

**Atf İçin:** Bülbül, M. A. (2023). Kuru Fasulye Tohumlarının Çok Sınıflı Sınıflandırılması İçin Hibrit Bir Yaklaşım. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(1), 33-43.

**To Cite:** Bülbül, M. A. (2023). A Hybrid Approach for Multiclass Classification of Dry Bean Seeds. *Journal of the Institute of Science and Technology*, 13(1), 33-43.

## Kuru Fasulye Tohumlarının Çok Sınıflı Sınıflandırılması İçin Hibrit Bir Yaklaşım

Mehmet Akif BÜLBÜL<sup>1\*</sup>

### **Öne Çıkanlar:**

- Kuru fasulye tohumlarının sınıflandırılması

### **Anahtar Kelimeler:**

- Parçacık Sürü Optimizasyon Algoritması
- Yapay Sinir Ağları
- Çok sınıflı sınıflandırıcı

### **ÖZET:**

Sürdürülebilir tarımda, hangi toprak türünde hangi tür tohum yetiştirilmesi gerektiğine karar vermek büyük önem arz etmektedir. Dikilmesi hedeflenen kuru fasulye cinsinin belirlenmesi tecrübe, bilgi birikimi ve alanında uzman kişileri gerektiren maliyetli bir işlemdir. Kuru fasulyelerin doğru bir şekilde sınıflandırılabilmesi için geliştirilen karar destek sistemleri bu noktada büyük önem taşımaktadır. Bu çalışmada, kuru fasulye tohumlarının sınıflandırılmasında Yapay Sinir Ağı (YSA) ve Parçacık Sürü Optimizasyon (PSO) Algoritması kullanılarak hibrit bir model önerilmiştir. Önerilen hibrit model sayesinde YSA ağ yapısında bulunan hiper-parametreler optimize edilmiştir. Optimize işlemi sonucunda elde edilen hiper-parametreler ile kurulan YSA ağ yapısı kuru fasulyelerin çok sınıflı sınıflandırılmasında kullanılmıştır. Hibrit model ile elde edilen sonuçlar Karar Ağacı, K En Yakın Komşu Algoritması kullanılarak yapılan sınıflandırma sonuçları ile tartışmalı bir şekilde kıyaslanmıştır. Yapılan deneysel çalışmalar sonucunda hibrit model ile kuru fasulye tohumlarının sınıflandırılmasında %90 doğrulukla başarılı sonuçlar elde edilmiştir.

## A Hybrid Approach for Multiclass Classification of Dry Bean Seeds

### **Highlights:**

- Classification of dry bean seeds

### **Keywords:**

- Particle Swarm Optimization
- Artificial Neural Network
- Multiclass classification

### **ABSTRACT:**

In sustainable agriculture, it is of great importance to decide which type of seed should be grown in which soil type. Determining the dried bean type to be planted is a costly process that requires experience, knowledge and experts in the field. Decision support systems developed for the correct classification of dry beans are of great importance at this point. In this study, a hybrid model was proposed for the classification of dry bean seeds using Artificial Neural Network (ANN) and Particle Swarm Optimization (PSO) algorithm. Thanks to the proposed hybrid model, the hyper-parameters in the ANN network structure have been optimized. The ANN network structure established with the hyper parameters obtained as a result of the optimization process was used in the multi-class classification of dry beans. The results obtained with the hybrid model are controversially compared with the classification results using the Decision Tree, K Nearest Neighbor Algorithm. As a result of the experimental studies, successful results were obtained with 90% accuracy in the classification of dry bean seeds with the hybrid model.

<sup>1</sup> Mehmet Akif BÜLBÜL (Orcid ID: 0000-0003-4165-0512), Nevşehir Hacı Bektaş Veli Üniversitesi, Mühendislik - Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Nevşehir, Türkiye

\*Sorumlu Yazar/Corresponding Author: Mehmet Akif BÜLBÜL, e-mail: makifbulbul@nevsehir.edu.tr

## GİRİŞ

Kuru fasulye, toplamda 30.4 milyon ton üretim ve 34.5 milyon hektar alanda yetiştirilen en önemli baklagil türüdür (Soydaş ve ark., 2021). Düşük maliyetli mineral, karbonhidrat ve protein kaynağı olan bu baklagil gelişmekte olan ülkeler için büyük önem taşımaktadır (Baldin ve ark., 2021).

