

AKÜ FEMÜBİD 22 (2022) 015101 (100-111)

AKU J. Sci. Eng. 22 (2022) 015101 (100-111)

DOI: 10.35414/akufemubid.1013047

Araştırma Makalesi / Research Article

# Mısır Tohumu Embriyolarının Bölütlenmesinde Tam Evrişimsel Ağ Tabanlı Mimarilerin Tam Bağlı Şartlı Rastgele Alanlar ile Entegrasyonu

Serdar ALASU<sup>1</sup>, Muhammed Fatih TALU<sup>1</sup><sup>1</sup> İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Malatya.Sorumlu yazar e-posta: serdaralasu@gmail.com ORCID ID: <http://orcid.org/0000-0003-2267-9707>fatihtalu@gmail.com ORCID ID: <http://orcid.org/0000-0003-1166-8404>

Geliş Tarihi: 21.10.2021

Kabul Tarihi: 14.02.2022

## Öz

Haploid ve diploid mısır tohumlarının sınıflandırılması mısır ıslahında önemli bir konudur. R1-nj renk markörü sayesinde haploid ve diploid mısır tohumları embriyolarındaki renklerin farklılıkları dikkate alınarak görsel olarak ayırt edilebilmektedir. Bu nedenle, mısır tohumu embriyolarının bölütlenmesi haploid ve diploid mısır tohumlarının sınıflandırılması için önemli bir ön-ışlemdir. Bu çalışmada, mısır tohumu görüntülerinin otomatik embriyo bölütlenmesinde tam evrişim ağ tabanlı derin öğrenme mimarilerinin (FCN8s, SegNet ve U-Net) bölütleme performansları değerlendirilmektedir ve bölütleme çıktılarının tam bağlı Şartlı Rastgele Alanlar yöntemiyle düzgünleştirilmesi incelenmektedir. Böylece tam bağlı Şartlı Rastgele Alanların bölütleme sonucuna etkisi araştırılmıştır. Ayrıca bu çalışma için mısır tohumu görüntüleri piksel seviyesinde etiketlenerek referans görüntüler elde edilmiş ve haploid ve diploid mısır tohumu görüntüleri için yeni bir semantik görüntü bölütleme veri seti oluşturulmuştur. Çalışma sonuçları göstermiştir ki, tam evrişim ağ tabanlı derin öğrenme mimarileri ile tam bağlı Şartlı Rastgele Alanlar'ın birlikte kullanımı, görüntü bölütleme sonucunu ortalama IoU performans değerlendirme metriğinde FCN8s, SegNet ve U-Net derin öğrenme mimarileri için sırasıyla 0.0139, 0.0076, 0.0024 iyileştirdiği görülmüştür.

### Anahtar kelimeler

Mısır Tohumu Embriyo  
Bölütleme; Semantik  
Bölütleme; Tam  
Evrişimsel Ağlar;  
SegNet; U-Net; Tam  
Bağlı Şartlı Rastgele  
Alanlar

## Integration of Fully Convolutional Network Based Architectures with Fully Connected Conditional Random Fields in Maize Seed Embryos Segmentation

### Abstract

Classification of haploid and diploid maize seeds is an important issue in maize breeding. Thanks to the R1-nj color marker, haploid and diploid maize seeds can be visually distinguished by considering the coloration differences in embryos. Therefore, segmentation of maize seed embryos is an important pre-processing for the classification of haploid and diploid maize seeds. In this study, the segmentation performances of fully convolution network-based deep learning architectures (FCN8s, SegNet and U-Net) in automatic embryo segmentation of maize seed images are evaluated and the smoothing of segmentation outputs with the fully connected Conditional Random Fields method is examined. Thus, the effect of fully connected Conditional Random Fields on the segmentation result was studied. In addition, for this study ground truths were obtained by labeling the maize seed images at the pixel level, and a new semantic image segmentation dataset was created for the haploid and diploid maize seed images. The study results showed that the combined use of full convolution network-based deep learning architectures and fully connected Conditional Random Fields improved the image segmentation result in the mean IoU performance evaluation metric for FCN8s, SegNet and U-Net deep learning architectures by 0.0139, 0.0076, 0.0024, respectively.

### Keywords

Maize Seed Embryo  
Segmentation;  
Semantic  
Segmentation; Fully  
Convolutional  
Networks; SegNet, U-  
Net; Fully Connected  
Conditional Random  
Fields

## 1. Giriş

Görüntüyü, benzer özellikleri içeren bölümlere ayırmayı sağlayan görüntü bölütleme bilgisayarlı görünümün önemli alanlarından biridir. Görüntü bölütleme sayesinde anlamlı ve anlaşılması daha kolay bir görüntü elde edilmektedir. Otonom sürüş, medikal görüntü analizi ve robot navigasyonu vb. birçok bilgisayarlı görü uygulamasında görüntünün bölütlenmesine ihtiyaç duyulmaktadır. Görüntü bölütleme, semantik bölütleme ve örnek (instance) bölütleme olarak ikiye ayrılmaktadır (Minaee *et al.* 2021). Semantik bölütleme, bir görüntünün her bir pikselinin bir sınıf etiketi ile ilişkilendirildiği bir sınıflandırma işlemidir. Semantik bölütlemeye aynı sınıfa ait ayrı örnekler aynı değerlerle etiketlenmektedir. Örnek bölütlemeye ise semantik bölütlemeye farklı olarak aynı sınıfa ait ayrı örnekler için farklı etiketler kullanılmaktadır. Bu çalışmada haploid ve diploid mısır tohumlarının embriyolarının semantik bölütlenmesi çalışması yapılmıştır.

Mısır, hem insan hem de hayvan tüketimi için en önemli tahıllardan biridir. Bu nedenle daha verimli mısır çeşitlerinin geliştirilebilmesi için mısır ıslah çalışmaları yapılmaktadır. Saf hatların elde edilmesini amaçlayan mısır ıslahında, haploid mısır tohumlarının varlığı önemlidir. Haploid mısır tohumları doğada %0.1 gibi çok düşük bir frekansta bulunmakta ve diploid mısır tohumlarından oldukça zor ayırt edilmektedirler. Gerek haploid mısır tohumu frekansının artırılması, gerekse haploid mısır tohumlarının ayırt edilebilmesi için Nanda ve Chase (1966) tarafından geliştirilen dominant R1-nj genine sahip bitkiler tozlayıcı olarak kullanılarak melezleme yapılmakta ve melezleme sonucunda elde edilen tüm tohumların endospermilerinde renklenme ortaya çıkmaktadır. Bununla birlikte sadece diploid mısır tohumlarının embriyolarında renklenme görülürken haploid mısır tohumlarının embriyolarında renklenme görülmemektedir. Bu durum haploid ve diploid mısır tohumlarının gözle sınıflandırılmasını mümkün kılmaktadır. Ancak sınıflandırma işleminin insan gözü ile yapılıyor olması, sınıflandırma hatalarına, zaman ve emek kaybına sebep olmaktadır (Altuntaş vd. 2018a). Bu nedenle tohumların otomatik olarak

sınıflandırılması için çalışmalar yapılmıştır (Altuntaş *et al.* 2018b, Altuntaş *et al.* 2019a, De La Fuente *et al.* 2017, Wang *et al.* 2018).

