ilgilidir ve bu adım sayesinde sahte eşleşmelerin önüne geçilmiştir. 11 – 15 nolu satırlar ise Adım-3 kapsamındadır ve bu sayede de eşleşme derecesi daha net bir şekilde tespit edilebilmiştir. Algoritma da görüldüğü üzere tüm süreç eşleşmenin $r=0.5$ olarak elde edilmesiyle başlamaktadır.

1. Benzerlik eşik değeri = 0.5
2. Komşuluk = [15 x 15]
3. Döngü başlangıcı: Kaynak görüntüyü piksel piksel tara
4. Yeni çerçeve = şablon boyutu(kaynak görüntü)
5. Yeni r değeri = korelasyon hesapla(şablon görüntü, yeni çerçeve)
6. Eğer eşleşme derecesi (r) > 0.5 ise:
7. $X1, Y1$ = Başlangıç konumu(Yeni çerçeve)
8. Eğer $X1, Y1$ değeri komşuluk değerleri içinde ise:
9. Konumla eşleşen eski r değerini komşuluk havuzundan çek
10. Eğer yeni r değeri > eski r değeri ise:
11. Eski r değeri = yeni r değeri
12. Eski $X1, Y1$ konumu = Yeni $X1, Y1$ konumu
13. }
14. } değilse {
15. Komşuluk havuzuna ekle($X1, Y1$)
16. }
17. } Döngü sonu

Şekil-3’te kaynak görüntüde şablon aslında tek bir görüntü olmasına rağmen yine de işlem sonunda görüntü üzerinde farklı eşleşme derecesine sahip dört eşleşme tespit edildiği görülmektedir. Bunun önüne geçmek için önerilen komşuluk havuzu yöntemiyle her eşleşme bölgesi bir diziye depolanmaktadır. Aynı komşuluk bölgesinde yeni eşleşmeler tespit edildiğinde ancak önceki eşleşme derecesinden yüksek olanlar dizideki önceki değerle yer değiştirerek gerçek eşleşme derecesinin kolaylıkla tespit edilmesine katkı sağlamaktadır. Şekil-3’de de benzer bir durum bulunmaktadır ve en yüksek benzerlik oranına sahip olan eşleşme aslında en iyi eşleşmeye sahiptir ve bu değer bu çalışmada önerilen komşuluk havuzu yöntemiyle kolaylıkla tespit edilebilmektedir.


13. Böylece $r=0.48$ ile tek bir eşleşme ortaya konmuş olur.

3. DENEYSEL SONUÇLAR VE TARTIŞMA

Bu çalışmada ki deneysel çalışmalarda kodlama arabirimi olarak Matlab 2015 ve test görüntüleri olarak ise literatürde nesne tanıma deneylerinde sıklıkla kullanılan ve Şekil-4'te verilen görseller tercih edilmiştir. Deneylerde hem klasik şablon eşleme hem de komşuluk havuzu yöntemini içeren şablon eşleme yöntemi ayrı ayrı kodlanmış ve çıktılar derinlemesine analiz edilmiştir. Sonuçlar şablon ve kaynak görüntüler; boyutları, sonuca ulaşma süresi ve farklı eşleşme dereceleri bakımından analiz edilmiştir.

$$r = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n \sum x^2 - (\sum x)^2] [n \sum y^2 - (\sum y)^2]}} \quad (2)$$

Bu çalışmada kaynak görüntüde şablon görüntü ile gerçekleştirilecek eşleşmeler Denklem-3'te verilen Pearson Korelasyon Katsayısı formülü ile elde edilen bir değer vasıtasıyla tespit edilmiştir. Deneylerde eşleşme eşik değeri olarak isimlendirilen bu değerın üstü eşleşmenin varlığını değerin altı ise eşleşmenin gerçekleşmediğini ifade eder.