Tüm yetiştirme koşulları sağlanmış olsa bile, üretimde daha düşük kaliteli tohum kullanılması, üretilen baklagil miktarın düşmesine neden olmaktadır (Koklu ve Ozkan, 2020). Doğru toprak yapısında doğru kuru fasulye yetiştirilebilmesi için doğru tür tohumun belirlenmesi gerekmektedir. Bu belirleme işleminin doğru bir şekilde gerçekleşmesi bilgi birikimi ve tecrübe gerekmektedir (Kılıçarslan, 2022). Farklı uzmanların farklı tecrübeleri kuru fasulye tohumlarının sınıflandırılmasında farklılıklar meydana getirebilmektedir. Bu sebeple, kuru fasulye tohumlarının sınıflandırılmasında veri madenciliği yöntemleri ile karar destek sistemlerinin geliştirilmesi büyük önem taşımaktadır. Karar destek sistemleri sayesinde birçok alanda farklı problemlere farklı yöntemlerle çözümler üretilmiştir. (Bayat ve Isik, 2020; Işık ve ark., 2017; Işık ve ark., 2018; Pacal ve ark., 2022; Pacal ve Karaboga, 2021)

Yapay Sinir Ağı (YSA), makine öğrenme alanında sık kullanılan ve karar destek sistemlerinde sıkça tercih edilen yöntemlerden bir tanesidir (Bülbül ve ark., 2022; Bülbül ve Öztürk, 2022). Bu ve bunun gibi makine öğrenme yöntemleri zamandan, hesaplamalardan, maliyetlerden tasarruf sağlayarak hızlı bir şekilde insansı karar verme özellikleri üzerine yoğunlaşmış sistemlerdir. YSA sınıflandırma problemlerinde başarılı sonuçlar üretmektedir (Wahab ve ark., 2022).

Geliştirilen yeni nesil yöntemlerin üzerinde durduğu en önemli konulardan biri optimizasyondur. En iyi değerleri elde etme çabası içinde bulunan optimizasyon algoritmalarından bir tanesi de Parçacık Sürü Optimizasyon (PSO) algoritmasıdır. PSO sınıflandırma problemlerinde başarılı sonuçlar üretmektedir (Alhaj ve ark., 2022; Wahab ve ark., 2022).

Literatürde tohum sınıflandırılması ile ilgili yapılan çalışmalarda, Granitto ve arkadaşları (Granitto ve ark., 2002), tohumların hızlı bir şekilde tanımlanması ve sınıflandırılması için Naive Bayes ve YSA makine öğrenme yöntemlerini kullanmışlardır. 12 tohum karakteristiği belirlenen çalışmada, YSA ile %99.5 doğruluk oranında başarılı sonuçlar elde edilmiştir. Eryiğit ve Tuğrul (Eryiğit ve Tuğrul, 2021), çim tohumlarının sınıflandırılmasında 15 farklı Evrişimli Sinir Ağı (CNN) mimarisi kullanmışlardır. Yapılan çalışmada, DenseNet201,  $256 \times 256$  piksel görüntü seti için % 99.42 test doğruluğu ile en iyi CNN yapısı ortaya konulmuştur. Loddo ve arkadaşları (Loddo ve ark., 2021), bitki tohumlarının sınıflandırılmasında yeni bir CNN önerdi. Önerilen CNN mimarisi iki farklı tohum kümesi için uygulandı. SeedNet adlı yeni CNN mimarisi ile yapılan sınıflandırma işleminde iki farklı tohum grubunda sırasıyla %95.65 ve %97.47 doğruluk oranlarında başarı elde edildi. Qian ve arkadaşları (Qian ve ark., 2021), pirinç çeşitlerinin hızlı ve doğru bir şekilde tanımlanmasını sağlamak için pirinç tohumlarının yüzeyinin üç boyutlu nokta bulutu verilerini derin bir öğrenme ağı ile birleştirerek bir pirinç çeşidi sınıflandırma yöntemi önermiştir. Önerilen PointNet modeli ile 8 farklı pirinç tohumu çeşidi sınıflandırılmış ve %89.4 doğruluk oranında başarı elde edilmiştir. Kılıç ve arkadaşları (Kılıç ve ark., 2007), bilgisayar görüşü sistemi ve yapay sinir ağları kullanarak fasulyeler için bir sınıflandırma sistemi önermişlerdir. Önerilen sistemde, fasulyeleri yoğunluk dağılımlarına göre tanımlamak için moment analizi yapılmıştır. Aynı zamanda, RGB renk formatındaki her kanal için ortalama, varyans, çarpıklık ve basıklık değerleri belirlenen çalışmada %90.6 genel doğruluk oranında başarılı sınıflandırma yapılmıştır. Espinosa-Pérez ve arkadaşları (Espinosa-Pérez ve ark., 2015), tohum özellikleri kullanılarak temel bileşenlerin ve Öklid mesafelerine dayalı hiyerarşik kümelemenin tanımlayıcı ve sınıflandırıcı bir analizi yapmışlardır. Temel bileşenler analizine göre, tohumların