Mısır embriyosunun mısır tohumuna dair pek çok değerli bilgiyi içerdiği bilinmektedir. Haploid ve diploid mısır tohumlarının embriyolarının farklı olarak renklenmesi, bu tohumların sınıflandırılmasında embriyonun bölütlenmesini önemli hale getirmektedir. Altuntaş ve Kocamaz (2019b) çalışmalarında tüm mısır tohumu görüntüsü yerine sadece embriyo görüntüsü kullanmanın sınıflandırma başarımını arttıracaklarını belirtmişlerdir. Literatürde klasik yöntemler kullanılarak mısır tohumu embriyo bölütlemesi yapan çalışmalar yapılmıştır. Ma vd. (2014) çalışmalarında mısır çeşidi tespitinde, mısır tohumlarının embriyo karakteristiğinden faydalanarak elde ettiği altı özneliği kullanmıştır. Embriyo bölütlemesi için ampirik olarak eşik değeri belirlenmesi yerine her mısır tohumu görüntüsüne özgü adaptif eşik değerini OTSU (Otsu 1979) metodu ile hesaplayarak embriyo bölütlemesini gerçekleştirmişlerdir. Chu vd. (2014) çalışmalarında küflü mısır tohumlarını tespit ederken embriyo bölütlemesi yapmaktadırlar. Embriyo bölgesinin bulunmasında ilk önce mısır tohumunun ağırlık merkezi tespit edilmektedir. Tespit edilen konum, embriyo bölgesini oluşturacak ampirik olarak çapı belirlenen çemberin merkezidir. Altuntaş ve Kocamaz (2019b) çalışmalarında haploid ve diploid mısır tohumlarını ayırt etme işlemi yaparken embriyo bölütleme işlemi gerçekleştirmektedirler ve bu çalışmada mısır tohumu embriyoları k-ortalama kümeleme yöntemi ile bölütlenmektedir. Ancak bu çalışmalarda embriyo bölütleme işlemi, mısır tohumu sınıflandırmasının bir ön işlemi olarak kullanılmıştır. Bu nedenle bu çalışmalarda kullanılan embriyo bölütleme yöntemleri için performans değerlendirmesi yapılmamıştır.

Bu çalışmada mısır tohumu embriyolarının klasik yöntemler kullanarak bölütlenmesinden farklı olarak, semantik bölütlemeye başarılı olan tam evrim ağ tabanlı FCN8s (Long *et al.* 2015), SegNet (Badrinarayanan *et al.* 2017) ve U-Net (Ronneberger *et al.* 2015) derin öğrenme mimarilerinin bölütleme performansları değerlendirilmektedir ve bölütleme çıktılarının tam bağlı Şartlı Rastgele Alanlar (ŞRA)

yöntemiyle düzgünleştirilmesi incelenmektedir. Ayrıca bu çalışma için haploid ve diploid mısır tohumu görüntüleri piksel seviyesinde etiketlenerek referans görüntüler elde edilmiş ve haploid ve diploid mısır tohumu görüntüleri için yeni bir semantik görüntü bölütleme veri seti oluşturulmuştur. İlk olarak FCN8s, SegNet ve U-Net derin öğrenme mimarileri oluşturulan veri setinde eğitilerek bölütleme sonuçları elde edilmiştir. İkinci olarak, eğitilmiş bu mimariler sonrasında tam bağlı ŞRA son işlem olarak kullanılmıştır. Böylece tam evrişim ağ tabanlı FCN8s, SegNet ve U-Net derin öğrenme mimarileri sonrasında tam bağlı ŞRA'nın kullanılmasının bölütleme sonucuna etkisi incelenebilmektedir. Normal mısır tohumlarında embriyo ve endospermin bölütlenmesi kolay bir görevken, Navajo geninin farklı renk tonlarında ve büyüklüklerinde ortaya çıkması haploid ve diploid mısır tohumlarında embriyo bölütlemeyi zorlu bir göreve dönüştürmektedir. Bu çalışma bildiğimiz kadarıyla mısır tohumu embriyolarının bölütlenmesinde derin öğrenme yöntemlerinin kullanıldığı ilk çalışmadır.


Makalenin geri kalanı şu şekilde düzenlenmiştir: II. Bölüm'de, kullanılan veri seti ve yöntemler anlatılmıştır. III. Bölümde deneysel sonuçlara yer verilip, model sonuçları değerlendirilmiştir. IV. Bölümde ise tartışma ve sonuç kısmı yer almaktadır.

## 2. Materyal ve Metod

### 2.1. Veri Seti

Bu çalışmada, Haploid ve Diploid Mısır Tohum Görüntü Veri Seti (Altuntaş *et al.* 2019a) kullanılmıştır. Orijinal veri seti 300x289 ile 610x637 çözünürlükleri arasında değişen 3000 renkli görüntüden oluşmaktadır. Çalışma kapsamında kullanılmak üzere, orijinal veri setinden 100'er adet haploid ve diploid mısır tohumu görüntüsü rastgele seçilmiştir. Seçilen görüntüler en boy oranı korunarak 224x224 çözünürlüğe yeniden boyutlandırılmıştır. Semantik bölütlemeye piksel seviyesinde sınıflandırma yapıldığı için veri setini oluşturacak referans görüntülerinin piksel seviyesinde etiketlenmesi gerekmektedir. Matlab programına dilinin Image Labeler aracı kullanılarak,

seçilen mısır tohumu görüntüleri piksel seviyesinde arka plan, endosperm ve embriyo olarak etiketlenerek oluşturulan mısır tohumu referans görüntüleriyle yeni bir veri seti oluşturulmuştur. 100 adet haploid ve 100 adet diploid toplam 200 mısır tohumu görüntüsünün %60'ı (120 adeti) eğitim, %20'si (40 adeti) doğrulama ve %20'si (40 adeti) de test veri seti olarak kullanılmıştır. Şekil 1'de bölütlenmiş örnek haploid ve diploid mısır tohumu görüntüsü ve referans görüntüleri gösterilmektedir.



Şekil 1. a) Haploid mısır tohumu, b) Etiketli haploid mısır tohumu, c) Diploid mısır tohumu, d) Etiketli diploid mısır tohumu


### 2.2. Tam Evrişim Ağ Tabanlı Bölütleme Yöntemleri

Klasik yöntemler ayırt edici özneliklerin çıkarılmasında uzman bilgisine ihtiyaç duyarken, derin öğrenme yöntemleri, uzman bilgisine ihtiyaç duymadan otomatik olarak probleme özgü özneliklerin çıkarılmasını sağlamaktadır (Sultana *et al.* 2020). Ancak derin öğrenme mimarileri ayırt edici özneliklerin çıkarılmasında büyük miktarda etiketli veriye ve bu mimarilerin eğitimini sağlayacak donanımlara ihtiyaç duymaktadır. Son yıllarda etiketli verinin artması ve Grafik İşleme Birimlerinin (Graphic Processing Unit, GPU) teknolojisinin gelişmesiyle birlikte derin öğrenme mimarileri yaygın bir şekilde kullanılmaya başlanmıştır. Özellikle AlexNet Derin Evrimsel Sinir Ağı (DESA) mimarisinin (Krizhevsky *et al.* 2012) sınıflandırma problemlerinde büyük başarı elde etmesiyle birlikte, araştırmacılar semantik bölütlemeye de DESA mimarilerini kullanmaya başlamışlardır.