Şekil 2:

Deneylerde analiz için kullanılan kaynak görüntüler

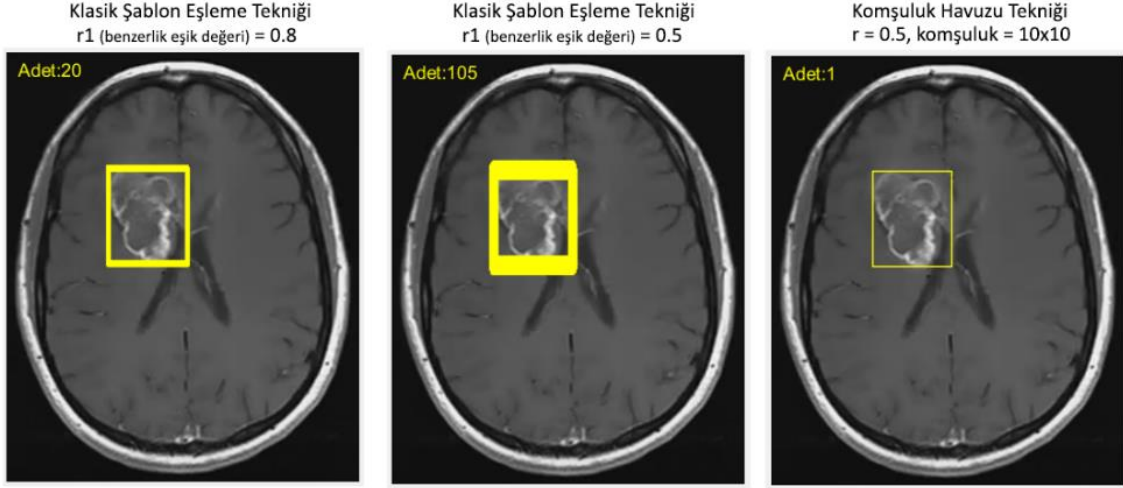
Bu çalışmada Şekil-4'te verilen üç farklı görüntü üzerinde işlemler gerçekleştirilmiştir. Her bir görüntü farklı genişlik ve yükseklik bilgisine sahiptir. Bu durum işlemlerin çalışma süresi bakımından analiz edilmesini kolaylaştırmıştır. Ayrıca görüntüler üzerinde farklı sayıda eşleşme bulunması da farklı eşleşme konumları açısından algoritmanın başarısını analiz etme imkânı vermektedir.



Şekil 5:


Deneylerde analiz için kullanılan şablon görüntüler

Şekil-6, ilk test sonuçlarını göstermektedir. Burada farklı eşleşme katsayıları kullanılarak elde edilen eşleşmeler resmedilmiştir. Aslında komşuluk havuzu tekniği sayesinde görüntüde tek bir eşleşme gerçekleşmiştir. Ancak tarama işlemi neticesinde komşu piksellerin birbirine olan benzerliği nedeniyle aynı eşleşmede sahte eşleşmelerin de olduğu yine Şekil-6'da açıkça görülmektedir. Bu durum benzerlik katsayısı (r) sınır değerine göre değişiklik göstermektedir. " r " değeri düştükçe benzer piksellerin oranı artacağından sahte eşleşmelerin sayısı da artmıştır. Bu durum daha fazla çerçeve eşleştirmesi yapması nedeniyle çalışma süresinin de artmasına sebep olmuştur.



Şekil 6:
Test-1, klasik şablon eşleme ve komşuluk havuzu tekniği çıktıları

Şekil-6'da gerçekleşen sahte eşleşmelerin $[x, y]$ konum bilgilerinin dağılım grafiği Şekil-7'de görülmektedir. "Şekil-6, $r=0.8$ " grafiğinde 20 adet eşleşme gerçekleştiğinden dağılımın 0.8 - 1 aralığında olduğu görülmektedir. "Şekil-6, $r=0.5$ " grafiğinde ise 105 adet eşleşme gerçekleşmiş ve dağılım da 0.5 - 1 aralığındadır. Bu grafik aslında komşuluk bölgelerindeki sahte eşleşmelerin nasıl gerçekleştiğini açıkça gösterdiğinden bu çalışmada önerilen tekniğin önemini güçlü şekilde vurgulamaktadır.