uzunluğu, genişliği, ağırlığı ve hacmi ile özgül ağırlık, toplam varyasyona göre başlıca ayırt edici özelliğin kullanıldığı çalışma da başarılı sonuçlar elde etmişlerdir. Köklü ve Özkan ( Köklü ve Özkan, 2020), kuru fasulye tohumlarının sınıflandırılmasında Çok Katmanlı Algılayıcı (MLP), Destek Vektör Makinesi (SVM), k-En Yakın Komşular (kNN) ve Karar Ağacı (DT) sınıflandırma modellerini kullanmışlardır. Yapılan çalışmada, SVM sınıflandırma modeli ile başarılı sonuçlar elde etmişlerdir.

Literatürde tohum sınıflandırılması üzerine yapılan çalışmaların çoğunda kullanılan makine öğrenme teknikleri parametreleri deneysel gözlemlerle belirlenmektedir. Makine öğrenme tekniklerinde kullanılan mimarilerde bulunan parametreler kurulan model ve tekniklerin başarısını doğrudan etkilemektedir (Bülbül ve ark., 2022; Bülbül ve Öztürk 2022). Makine öğrenme tekniklerinde bulunan hiper-parametrelerin kullanılan veriye göre şekillenebilmesi için optimizasyon algoritmaları kullanılması daha başarılı sonuçlar elde etmek adına önemlidir.


Bu çalışmada, kuru fasulye tanelerinin çok sınıflı sınıflandırılmasında PSO algoritması ve YSA ile hibrit bir model önerilmiştir. Önerilen model ile birlikte YSA ağ yapısında kullanılan hiper-parametreler optimize edilmiştir. Önerilen model ile elde edilen en iyi ağ performansı ile Karar Ağacı (KA) ve K En Yakın Komşu Algoritması (KEYKA) performansları tartışmalı bir şekilde kıyaslanmıştır.

Makalenin geri kalanında, bir sonraki bölümde çalışmada kullanılan yöntemlere yer verilmiştir. Daha sonra, çalışmada kullanılan veri seti ile deneysel çalışmalara yer verilmiştir. Son bölümde, çalışma sonuçları ile ileriki çalışmalara yer verilmiştir.

## MATERYAL VE METOT

### Karar Ağacı

KA, literatürde sınıflandırma problemlerinde kullanılan makine öğrenme algoritmasıdır (Dinesh 2021; Quang-Huy ve ark., 2021) . Karar ağaçları kural tabanlıdır ve çok derin olmadıklarında yorumlanması oldukça kolaydır (Blanquero ve ark., 2021). Basit bir karar ağacı yapısı Şekil 1'de gösterilmektedir.




Şekil 1. Basit bir KA yapısı

Şekil 1'de sunulan ağaç yapısında dallar, yapraklar ve karar düğümleri bulunmaktadır. Veriler üzerinde gözlemler kök hücrenden başlayarak dallara doğru ilerlemektedir. Bu ilerleme yapraklara kadar ilerler ve sınıflandırma işlemi gerçekleştirilir.

### K En Yakın Komşu Algoritması

KEYKA, en basit makine öğrenme algoritmalarından biridir. Basit bir KEYKA yapısı Şekil 2'de gösterilmektedir.