#### 2.2.1. FCN

FCN, DESA mimarisini kullanarak semantik bölütlemeye kullanan ilk derin öğrenme yöntemlerinden biri olmuştur. FCN, VGG-16


(Simonyan and Zisserman 2015) mimarisinin tam bağlı katmanının yerine evrişim katmanlarını kullanarak semantik bölütleme gerçekleştiren tam evrimsel ağ tabanlı bir mimardir. FCN mimarisi tamamiyle evrişim katmanlarından oluştuğu için istenilen boyutta görüntüyü girdi olarak kullanabilmektedir. Bu mimaride art arda uygulanan evrişim ve havuzlama işlemleriyle yüksek boyutlu bir görüntü düşük boyutlu bir görüntüye dönüştürülmektedir. Art arda uygulanan bu işlemler sayesinde ilk katmanlarda düşük seviyeli öznelilikler, sonraki katmanlarda ise daha yüksek seviyeli öznelilikler öğrenilmektedir. Semantik bölütleme çıktısının boyutu girdi görüntüsünün boyutu ile aynı boyutta olmak zorunda olduğundan, küçülen görüntü boyutu, transpoz evrişim kullanılarak gerçek görüntü boyutuna getirilmektedir. FCN mimarisinin ilk örneği olarak, art arda uygulanan maksimum havuzlama işlemiyle görüntü boyutunu 32 kat küçülten ve transpoz evrişimle 32 kat görüntü boyutunu büyüterek gerçek boyutuna dönüştüren FCN-32s mimarisi önerilmiştir. Şekil 2’de FCN mimarisi gösterilmektedir.



Şekil 2. FCN mimarisi (Long et al. 2015)

FCN-32s mimarisinde görüntü boyutunu 32 kat küçültülmesi nedeniyle uzamsal bilgide kayıplar olmakta ve sonuç olarak kaba bir bölütleme elde edilmektedir. Bu problemin çözümü için daha iyi uzamsal bilgiye sahip ara katmanlardan faydalanan FCN-16s ve FCN-8s mimarileri önerilmiştir. Bu mimarilerde ara katmanlar ile son katmanlar atlama bağlantısıyla birleştirilerek kaba bölütleme sorunu çözülmeye çalışılmaktadır. FCN-16s mimarisinde, en son maksimum havuzlama katmanının (pool5) çıktısı 2 kat büyütülür ve bir önceki maksimum havuzlama (pool4) katmanının çıktısı ile birleştirilmektedir.

Birleştirme sonucu 16 kat büyütülerek görüntü gerçek boyutuna dönüştürülmektedir. FCN-8s mimarisinde ise, en son maksimum havuzlama katmanının(pool5) çıktısı 2 kat büyütülüp, bir önceki maksimum havuzlama (pool4) katmanının çıktısı ile birleştirilir ve elde edilen birleştirme sonucu 2 kat büyütülerek bir önceki maksimum havuzlama katmanının (pool3) çıktısı ile birleştirilmektedir. Son olarak 8 kat büyütülerek görüntü gerçek boyutuna dönüştürülmektedir. Şekil 3’te FCN-32s, FCN-16s ve FCN-8s mimarileri gösterilmektedir.

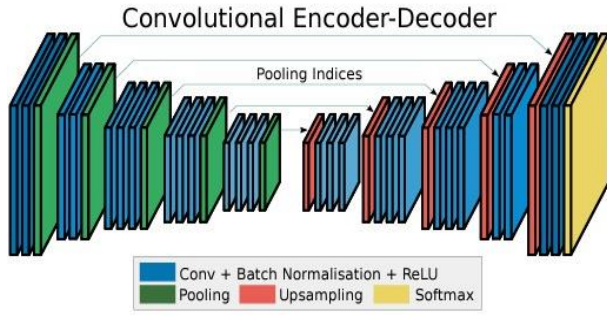


Şekil 3. FCN-32s, FCN -16s ve FCN-8s mimarileri (Long et al. 2015)

### 2.2.2. SegNet

Kodlayıcı-kod çözücü mimaride olan SegNet tam evrimsel ağ tabanlı diğer bir semantik bölütleme mimarisidir. SegNet, bir kodlayıcı ağına ve buna karşılık gelen bir kod çözücü ağına sahiptir. SegNet kodlayıcı ağında son bağlı katmanı çıkarılmış VGG16, ağ modeli kullanılmaktadır. Kodlayıcı kısmında, görüntüye evrişim, yığın normalizasyonu, ReLU aktivasyon fonksiyonu ve maksimum havuzlama işlemleri uygulanarak görüntü kodlanmaktadır. Kodlanan görüntü, kod çözücü ağında evrişim ve ters havuzlama ile gerçek görüntü boyutuna büyütülmekte ve son katmanında da piksel seviyesinde sınıflandırma yapılarak bölütleme sonucunu oluşturulmaktadır. SegNet’in en önemli özelliklerinden biri kodlayıcı ağının havuzlama katmanlarında maksimum havuz indekslerini depolaması ve bu indisleri kod çözücü ağında ters havuzlama işlemiyle kullanmasıdır. Böylece kod çözücü ağında görüntünün boyutu büyütülürken bu indislerin sağladığı konum bilgisinden faydalanılmaktadır. SegNet mimarisinde diğer Tam Evrişim Ağ Tabanlı semantik bölütleme yöntemlerinden farkı olarak ters evrişim işlemi

uygulanmamaktadır. Şekil 4'te SegNet mimarisi gösterilmektedir.