Şekil 7:
Şekil-6'ya ait sahte eşleşme konumlarının dağılımı

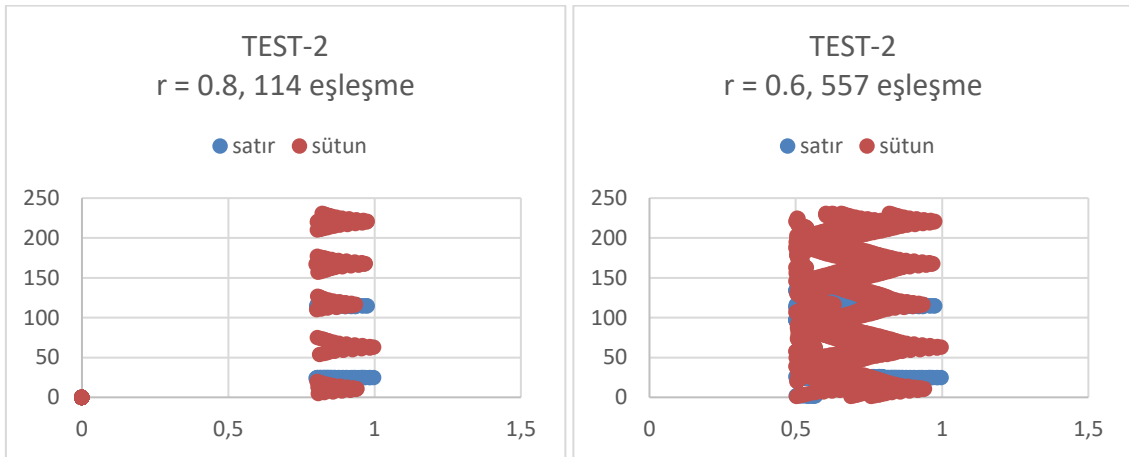
Şekil-8 çoklu nesnelerin bulunması nedeniyle bu çalışmada önerilen tekniğin önemini vurgulaması açısından önemli test aşamalarından biridir. Zira önerilen teknik sadece eşleşmeyi tespit etmekle kalmaz aynı zamanda eşleşme katsayısının maksimum olduğu değere sahip olan eşleşmeyi tespit eder. Bunun için uyguladığı strateji, önceki eşleşmenin başladığı piksel konumları çevresinde gerçekleşen yeni eşleşmelerin varlığını tespit ettikten sonra bu yeni eşleşmenin katsayısını önceki eşleşme katsayısı ile karşılaştırır. Eğer yeni eşleşme katsayısı daha iyi bir değere sahipse bu durumda eşleşmeyi günceller aksi halde yeni eşleşmeyi iptal eder. Şekil-8’de şablon görüntüye ait piksel değerleri kaynak görüntüdeki değerlere oldukça yakındır. Bu nedenle çok sayıda eşleşme gerçekleşmektedir. Özellikle r değerinin 0.6 değerine eşitlendiği durumda ki gerçekleşen eşleşmenin 557 adet olduğu düşünüldüğünde eşleşme sayısı çok daha fazla olabilmektedir. Hatta şablon görüntünün olmadığı bölgelerde bile eşleşme görülmektedir.



Şekil 8:

Test-2, klasik şablon eşleme ve komşuluk havuzu tekniği çıktıları

Şekil-9, Şekil-8’e ait eşleşmelerin (x, y) konum bilgilerini resmetmektedir. Komşuluk Havuzu Tekniğine göre 5 adet tespit edilen eşleşme klasik şablon eşleme tekniğiyle 114 ve 557 adet olarak tespit edilmiştir. Dolayısıyla Şekil-9 sahte eşleşmelerin komşu piksellerde nasıl oluştuğunu ve bu çalışmada önerilen “Komşuluk Havuzu” yönteminin önemini açıkça göstermesi bakımından oldukça önemlidir. Elbette eşleşme katsayısı düştükçe sahte eşleşmelerin arttığı da yine bu şekilde açıkça görülmektedir.