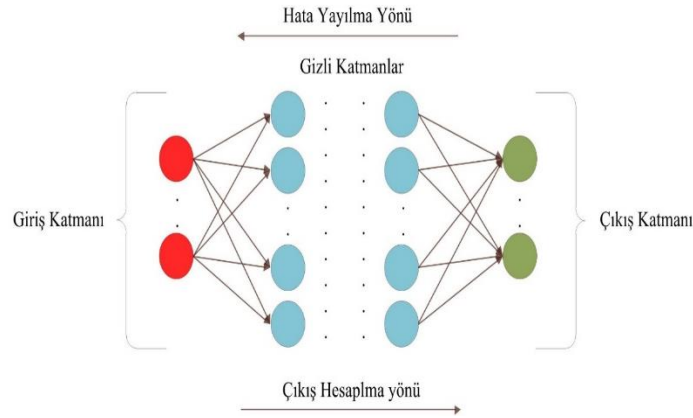


Şekil 2. Basit bir KEYKA yapısı

Şekil 2’de, sınıflandırılmamış örneğin sınıflandırma işlemi gerçekleştirilirken en yakın sınıflandırılmış değerlere olan Öklid uzaklığı dikkate alınmaktadır. (Cansız ve ark., 2022).

### Yapay Sinir Ağları

Çalışma tekniği olarak biyolojik sinir sistemini örnek alan YSA nöronların belirli bir hiyerarşi içerisinde dizilmesiyle oluşmaktadır (Yavuz ve ark., 2022). Basit bir ileri beslemeli geri yayımlı bir YSA yapısı Şekil 3’de sunulmuştur.



Şekil 3. Basit bir YSA yapısı

Şekil 3’de sunulan ileri beslemeli ve geri yayımlı YSA yapısında giriş katmanında ağ yapısına verilecek olan giriş bilgileri bulunmaktadır. Bu giriş bilgileri çıkış katmanına doğru ilerlemektedir (Işık ve ark., 2020). Her bir nöron hücreğine gelen bilgiler öncelikle ağırlıkları ile çarpılarak toplama fonksiyonuna gönderilmektedir. Toplama fonksiyonundan çıkan bilgiler üzerine her bir nöron hücreğinde bulunan *bias* değeri eklenmektedir. Böylelikle nöron hücreсі için net girdi değeri hesaplanmış olup bu değer hücrede kullanılan aktivasyon fonksiyonundan geçirilmektedir. Her bir iterasyon sonunda hesaplanarak elde edilen hata geri yayılım ile nöron hücrelerine dağıtılmaktadır. Böylelikle daha iyi bir tahminleme işlemi gerçekleştirilmektedir.

### Parçacık Sürü Optimizasyon Algoritması

PSO, Reeves tarafından bir çalışmada parçacık sistemi kullanılmasıyla ortaya çıkmıştır (Reeves, 1983). 1995 yılında Kennedy ve Eberhart tarafından (Eberhart ve Kennedy, 1995) algoritma olarak ortaya konulan PSO, popülasyon temelli bir algoritmadır olup sosyal davranış ilkelerini kullanmaktadır (de Gusmão ve de Carvalho, 2019). PSO’ nun adımları şu şekildedir (Bülbül ve ark., 2021).

1. Parametre ve eşik değerlerini tanımlayın; bir başlangıç popülasyonu oluşturun; hız değerlerini oluşturunuz.
2. *pbest* ve *gbest* değerlerini belirleyiniz.

3. Yeni hız değerlerini hesaplayın ve parçacıkların yerlerini değiştiriniz.
4.  $pbest$  ve  $gbest$  değerlerini güncelleyiniz.
5. Yineleme sayısı kadar 3. adıma geri dönünüz.

PSO bünyesinde parçacıklardan oluşan bir popülasyon barındırmaktadır. Her bir parçacık optimize edilmek istenen parametreler için bir çözümü temsil etmektedir. Bu parçacıklar etrafında bulunan diğer parçacıkların tecrübelerinden faydalanarak hareket etmektedir (Bülbül ve ark., 2021). Her bir iterasyonda parçacıkların konumları belirlenen uygunluk fonksiyonuna göre ölçülmektedir. Uygunluk fonksiyonuna göre belirleme işlemi ile parçacıkların en iyi konumu ( $pbest$ ) ve popülasyon içerisindeki en iyi konum ( $gbest$ ) belirlenmektedir. Her bir iterasyondaki parçacıkların hızı Eşitlik 1'e göre hesaplanmaktadır (Bülbül ve ark., 2021).