Şekil 4. SegNet mimarisi (Badrinarayanan *et al.* 2017)

### 2.2.3. U-Net

Tam evrişim ağ tabanlı diğer bir mimari de U-Net mimarisidir. U-Net mimarisi, SegNet mimarisi benzer şekilde ayırt edici özneliklerin çıkarılması için görüntünün boyutunun küçültüldüğü kodlayıcı ağ ve öznelik haritasının büyütülerek gerçek görüntü boyutuna dönüştürüldüğü kod çözücü ağdan oluşmaktadır. Tam evrimsel ağ mimarisine dayalı bölütleme yöntemleri iyi bölütleme sonucu elde edebilmek için eğitim aşamasında çok fazla etiketlenmiş görüntüye ihtiyaç duymaktadır. U-Net mimarisi az sayıda etiketlenmiş görüntüyle eğitilebilmektedir. Bu nedenle özellikle etiketlenmiş görüntü elde etmenin zor olduğu biyomedikal görüntü bölütleme uygulamalarında U-Net mimarisi sıklıkla kullanılmaktadır. U-Net mimarisi kodlayıcı ve kod çözücü ağ katmanlarını daralma ve genişleme katmanları olarak adlandırılır. U-Net mimarisinin kodlayıcı ağında her maksimum havuzlama işleminden sonra görüntü boyutu yarıya düşerken öznelik haritası sayısı iki katına çıkarılmaktadır. Kod çözücü kısmında ise ters evrişim işlemiyle görüntü boyutu iki katına çıkarılırken öznelik harita sayısı yarıya düşürülmektedir. Kodlayıcı aği derinleştikçe yüksek seviyeli özneliklerin öğrenilmesini sağlanırken, maksimum havuzlama işlemi nedeniyle girdi görüntüsünün çözünürlüğü azaldığı için uzamsal bilginin detaylarında kayıplar olmaktadır. U-Net mimarisinde daralma katmanındaki daha iyi uzamsal bilgiye sahip öznelik haritaları, genişleme katmanında aynı seviyede bulunan öznelik haritalarıyla atlama bağlantısıyla birleştirilerek kayıp

olan uzamsal bilgi detayları kurtarılmaktadır. Şekil 5'te U-Net mimarisi gösterilmektedir.



Şekil 5. U-Net mimarisi (Ronneberger *et al.* 2015)

### 2.2.4. Tam Bağlı ŞRA

Semantik bölütlemeye kullanılan diğer bir yöntem de olasılıksal grafik modellerin bir çeşidi olan ŞRA'dır. Sınıf etiketi tahmin edilecek pikseller arasındaki ilişkiyi modelleyen olasılıksal grafik modellerinin bir çeşidi olan ŞRA, semantik bölütlemeye kullanılan diğer bir yaklaşımdır. Çizge ve olasılık teorisini bir araya getiren olasılıksal grafik modellerinde, çizgenin her düğümü bir rastgele değişkenle ilişkilendirilir ve düğümler arasındaki kenarlar düğümlere karşılık gelen değişkenler arasındaki olasılıksal etkileşimi temsil etmektedir (Koller and Nir 2009, Murphy 2012). ŞRA ayırt edici sınıflandırıcılardan elde edilen tekli terim ve görüntü piksel öznelikleri ve pozisyon bilgisinden elde edilen çiftli terimden oluşmaktadır. Literatürde, destek vektör makinaları (Toyoda and Hasegawa 2008), yapay sinir ağları (He *et al.* 2004) vb. sınıflandırıcılar ve Gauss Karışım Modelleri (Arani and Zhang 2014, Wang *et al.* 2009) kullanılarak ŞRA'nın tekli terimini elde eden semantik bölütleme çalışmaları bulunmaktadır. ŞRA semantik bölütlemedeki etiketleme problemini enerji fonksiyonun minimizasyon problemine dönüştürmektedir. Denklem 1'de Çiftli-ŞRA'da kullanılan enerji fonksiyonu gösterilmektedir.

$$E(x) = \sum_i \psi_i(x_i) + \sum_{i,j} \psi_{i,j}(x_i, x_j) \quad (1)$$

$\psi_i(x_i)$  ve  $\psi_{i,j}(x_i, x_j)$  potansiyel fonksiyonlardır ve sırasıyla tekli terim ve çiftli terim olarak

adlandırılırlar ve ŞRA için en önemli konu potansiyel fonksiyonlarının oluşturulmasıdır. ŞRA'da diğer önemli bir konu da enerji fonksiyonunun terimleri hesaplandıktan sonra enerji fonksiyonunu minimize edecek etiket kümesini bulan etkili bir çıkarım algoritmasının uygulanmasıdır. Tekli terim, renk, doku vb. yerel görünüm öznitelikleri bilindiğinde bir pikselin bir sınıfa ait olma olasılıklarını ifade etmektedir. Çiftli terim sayesinde ise birbirine yakın konumda olan ve öznitelikleri birbirine benzeyen pikseller aynı sınıf etiketini almaya zorlanmaktadır. Yüksek dereceli komşuluk içeren enerji fonksiyonları için çıkarım algoritmalarının çalışma sürelerinin çok uzun olması, çiftli terimin genellikle tek dereceli komşuluklardan oluşturulmasına neden olmuştur. Sadece birinci derece komşuluğu hesaba katan çiftli terimler uzun süreli bağımlılıkları yakalayamadığı için kaba bölütleme sonuçları elde etmişlerdir. Krähenbühl ve Koltun (2011) çalışmalarında bir düğümün diğer tüm düğümlere bağlı olduğu çiftli terimleri içeren enerji fonksiyonu ve bu enerji fonksiyonu çok kısa sürede minimize eden mean-field çıkarım algoritmasını önerdiler. Tam bağlı ŞRA olarak isimlendirilen bu yöntem, değişkenler arasındaki uzun süreli bağımlılığı yakalayabildiği için kaba bölütleme sorununa çözüm getirmiştir. Tam Bağlı ŞRA'da tekli terim ( $\psi_i(x_i)$ ), sınıflandırıcı tahminiyle elde edilmektedir. Denklem 2'de tam bağlı ŞRA'nın tekli terim hesabı gösterilmiştir. Denklemdeki  $p(x_i)$ ,  $x_i$  pikselinin sınıf olasılıklarını ifade etmektedir.

$$\psi_i(x_i) = -\log(p(x_i)) \quad (2)$$

Tam Bağlı ŞRA'da çiftli terim hesabı ( $\psi_i(x_i, x_j)$ ) Denklem 3'te gösterilmiştir.

$$\psi_i(x_i, x_j) = \mu(x_i, x_j)[w^1 k^1(f_i, f_j) + w^2 k^2(f_i, f_j)] \quad (3)$$

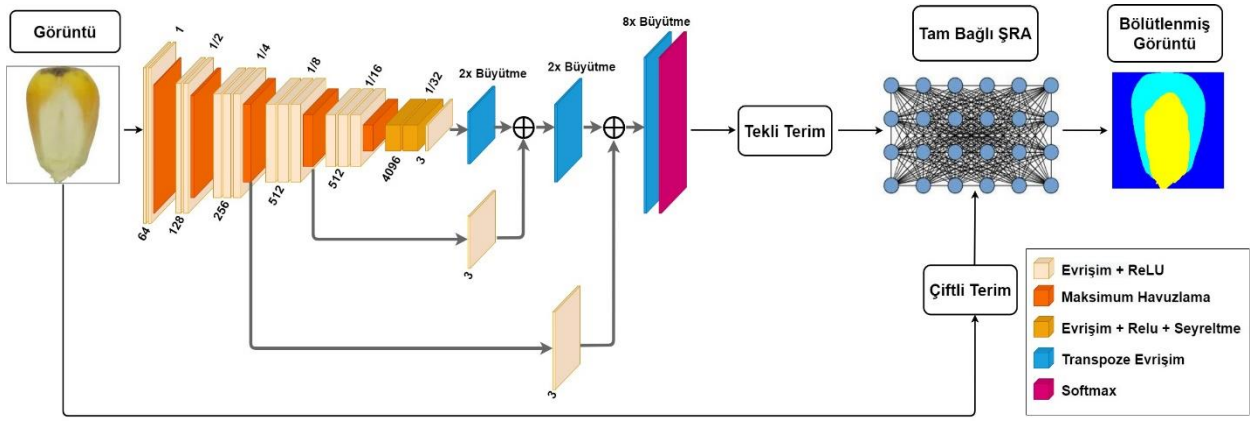
$k^1$  ve  $k^2$  iki gaussian kerneli,  $f_i$  ve  $f_j$  piksel  $i$  ve  $j$  için öznitelik vektörünü  $w^1$  ve  $w^2$  doğrusal kombinasyon ağırlıklarını ve  $\mu$  etiket uyumluluk fonksiyonunu göstermektedir. Denklem 4'te gaussian kernel gösterilmiştir.