Şekil 9:

Şekil-8’e ait sahte eşleşme konumlarının dağılımı

Şekil-9, birden fazla benzerliğin bulunduğu ve daha büyük çözünürlük değerlerine sahip bir görüntüdeki klasik şablon eşleme ve komşuluk havuzu tekniklerinin karşılaştırmasını göstermektedir. Yine, önceki iki deneyde olduğu gibi klasik şablon eşleme tekniği her tespit ettiği nesnenin komşuluk bölgesinde sahte eşleşmeler tespit etmiştir. Sahte eşleşme sayısı bu deneyde


de r (eşleşme katsayısı) değerine bağlı olarak artmıştır. Ancak komşuluk havuzu tekniğinde r değerine bağlı olmaksızın nesnelere tespit edilebilmiştir.



Şekil 10:

Test-3, klasik şablon eşleme ve komşuluk havuzu tekniği çıktıları

Şekil-11, Şekil-10'da tespit edilen iki nesnenin komşuluk bölgesinde oluşan sahte eşleşmeleri ve (x, y) konumlarını resmetmektedir. Bu şekilde göre test görüntüsünde tespit edilen ikinci nesnenin daha fazla komşu sahte eşleşmesinin gerçekleştiği görülmektedir.

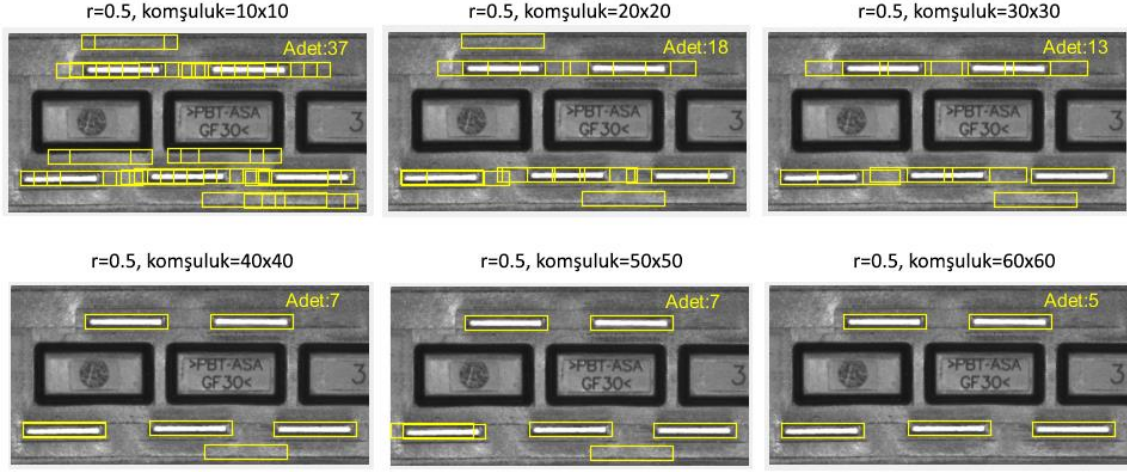


Şekil 11:

Şekil-10'a ait sahte eşleşme konumlarının dağılımı

Komşuluk havuzu tekniği, klasik şablon eşleme tekniği gibi çalıştığından nesne tespit konusunda r (eşleşme katsayısı) değerine doğrudan bağlıdır. Dolayısıyla yapılan tüm testlerde görüldüğü üzere r değeri büyüdükçe nesne tespiti konusunda algoritmanın duyarlılığı artacağından sahte eşleşme sayısı da düşmektedir. Önerilen bu yeni teknikte ayrıca ilave bir komşuluk büyüklüğü parametresi çalışmaktadır. Özel bir matris yapıda olan bu parametre eşleşmenin başlangıç (x, y) noktalarına komşu pikselleri dikkate almaktadır ve tespit edilen nesnenin aynı nesneye ait sahte bir eşleşme olduğunu belirleme noktasında önemli bir görev üstlenmektedir. Dolayısıyla komşuluk büyüklüğü de sahte eşleşmenin önüne geçen önemli bir parametredir. Şekil-12'de bu durum aynı test görüntüsü üzerinde aynı r korelasyon katsayısı değeri ve farklı komşuluk değerleriyle elde edilen çıktılarla ortaya konmuştur. Bu deney için yapılan altı farklı teste dikkate alınan piksel komşuluğu büyüdükçe doğruluğun arttığı açıkça görülmektedir. Bunun sebebi elbette komşuluk havuz tekniğinin çalışma biçimidir ki tespit edilen bir eşleşme öncekiyle aynı komşuluk bölgesindeyse r korelasyon katsayısı değerine göre göz ardı edilir veya öncekiyle yer değiştirir. Bu sayede ilave bir sahte eşleşme söz konusu olmamaktadır.

Sonuç olarak yapılan deneylerde göstermiştir ki; r korelasyon katsayısı ve komşuluk bölgesinin büyüklüğü eşleşmenin doğruluğu için oldukça önemli bir parametredir.



Şekil 12:

Komşuluk büyüklüğünün önerilen yöntemin başarısına etkisi

Tablo-2, klasik şablon eşleme ile komşuluk havuzu tekniklerini yapılan deneylerde elde edilen değerler açısından karşılaştıran özet bir tablo olarak sunulmuştur. Yapılan tüm deneylerde farklı r korelasyon katsayısı değerinin eşleşme sayısını ve dolayısıyla da sahte eşleşme sayısını artırdığı görülmektedir. Sahte eşleşme sayısının artması aynı zamanda hesaplama süresinin de artmasına neden olduğu açıktır. Çünkü r eşik değerinden daha büyük değerlere sahip olan şablonlar işlenmiştir. Komşuluk havuzu tekniğinde sürenin düşmesinin nedeni ise hem eşik değerinden büyük hem de komşuluk dışında kalan şablonların işlenmesidir. Dolayısıyla sahte eşleşmelerin tümünün es geçildiği düşünüldüğünde zaten sürenin düşmesi oldukça doğaldır. Tablo aynı zamanda görüntü boyutlarının işlem süresine olan etkisini de göstermektedir ki görüntü boyutu arttıkça tarama süresi arttığından dolayı hesaplama süresi de artmıştır. Bu tablodaki komşuluk büyüklüğü görüntülerdeki en uygun eşleşmeyi gerçekleştiren şekilde tercih edilmiştir.

Tablo 2. Klasik şablon eşleme ile komşuluk havuzu tekniği karşılaştırması

Test Görüntüsü	r	Görüntü Boyutu	Gerçek Nesne Sayısı	Çalışma Süresi (s)	Eşleşme Sayısı	Komşuluk	Çalışma Süresi (s)	Hızlanma	Eşleşme Sayısı
1	0,5	304 x 370	1	28,172	105	10 x 10	5,2241	~5x	1
	0,8			24,6534	50			~5x	
2	0,6	300 x 150	5	12,0071	557	40 x 40	1,756	~7x	5
	0,8			9,1933	114			~5x	
3	0,5	534 x 360	2	45,3704	256	10 x 10	11,9876	~4x	2
	0,8			36,0418	125			~3x	

Tablo-3, literatürdeki şablon eşleme tekniklerini gerçekleştirmek için kullanılan hesaplama tekniklerinden bazılarını göstermektedir. Araştırmaların NCC'nin yüksek hesaplama maliyetini düşürmeye çalışarak bir avantaj sağlamaya çalıştıkları aşikârdır. Benzer şekilde SSD ve SAD içinde benzerlik kalitesini artırmaya yönelik çalışmaların literatürde yoğunlaştığı görülmektedir. Bu çalışmada ise bunlardan farklı olarak arama aşamasında bir iyileştirme yapılarak şablon eşleme güçlendirilmiştir.