$$V_{ab}(t+1) = WV_{ab}(t) + C_1 rand(1)(pbest_{ab}(t) - X_{ab}(t)) + C_2 rand(1)(gbest_{ab}(t) - X_{ab}(t)) \quad (1)$$

Eşitlik 1'de,  $W$  değeri momentum katsayısını göstermektedir.  $V_{ab}(t+1)$  değeri  $t$  iterasyonunda a. parçacığın b. boyutundaki hızını göstermektedir.  $pbest_{ab}(t)$  değeri  $t$  iterasyonunda a. parçacığın b. boyuttaki en iyi konumunu göstermektedir.  $X_{ab}(t)$  değeri  $t$  iterasyonunda a. parçacığın b. boyutundaki konumunu göstermektedir.  $gbest(t)$  değeri  $t$  iterasyonunda b. boyuttaki en iyi konumu göstermektedir.  $C_1$  ve  $C_2$  sabiti en iyi çözümün bulunmasında kullanılan öğrenme parametreleridir.  $C_1$  sabiti bilişsel öğrenmeyi sağlarken  $C_2$  sabiti sosyal öğrenme becerisi sağlamaktadır (Bülbül ve ark., 2021).

Her bir iterasyonda parçacıkların konumları Eşitlik 2'ye göre sağlanmaktadır.

$$X_k(t+1) = X_k(t) + V_k(t+1) \quad (2)$$

Popülasyon içerisinde bulunan her bir parçacığın ilk hızı rastgele olarak belirlenmektedir.

## BULGULAR VE TARTIŞMA

### Veri Seti

Çalışmada, Köklü ve Özkan tarafından 2020 yılında elde edilen 7 farklı kuru fasulye sınıfı için elde edilmiş 16 özniteliğe sahip 13 611 adet veri kullanılmıştır (Koklu ve Ozkan, 2020). Çizelge 1'de, çalışmadaki 13 611 kuru fasulye veri setindeki sınıflandırmaları, miktar dağılımları ve ortalama ağırlıkları gösterilmektedir (Koklu ve Ozkan, 2020).

**Çizelge 1.** Kuru fasulyelerin numune dağılımı

No	İsim	Adet	Tohum Ağırlığı (tohum başına ortalama gram)
1	Seker	2 027	0.49
2	Barbunya	1 322	0.7
3	Bombay	522	1.92
4	Cali	1 630	0.61
5	Horoz	1 928	0.52
6	Sira	2 636	0.38
7	Dermason	3 546	0.28
<b>Toplam</b>		<b>13 611</b>	<b>0.71</b>

Kuru fasulyeye veri kümesine ait özniteliklerin açıklamaları ve tanımlayıcı istatistiksel sonuçları Çizelge 2'de gösterilmektedir (Köklü ve Özkan, 2020).

**Çizelge 2.** Kuru fasulye çeşitlerinin özniteliklerinin piksel olarak istatistiksel dağılımı

Öznitelikler	Açıklama	Ortalama	Std. Sapma	Min.	Mak.
Alan (A)	Bir fasulye bölgesinin alanı ve sınırları içindeki piksel sayısı.	53 048.285	29 324.096	20 420.000	25 4616.000
Çevre (P)	Fasulye çevresi, bordürünün uzunluğu olarak tanımlanır.	855.283	214.290	524.736	1 985.370
Ana Eksen Uzunluğu (L)	Bir çekirdekten çizilebilecek en uzun çizginin uçları arasındaki mesafe	20.142	85.694	183.601	738.860
Küçük Eksen Uzunluğu (I)	Çekirdekten ana eksene dik dururken çizilebilecek en uzun çizgi.	202.271	44.970	122.513	460.198
En Boy Oranı (K)	L ve I arasındaki ilişkiyi tanımlar.	1.583	0.247	1.025	2.430