$$k(f_i, f_j) = w^1 \exp\left(-\frac{|p_i - p_j|}{2\theta_\alpha^2} - \frac{|l_i - l_j|}{2\theta_\beta^2}\right) + w^2 \exp\left(-\frac{|p_i - p_j|}{2\theta_\gamma^2}\right) \quad (4)$$


### 2.2.5. Son İşlem (Post-Processing) Olarak Tam Bağlı ŞRA'nın Kullanılması

DESA'ya dayalı semantik bölütleme yöntemleri, bir pikselin sınıf etiketine tahmin etmek için, yalnızca yeterince ayırt edici olmayan yerel piksel özniteliklerini kullanmaları nesne sınırlarında bulunan piksellerin sınıf etiketlerinin keskin tahmin edilememesine neden olmakta ve sonuç olarak kaba bir bölütleme elde edilmektedir (Arnab *et al.* 2018). Tam bağlı ŞRA'nın çiftli teriminin yakın konumda bulunan ve benzer öznitelikleri taşıyan pikselleri aynı sınıf etiketine atamaya zorlayan yapısı sayesinde, DESA mimarisinin sonrasında tam bağlı ŞRA'nın kullanılmasının DESA'ya dayalı semantik bölütleme yöntemlerinin elde ettiği kaba bölütleme sonucunu iyileştirdiği görülmüştür (Chen *et al.* 2018). Bu çalışmada Tam Evrim ağ tabanlı FCN-8s, SegNet ve U-Net derin öğrenme mimarilerinin sonrasında tam bağlı ŞRA'yı kullanmanın bölütleme sonucuna etkisi incelenmiştir. Semantik bölütleme için oluşturulan veri setinde tam evrim ağ tabanlı FCN-8s, SegNet ve U-Net mimarileri eğitilmiş ve eğitilen bu mimarilerin softmax çıktısı ile elde edilen sınıf olasılık değerleriyle tam bağlı ŞRA'nın tekli terimi oluşturulmuştur. Çiftli terim ise Denklem 3'te belirttiği üzere iki gaussian kerneli ile oluşturulmaktadır. Şekil 6, Şekil 7 ve Şekil 8'de sırasıyla tam bağlı ŞRA'yı son işlem olarak kullanan FCN-8s-ŞRA, SegNet-ŞRA ve U-Net-ŞRA mimarileri gösterilmiştir.

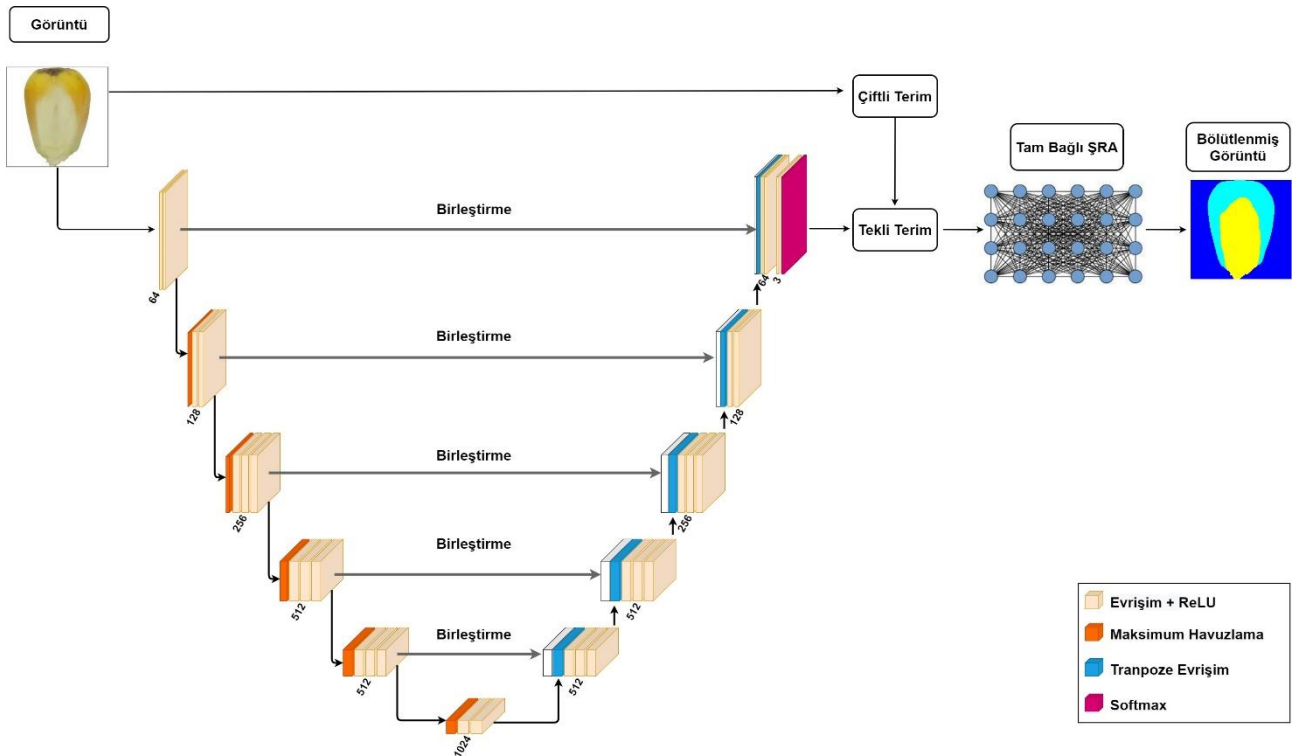




Şekil 6. FCN-8s-ŞRA mimarisi



Şekil 7. SegNet-ŞRA mimarisi



Şekil 8. U-Net-ŞRA mimarisi

### 3. Bulgular

#### 3.1. Uygulama Ayrıntıları

Deneysel çalışmalar, Intel Corei5-9500 3.00 GHz 6 çekirdek işlemci, 16 GB bellek, 240 GB SSD depolama alanına sahip bilgisayarda ve Matlab 2019a platformu üzerinde gerçekleştirilmiştir. Çizelge 1’de FCN-8s, SegNet ve U-Net mimarilerinde kullanılan hiperparametreler gösterilmiştir.