Tablo 3. Literatürde farklı benzerlik metriği ile gerçekleştirilen şablon eşleme araştırmaları

Referans	Benzerlik Ölçüm Metriği (Korelasyon Katsayısı)	Amaç ve Sonuç
Hisham, vd., 2015	Sum of Squared Difference (SSD) ve NCC	Amaç: Şablon eşlemede kullanılan SSD ve NCC benzerlik ölçüm yöntemlerini karşılaştırmışlardır. Sonuç: SSD'nin daha basit olması nedeniyle daha kısa sürede netice almalarına rağmen NCC'nin karmaşık yapısına karşın daha güçlü bir benzerlik ortaya koyduğunu ifade etmişlerdir.
Kusuma, vd., 2016	Sum of Squared Difference – SSD	Amaç: Omurgadaki herhangi bir rahatsızlığın daha hızlı ve kesin olarak tespit edilmesi amacıyla şablon eşleme tekniğini kullanmışlardır. Sonuç: Omurga tespitini yaklaşık 20-40 s sürelerinde 96% oranında tespit edebilmişlerdir.
Dawoud, vd., 2011	Sum of Absolute Difference (SAD)	Amaç: SAD benzerlik ölçüm tekniğini optimize ederek sistemin performansını artırmak. Sonuç: Optimized SAD (OSAD) ismini verdikleri yeni yöntemle Yale veri setinde bulunan örnek görüntülerle yüz tespit testlerini gerçekleştirmişlerdir. Yeni yöntemi 9 farklı benzerlik metriğiyle kıyaslamışlardır.
Annaby, vd., 2019	Normalized cross correlation (NCC)	Amaç: Benzerlik performansı oldukça iyi olan ancak hesaplama maliyeti yüksek olan NCC tekniğini geliştirerek daha kısa sürelerde şablon eşleme algoritmasını uygulamak. Sonuç: NCC tekniğini DCT fikriyle geliştirilerek işlem süresini kısaltmışlardır. Test işlemlerinde PCB kartlarındaki baskı kusurlarını tespit etmişlerdir.
Kaso, 2018	Normalized cross correlation (NCC)	Amaç: NCC'nin arama işlemindeki yüksek zaman maliyetli dezavantajını azaltmak. Sonuç: NCC hesaplamasını Fast Fourier Transform (FFT) üzerinden gerçekleştirerek hesaplama süresini azaltabilmiştir. Test işlemleri için biyomedikal görüntüler kullanılmıştır.

4. SONUÇLAR

Bu çalışmada literatürde daha önce aynı araştırmacılar tarafından önerilen ve şablon eşleme yöntemini hem sahte eşleşmelere karşı hem en yüksek eşleşme oranına hem de yüksek hesaplama süresine karşı geliştiren Komşuluk Havuzu (Neighbourhood Pooling) yöntemi derinlemesine analiz edilmiştir. Analizde r eşleşme katsayısı, görüntü boyutu ve komşuluk büyüklüğü parametrelerinin değişmesinin yöntemin başarısına olan etkileri incelenmiş ve endüstriyel

ortamdan elde edilen görüntülerle gerçekleştirilen deneylerle kanıtlanmıştır. Deneylerde ayrıca farklı boyutlarda şablonların eşleştirilmesinde komşuluk büyüklüğünün etkisi de incelenmiştir. Dolayısıyla deneylerde yöntemin yüksek sayıda sahte eşleşme ve uzun tarama süresiyle nasıl başa çıktığı detaylıca ortaya konarken aynı zamanda en yüksek benzerliğe sahip çerçevenin elde edilmesi sağlanmıştır. Yapılan deneylerde önerilen yöntemin sahte eşleşmeleri komşuluk boyutuna göre hangi oranda engellediği ve tespit edilen doğru eşleşme seviyelerini hangi oranda ortaya koyduğu üzerine yoğunlaşmıştır. Bunun için farklı komşuluk boyutuna sahip matrisler eşliğinde şablon eşleşme yöntemi işletildiğinde tahmin edildiği gibi sahte eşleşmelerin engellendiği görülmüştür. Sahte eşleşmelerin engellenme oranına paralel olarak da algoritmanın çalışma süresinin düştüğü gözlemlenmiştir. Bu durum klasik şablon eşleşmeyle karşılaştırıldığında 3.5 – 7.5 katlık bir hızlanma anlamına gelmektedir.