## Çizelge 2'nin Devamı

Eksantriklik (Ec)	Bölge ile aynı momentlere sahip elipsin eksantrikliği.	0.751	0.092	0.219	0.911
Dışbükey Alan (C)	Bir fasulye tohumunun alanını içerebilen en küçük dışbükey çokgendeki piksel sayısı.	53 768.200	29 774.916	20 684.000	26 3261.000
Eşdeğer Çap (Ed)	Fasulye tohum alanı ile aynı alana sahip bir dairenin çapı.	253.064	59.177	161.244	569.374
Kapsam (Örn)	Sınırlayıcı kutudaki piksellerin çekirdek alanına oranı.	0.750	0.049	0.555	0.866
Katılık (S)	Dışbükeylik olarak da bilinir. Dışbükey kabuktaki piksellerin fasulyede bulunanlara oranı.	0.987	0.005	0.919	0.995
Yuvarlaklık (R)	Şu formülle hesaplanır: $(4\pi A)/(P^2)$	0.873	0.060	0.490	0.991
Kompaktlık (CO)	Bir nesnenin yuvarlaklığı ölçer: $Ed/L$	0.800	0.062	0.641	0.987
Şekil Faktörü 1		0.007	0.001	0.003	0.010
Şekil Faktörü 2		0.002	0.001	0.001	0.004
Şekil Faktörü 3		0.644	0.099	0.410	0.975
Şekil Faktörü 4		0.995	0.004	0.948	1.000

## Değerlendirme Metrikleri

Bu çalışmada, her bir sınıflandırıcı için doğruluk, duyarlık ve kesinlik değerleri hesaplanmış ve karşılaştırılmıştır. Bu değerlerin hesaplanabilmesi için öncelikle her bir sınıflandırıcı için karmaşıklık matrisi oluşturulmalıdır (Pacal ve ark., 2020). Çok sınıflı sınıflandırmada örnek bir karmaşıklık matrisi Şekil 4'de gösterilmektedir.

		Tahmin Edilen		
		DN	YP	DN
Gerçek	YN	YN	DP	YN
	DN	DN	YP	DN

Şekil 4. Çok boyutlu karışıklık matrisi

Şekil 4'de DP gerçek pozitif, YP yanlış pozitif, DN gerçek negatif ve YN ise yanlış negatif ifade etmektedir (Bayat ve Işık, 2022). Bu değerlere göre doğruluk, duyarlık ve kesinlik değerlerin hesaplanması Eşitlik 3-7'de gösterilmektedir (Krüger, 2016).

$$\text{Doğruluk} = \frac{\sum_{k=0}^S x_{kk}}{\sum_{k=0}^S \sum_{l=0}^S x_{kl}} \quad (3)$$

$$\text{Duyarlılık}_{sınıf} = \frac{TP_{sınıf}}{TP_{sınıf} + FN_{sınıf}} \quad (4)$$

$$\text{Duyarlılık} = \frac{\sum_{k=0}^S \text{Duyarlılık}_k * (TP_k + FN_k)}{\sum_{k=0}^S \sum_{l=0}^S x_{kl}} \quad (5)$$

$$\text{Kesinlik}_{sınıf} = \frac{TP_{sınıf}}{TP_{sınıf} + FP_{sınıf}} \quad (6)$$

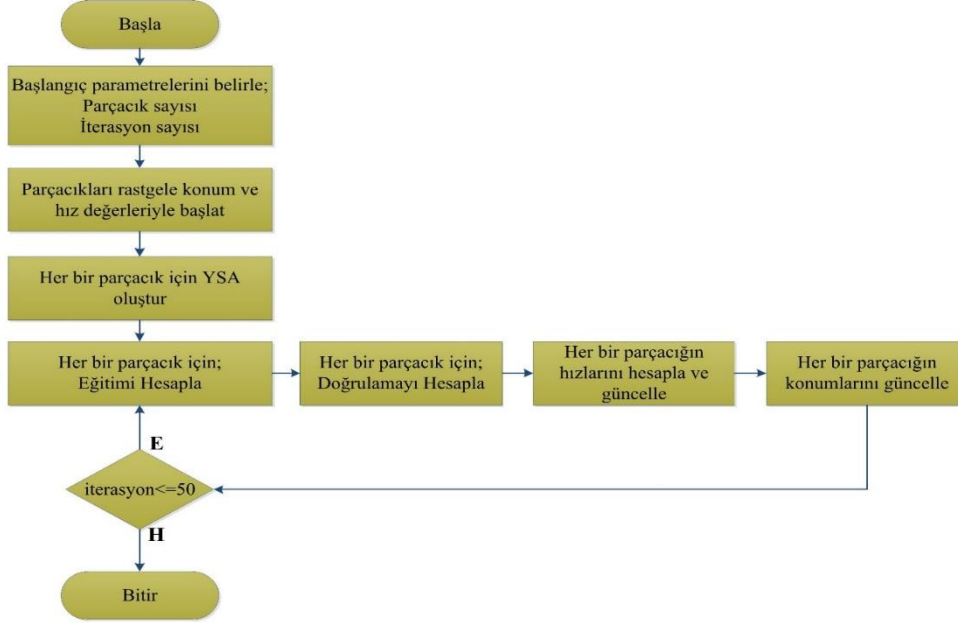
$$\text{Kesinlik} = \frac{\sum_{k=0}^S \text{Kesinlik}_k * (TP_k + FN_k)}{\sum_{k=0}^S \sum_{l=0}^S x_{kl}} \quad (7)$$