Çizelge 1. Hiperparametreler

Parametreler	Değer
Yığın Boyutu	4
Epoch Sayısı	100
Öğrenme Oranı	0.001
En İyileyici	Adam

Önceden eğitilmiş VGG16 modeli, çalıştırılan bütün mimarilerde omurga (backbone) olarak kullanılmıştır. SegNet ve U-Net kodlayıcı – kod çözücü mimarilerin kodlayıcı ağının ağırlık başlangıç değerleri ImageNet (Deng *et al.* 2009) verisi ile ön eğitilmiş VGG16’ın ağırlıkları ile başlatılırken, kod çözücü ağının ağırlıklarının başlangıç değerleri He vd. (2015) çalışmasında önerilen ağırlık başlatma yöntemi ile belirlenmiştir. Doğrulama maliyetinde önceden belirlenen bir süre içerisinde azalmanın olmadığı durumlar (overfitting) için erken durdurma (early stopping) işlemi uygulanmıştır. Doğrulama maliyeti her epochta 3 defa hesaplanmış ve son 10 doğrulama maliyeti incelenerek erken durdurma yapılıp yapılmayacağına karar verilmiştir. FCN-8s’de 30.Epoch’ta, SegNet’te 51.Epoch’ta ve U-Net’te ise 55.Epoch’ta öğrenme işlemi otomatik olarak durdurulmuştur.

#### 3.2. Performans Değerlendirme Metrikleri

Semantik bölütleme bir görüntüdeki her pikselin sınıf etiketinin tahmin edilme işlemi olduğundan, yapılan işlem görüntüdeki her bir piksel için sınıflandırma yapmaktır. Bu nedenle sınıflandırma problemlerinin performanslarının ölçümünde kullanılan performans değerlendirme metrikleri semantik bölütlemeye de kullanılmaktadır. Bu çalışmada yöntemlerin performans değerlendirmesi için Genel Doğruluk, Ortalama Doğruluk, Ortalama

IoU, Ağırlıklandırılmış IoU ve Ortalama Dice Katsayısı performans değerlendirme metrikleri kullanılmıştır. Metrik hesaplamalarında k sınıf sayısını ve  $p_{ij}$ , i sınıfında olmasına rağmen j sınıfı olarak tahmin edilen piksellerin sayısını göstermektedir. Diğer bir deyişle  $p_{ii}$  doğru pozitif piksel sayısını,  $p_{ij}$  yanlış negatif piksel sayısını,  $p_{ji}$  yanlış pozitif piksel sayısını belirtmektedir (Garcia-Garcia *et al.* 2017).

**Genel Doğruluk:** Doğru olarak sınıflandırılan piksellerin toplam piksel sayısına oranını ile hesaplanmaktadır. Denklem 5’te Genel Doğruluk hesabı gösterilmektedir.

$$\frac{\sum_{i=1}^k p_{ii}}{\sum_{i=1}^k \sum_{j=1}^k p_{ij}} \quad (5)$$

**Ortalama Doğruluk:** Her sınıf için doğru sınıflandırılan piksel sayısının, sınıf toplam piksel sayısına oranıyla sınıf doğrulukları hesaplanır. Hesaplanan sınıf doğruluklarının ortalamasının alınması ile de Ortalama Doğruluk hesaplanmaktadır. Denklem 6’da Ortalama Doğruluk hesabı gösterilmektedir.

$$\frac{1}{k} \sum_{i=1}^k \frac{p_{ii}}{\sum_{j=1}^k p_{ij}} \quad (6)$$

**Ortalama IoU:** Semantik bölütlemeye sıklıkla kullanılan diğer bir performans değerlendirme metriği ortalama IoU metriğidir. IoU metriği tahmin edilen görüntü ve referans görüntü kesişiminin büyüklüğünün, tahmin edilen görüntü ve referans görüntü birleşiminin büyüklüğüne bölünmesiyle hesaplanmaktadır. Her sınıf için ayrı olarak hesaplanan IoU değerinin ortalaması alınarak ortalama IoU değeri elde edilmektedir. Denklem 7’de Ortalama IoU hesabı gösterilmektedir.

$$\frac{1}{k} \sum_{i=1}^k \frac{p_{ii}}{\sum_{j=1}^k p_{ij} + \sum_{j=1}^k p_{ji} - p_{ii}} \quad (7)$$

**Ağırlıklandırılmış IoU:** Ağırlıklandırılmış IoU, her sınıfın piksel sayısına göre ortalama IoU değerlerinin ağırlıklandırılmasıyla hesaplanmaktadır. Denklem 8’de Ağırlıklandırılmış IoU hesabı gösterilmektedir.

$$\frac{1}{\sum_{i=1}^k \sum_{j=1}^k p_{ij}} \sum_{i=1}^k \frac{p_{ii} \sum_{j=1}^k p_{ij}}{\sum_{j=1}^k p_{ij} + \sum_{j=1}^k p_{ji} - p_{ii}} \quad (8)$$



**Ortalama Dice Katsayısı:** F1-Score olarak da bilinen Dice Katsayısı, IoU performans değerlendirme metriği ile beraber en yaygın kullanılan bölütleme metriğidir. Denklem 9'da Ortalama Dice Katsayısı hesabı gösterilmektedir.

$$\frac{1}{k} \sum_{i=1}^k \frac{2p_{ii}}{\sum_{j=1}^k p_{ij} + \sum_{j=1}^k p_{ji}} \quad (9)$$

### 3.3. Deney Sonuçları

FCN-8s, SegNet, U-Net, FCN-8s-ŞRA, SegNet-ŞRA ve U-Net-ŞRA mimarilerinden elde edilen bölütleme sonuçları sırasıyla Çizelge 2, Çizelge 3 ve Çizelge 4'te verilmiştir. Performans değerlendirme metriklerinin tamamında tam evrimsel ağ tabanlı FCN-8s, SegNet ve U-Net derin öğrenme mimarileri

sonrasında tam bağlı ŞRA kullanımının bölütleme sonucunu iyileştirdiği görülmektedir. Tam bağlı ŞRA kullanımı bölütleme sonucunu Ortalama IoU performans değerlendirme metriğinde FCN8s için 0.0139, SegNet için 0.0076 ve U-Net için 0.0024 iyileştirmektedir. Kodlayıcı-kod çözücü yapıdaki SegNet ve U-Net mimarilerine kıyasla, FCN-8s mimarisinde son işlem olarak tam bağlı ŞRA'nın kullanımı bölütleme sonucunu daha fazla iyileştirmektedir. Tam evrim ağ tabanlı mimarilerin elde ettiği bölütleme sonucu iyileştikçe, tam bağlı ŞRA'nın bölütleme sonucuna etkisinin azaldığı görülmektedir.

FCN-8s, SegNet ve U-Net mimarilerinin eğitim ve doğrulama veri setlerine ait maliyet ve doğruluk grafikleri sırasıyla Şekil 9, Şekil 10 ve Şekil 11'de gösterilmiştir.