TEŞEKKÜR

Bu çalışma Sakarya Uygulamalı Bilimler Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından desteklenmiştir. Proje numarası: 110-2022.

ÇIKAR ÇATIŞMASI

Yazarlar, bilinen herhangi bir çıkar çatışması veya herhangi bir kurum/kuruluş ya da kişi ile ortak çıkar bulunmadığını onaylamaktadırlar.

YAZAR KATKISI

“Serkan Dereli çalışmanın kavramsal ve tasarım süreçlerinin belirlenmesi, yönetimi ve sonuçların yorumlanması, Asiye Rümeysa Ünsal test ve deneylerin gerçekleştirilmesi, sonuç verilerinin elde edilmesi, görselleştirilmesi ve yorumlanması”

KAYNAKLAR

1. Aktaş, H., (2015). Şablon Eşleştirme Yöntemi İle Nesne Takibi Ve Yüksek Hızlı Fpga Gerçekleşmesi, Antalya: Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.
2. Alemdar, F. ve Avcı, N., (2019). Sarsma masası testlerindeki dinamik parametrelerin görüntü işleme yöntemi ile ölçülmesi. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 10(3), pp. 1099-1112. doi: 10.24012/dumf.524027
3. Annaby, M. H., Fouda, Y. M. ve Rushdi, M. A., (2019). Improved normalized cross-correlation for defect detection in printed-circuit boards. *EEE Transactions on Semiconductor Manufacturing*, 32(2), pp. 199-211. doi: 10.1109/TSM.2019.2911062
4. Aqel, M. O., Marhaban, M. H., Saripan, M. I. ve Ismail, N. B., (2016). Adaptive-search template matching technique based on vehicle acceleration for monocular visual odometry system. *IEEJ Transactions on Electrical and Electronic Engineering*, 11(6), pp. 739-752. doi: 10.1002/tee.22299
5. Atallah, M. J., (2001). Faster image template matching in the sum of the absolute value of differences measure. *IEEE Transactions on image processing*, 10(4), pp. 659-663. doi: 10.1109/83.913600.
6. Can, E. ve Canay, Ö., (2016). A planar robot design and construction with Maple, *TOJSAT*, 6(2), 1-5.