**Çizelge 2.** FCN-8s ve FCN-8s-ŞRA mimarileri bölütleme sonuçları



Yöntemler	Genel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Ağırlıklandırılmış IoU	Ortalama Dice Katsayısı
FCN-8s	0.96887	0.96186	0.92932	0.94065	0.96236
FCN8s-ŞRA	<b>0.9755</b>	<b>0.97006</b>	<b>0.94321</b>	<b>0.9525</b>	<b>0.9703</b>

**Çizelge 3.** SegNet ve SegNet-ŞRA mimarileri bölütleme sonuçları

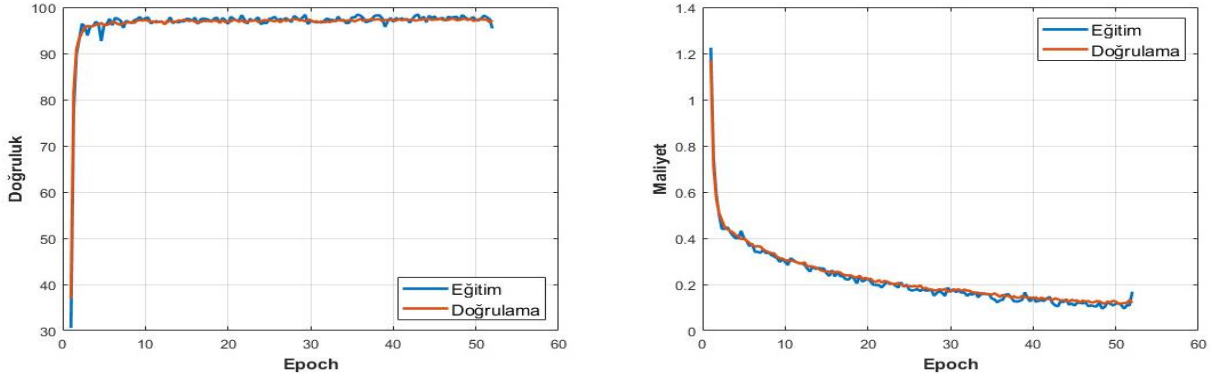
Yöntemler	Genel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Ağırlıklandırılmış IoU	Ortalama Dice Katsayısı
SegNet	0.97248	0.96532	0.93612	0.94737	0.96573
SegNet-ŞRA	<b>0.97609</b>	<b>0.9702</b>	<b>0.9437</b>	<b>0.95352</b>	<b>0.97049</b>

**Çizelge 4.** U-Net ve U-Net-ŞRA mimarileri bölütleme sonuçları

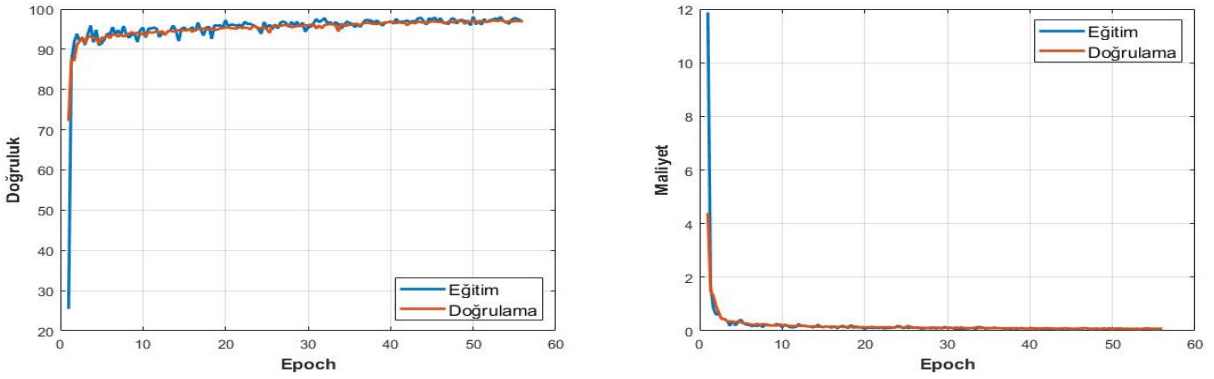
Yöntemler	Genel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Ağırlıklandırılmış IoU	Ortalama Dice Katsayısı
U-Net	0.97644	0.9719	0.94521	0.95477	0.97071
U-Net-ŞRA	<b>0.97791</b>	<b>0.97354</b>	<b>0.94757</b>	<b>0.95672</b>	<b>0.97266</b>



**Şekil9.** FCN-8s mimarisi eğitim ve doğrulama veri setleri doğruluk ve maliyet grafiği




Şekil 10. SegNet mimarisi eğitim ve doğrulama veri setleri doğruluk ve maliyet grafiği



Şekil 11. U-Net mimarisi eğitim ve doğrulama veri setleri doğruluk ve maliyet grafiği

Örnek test görüntüleri için FCN-8s, FCN-8s-ŞRA, SegNet, SegNet-ŞRA, U-Net, U-Net-ŞRA mimarilerinden elde edilen bölütleme sonuçları Şekil 12'de gösterilmiştir. Tam bağlı ŞRA'nın kullanılmadığı bazı örnek test görüntülerininin bölütleme sonuçlarında, endosperm piksel

bloğunun ortasında hatalı olarak embriyo olarak sınıflandırılan pikseller olduğu görülmektedir. Tam bağlı ŞRA kullanımı, bu sorunu birbirine yakın ve benzer özneliklere sahip pikselleri aynı etikete atamaya zorlayan çiftli terimi sayesinde çözmektedir.



Şekil 12. Örnek test görüntüleri bölütleme sonuçları

#### 4. Tartışma ve Sonuç

Bu çalışmada haploid ve diploid mısır tohumlarının embriyo bölütlemesi için, tam evrim ağ tabanlı FCN8s, SegNet ve U-Net derin öğrenme mimarilerinin bölütleme performansları değerlendirilmiştir ve bölütleme çıktıların tam bağlı ŞRA yöntemiyle düzgünleştirilmesi incelenmiştir. Böylece tam bağlı ŞRA'nın bölütleme sonucuna etkisi araştırılmıştır. Ayrıca bu çalışma için mısır tohumu görüntüleri piksel seviyesinde etiketlenerek referans görüntüler elde edilmiş ve haploid ve diploid mısır tohumu görüntüleri için yeni bir semantik görüntü bölütleme veri seti oluşturulmuştur. Son işlem olarak tam bağlı ŞRA kullanımı, Genel Doğruluk, Ortalama Doğruluk, Ortalama IoU, Ağırlıklandırılmış IoU ve Ortalama Dice Katsayısı performans metriklerinin tümünde bölütleme sonucunu iyileştirdiği görülmüştür. Ortalama IoU performans değerlendirme metriğinde tam bağlı ŞRA bölütleme sonucunu FCN8s için 0.0139, SegNet için 0.0076 ve U-Net için 0.0024 artırmaktadır.