7. Canay, O. ve Kocabıçak, Ü., (2024). Predictive modeling and anomaly detection in large-scale web portals through the CAWAL framework, *Knowledge-Based Systems*, 306, pp. 1-15. doi: 10.1016/j.knosys.2024.112710
8. Chantara, W., Mun, J. H., Shin, D. W. ve Ho, Y. S., (2015). Object tracking using adaptive template matching. *IEIE Transactions on Smart Processing & Computing*, 4(1), pp. 1-9. doi: 10.5573/IEIESPC.2015.4.1.001.
9. Dawoud, N. N., Samir, B. B. ve Janier, J. (2011). Fast template matching method based optimized sum of absolute difference algorithm for face localization. *International Journal of Computer Applications*, 18(8), 0975-8887.
10. Dereli, S. ve Ünsal, A. R., (2023). A new microarchitecture hardware proposal for the use of the improved template matching method in face similarity detection. *Microprocessors and Microsystems*, Cilt 101, pp. 1-9. doi: 10.1016/j.micpro.2023.104908.
11. Di Stefano, L., Mattocchia, S. ve Tombari, F., (2005). ZNCC-based template matching using bounded partial correlation. *Pattern recognition letters*, 26(14), pp. 2129-2134. doi: 10.1016/j.patrec.2005.03.022
12. Efeoğlu, E. ve Gürkan, T., (2021). Radyografi Görüntüleri Ve Sınıflandırma Algoritmaları ullanılarak Omuz Protezlerinin Üreticilerinin Belirlenmesi.. *Kırklareli Üniversitesi Mühendislik ve Fen Bilimleri Dergisi*, 7(1), pp. 57-73. doi: 10.34186/klujes.906660
13. Hisham, M. B., Yaakob, S. N., Raof, R. A. A., Nazren, A. A. ve Wafi, N. M. (2015). Template matching using sum of squared difference and normalized cross correlation, *IEEE student conference on research and development*. doi: 10.1109/SCORED.2015.7449303
14. Hsu, F. H. ve Shen, C. A., (2018). The design and implementation of an embedded real-time automated IC marking inspection system. *IEEE Transactions on Semiconductor Manufacturing*, 32(1), pp. 112-120. doi: 10.1109/TSM.2018.2875920
15. Huang, Y. W., Chen, C. Y., Tsai, C. H., Shen, C. F. ve Chen, L. G. (2006). Survey on block matching motion estimation algorithms and architectures with new results. *Journal of VLSI signal processing systems for signal, image and video technology*, Cilt 42, pp. 297-320. doi: 10.1007/s11265-006-4190-4.
16. Jiao, J., Wang, X., Deng, Z., Cao, J. ve Tang, W. (2018). A fast template matching algorithm based on principal orientation difference. *International Journal of Advanced Robotic Systems*, 15(3). doi: 10.1177/1729881418778.
17. Kaso, A. (2018). Computation of the normalized cross-correlation by fast Fourier transform. *PloS One*, 13(9), e0203434. doi: 10.1371/journal.pone.0203434.
18. Kim, H. Y., (2010). Rotation-discriminating template matching based on Fourier coefficients of radial projections with robustness to scaling and partial occlusion. *Pattern Recognition*, 43(3), pp. 859-872. doi: 10.1016/j.patcog.2009.08.005.
19. Kusuma, B. A., Nugroho, H. A. ve Wibirama, S. (2016). Spinal curvature determination from scoliosis X-Ray image using sum of squared difference template matching. In *2016 2nd International Conference on Science and Technology-Computer (ICST)* (pp. 29-34). IEEE. doi: 10.1109/ICSTC.2016.7877343.
20. Lai, J., Lei, L., Deng, K., Yan, R., Ruan, Y. Ve" Jinyun, Z. (2020). Fast and robust template matching with majority neighbour similarity and annulus projection transformation. *Pattern Recognition*, Cilt 98, pp. 1-11. doi: 10.1016/j.patcog.2019.107029.

21. Le, M. T., Tu, C. T., Guo, S. M. ve Lien, J. J. J., (2020). A PCB alignment system using RST template matching with CUDA on embedded GPU board. *Sensors*, 20(9), pp. 1-26. doi: 10.3390/s20092736.
22. Ouyang, W., Tombari, F., Mattocchia, S., Di Stefano, L., Cham, W. K. (2012). Performance evaluation of full search equivalent pattern matching algorithms. *IEEE transactions on pattern analysis and machine intelligence*, 34(1), pp. 127-143. doi: 10.1109/TPAMI.2011.106.
23. Yan, B., Xiao, L., Zhang, H., Xu, D., Ruan, L., Wang, Z., Zhang, Y. (2019). An adaptive template matching-based single object tracking algorithm with parallel acceleration. *Journal of Visual Communication and Image Representation*, Cilt 64, pp. 1-13. doi: 10.1016/j.jvcir.2019.102603.
24. Yaşar, F. G. ve Alaybeyoğlu, A., (2018). Otomatik Araç Plaka, Renk ve Marka Tanıma Sistem Tasarımı. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri Ve Mühendisliği Dergisi*, 11(1), pp. 7-16.