Geleneksel bölütleme yöntemleri kullanılarak mısır tohumu embriyo bölütlemesi yapılan çalışmalar mısır tohumu sınıflandırma probleminin bir ön işlemi olarak kullanıldığından, bu çalışmalarda kullanılan embriyo bölütleme yöntemleri için performans değerlendirmesi yapılmamıştır. Bu nedenle bu çalışmada elde edilen bölütleme sonuçları bu yöntemler ile karşılaştırılamamıştır.

Bundan sonraki çalışmalarda tam evrim ağ temelli mimarilerinin birlikte kullanıldığı topluluk(ensemble) yapıda mimariler ve topluluk mimarilerinin son işlemi olarak tam bağlı ŞRA'nın kullanımının bölütleme sonucuna etkisinin araştırılması planlanmaktadır. Ayrıca tüm mısır tohumu görüntüsü yerine, bölütlenmiş embriyo görüntüleri ile haploid ve diploid mısır tohumlarının sınıflandırılması planlanmaktadır.

#### 5. Kaynaklar

Altuntaş, Y., Kocamaz, A.F., Cengiz, R. ve Esmeray M., 2018a. Haploid ve Diploid Mısır Tohumlarının Görüntü İşleme Teknikleri ve Destek Vektör Makineleri Kullanılarak Sınıflandırılması. *26th Signal Processing and Communications Applications Conference (SIU)*, 1-4.

Altuntaş, Y., Kocamaz, A.F., Cömert, Z., Cengiz, R. and Esmeray, M., 2018b. Identification of haploid maize seeds using gray level co-occurrence matrix and machine learning techniques. *In 2018 International Conference on Artificial Intelligence and Data Processing (IDAP)*, 1-5.

Altuntaş, Y., Cömert, Z. and Kocamaz, A.F., 2019a. Identificaton of haploid and diploid maize seeds using convolutional neural networks and a transfer learning approach. *Computers and Electronics in Agriculture*, **163**, 104874.

Altuntaş, Y. ve Kocamaz, A.F., 2019b. Renk Momentleri ve Destek Vektör Makineleri Kullanarak Haploid Mısır Tohumlarının Tanımlanmasında Renk Uzaylarının Sınıflandırma Performansına Etkisinin Karşılaştırılması. *Fırat Üniversitesi Mühendislik Bilim Dergisi*, **31(2)**, 551–560.

Arani, M.N. and Zhang, X.P., 2014. Generalized Gaussian mixture Conditional Random Field model for image labeling. *2014 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, 1068-1072.

Arnab, A., Zheng, S., Jayasumana, S., Romera-Paredes, B., Larsson, M. and Kirillov, A., 2018. Conditional Random Fields Meet Deep Neural Networks for Semantic Segmentation: Combining Probabilistic Graphical Models with Deep Learning for Structured Prediction. *IEEE Signal Processing Magazine*, **35(1)**, 37-52.

Badrinarayanan, V., Kendall, A. and Cipolla, R., 2017. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI)*, **39(12)**, 2481–2495.

Chen, L.C., Papandreou, G., Kokkinos, I., Murphy, K. and Yuille, A.L., 2017. Deeplab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **40(4)**, 834-848.

Chu, X., Tao, Y., Wang, W., Yuan, Y. and Xi, M., 2014. Rapid detection method of moldy maize kernels based on color feature. *Advances in Mechanical Engineering*, **6**, 625090.

De La Fuente, G.N., Carstensen, J.M., Edberg, M.A. and Lübberstedt T., 2017. Discrimination of haploid and

- diploid maize kernels via multispectral imaging. *Plant Breed*, **136(1)**, 50–60.
- Deng, J., Dong W., Socher, R., Li, L.J., Li K. and Fei-Fei, L., 2009 ImageNet: A large-scale hierarchical image database. *2009 IEEE Conference on Computer Vision and Pattern Recognition*, 248-255.
- Garcia-Garcia, A., Orts-Escolano, S., Oprea, S., Villena-Martinez, V. and Garcia-Rodriguez, J., 2017. A Review on Deep Learning Techniques Applied to Semantic Segmentation. *arXiv preprint*, 1-23.
- He, K., Zhang, X., Ren, S. and Sun J., 2015. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. *IEEE International Conference on Computer Vision*, 1026-1034.
- He, X., Zemel, R.S. and Carreira-Perpinán, M.A., 2004. Multiscale Conditional Random Fields for Image Labeling. *2004 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Vol. 2, pp. II-II.
- Koller, D. and Nir, F., 2009. Probabilistic Graphical Models: Principles and Techniques, MIT press, 3-5.
- Krähenbühl, P. and Koltun, V., 2011. Efficient Inference in Fully Connected CRFs with Gaussian Edge Potentials. *24th International Conference on Neural Information Processing Systems (NIPS)*, 109-117.
- Krizhevsky, A., Sutskever and I., Hinton, G.E., 2012. ImageNet classification with deep convolutional neural networks. *25th International Conference on Neural Information Processing Systems (NIPS)*, 1097-1105.
- Long, J., Shelhamer, E. and Darrell T., 2015. Fully convolutional networks for semantic segmentation. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3431-3440.
- Ma, D., Cheng, H. and Zhang, W., 2013. Maize embryo image acquisition and variety identification based on OTSU and K-means clustering algorithm. *2013 International Conference on Information Science and Cloud Computing Companion*, 835-840.
- Minaee, S., Boykov, Y.Y., Porikli, F., Plaza, A.J., Kehtarnavaz, N. and Terzopoulos, D., 2021. Image Segmentation Using Deep Learning: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1-20. <https://doi.org/10.1109/TPAMI.2021.3059968>
- Murphy, K.P., 2012. Machine Learning: A Probabilistic Perspective, MIT press, 91-93.
- Nanda, D.K. and Chase, S.S., 1966. An Embryo Marker for Detecting Monoploids Of Maize (*Zea Mays* L.). *Crop Science*, **6(2)**, 213–215, 1966.
- Otsu, N., 1979. A threshold selection method from gray level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, **9(1)**, 62–66, 1979.
- Ronneberger, O., Fischer, P. and Brox, T., 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. *International Conference on Medical Image Computing & Computer Assisted Intervention (MICCAI)*, 234-241.
- Simonyan, K. and Zisserman, A., 2015. Very Deep Convolutional Networks for Large-Scale Image Recognition. *3rd International Conference on Learning Representations (ICLR)*.
- Sultana, F., Sufian, A. and Dutta, P., 2020. Evolution of Image Segmentation using Deep Convolutional Neural Network: A Survey. *Knowledge-Based Systems*, **201**, 106062.
- Toyoda, T. and Hasegawa, O., 2008. Random field model for integration of local information and global information. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **30(8)**, 1483-1489.
- Wang, X.Y., Liao, W.X., An, D. and Wei, Y.G., 2018. Maize Haploid Identification via LSTM-CNN and Hyperspectral Imaging Technology. *arXiv preprint*, 1-14 .
- Wang, X., Zhang, X.P., Clarke, I. and Yakubovich, Y., 2009. A new Gaussian mixture conditional random field model for indoor image labeling. *1st International Workshop on Interactive Multimedia for Consumer Electronics*, 51-56.