Eşitlik 3-7’de, her bir S değeri sınıf sayısını, x değeri karmaşıklık matrisi üzerindeki konumu, k ve l değerleri konumların indislerini ifade etmektedir.

### Hibrit Model

Çalışmanın bu bölümünde, kuru fasulyelerin sınıflandırılması için PSO ve YSA ile hibrit bir yapı oluşturulmuştur. Oluşturulan hibrit yapı sayesinde en uygun değerde ağ yapısı ve ağ parametreleri belirlenmeye çalışılacaktır. Oluşturulan hibrit yapının akış şeması Şekil 5’de gösterilmektedir.



Şekil 5. PSO-YSA hibrit model

Şekil 5’de sunulan PSO-YSA hibrit modelinde ilk adım olarak PSO için başlangıç parametreleri Çizelge 3’de sunulduğu gibi belirlenmiştir. Hibrit model MATLAB platformunda oluşturulmuştur.

Çizelge 3. Hibrit model PSO parametreleri

PSO Parametreleri	Değerler
Parçacık Sayısı	20
Çözüm Uzayı	5
İterasyon Sayısı	100

Belirlenen başlangıç parametrelerinin ardından Çizelge 3’de gösterildiği gibi 20 adet parçacık rastgele olarak oluşturulmuştur. Her bir parçacığın içerisinde gizli katman sayısı (GKS), gizli katmalardaki nöron sayıları (NS), katmanlarda kullanılan aktivasyon fonksiyonları (AkF), ve her bir parçacığın oluşturacağı YSA ağ yapısı için kullanılacak öğrenme fonksiyonu (ÖF) bulunmaktadır. Parçacıklar oluşturulurken GKS ve NS maksimum sınır değeri 9 olarak alınmıştır. Her bir gizli katmanda bulunan AkF değerleri *hardlim*, *logsig*, *purelin*, *tansig*, *hardlims* ve *radbas* fonksiyonları arasından rastgele olarak belirlenmiştir. Her bir parçacığın oluşturmuş olduğu YSA ağ yapısı için öğrenme fonksiyonu ise *trainbfg*, *trainr*, *traincgb*, *trainc*, *trainbr*, *trainb*, *traincgf*, *trainscg*, *traincgp*, *trainrp*, *traingd*, *traingda*, *traingdm*, *trainoss*, *traingdx* arasından rastgele olarak belirlenmiştir.

Sunulan hibrit model içerisinde her bir parçacığın *pbest* ve *gbest* değerlerinin elde edilebilmesi için kullanılan uygunluk fonksiyonu Eşitlik 8’de gösterilmiştir

$$f(U_i) = \text{Max}(\text{Doğruluk}, \text{Kesinlik}, \text{Duyarlılık}) \quad (8)$$

Eşitlik 8’de sunulan uygunluk fonksiyonunda  $f(U_i)$  i. Parçacığın uygunluk değerini temsil etmektedir. Her bir parçacığın oluşturmuş olduğu YSA ağ yapısı ile test verileri üzerinden

sınıflandırma işlemi gerçekleştirilmektedir. Gerçekleştirilen sınıflandırma işlemi sonrası doğruluk, kesinlik ve duyarlılık hesaplanmaktadır. Oluşturulan hibrit model içerisinde *pbest* ve *gbest* değerleri bu değerlere göre belirlenmektedir.

Hibrit modelin her bir iterasyonunda parçacıkların hızları ve konumları Eşitlik 1 ve Eşitlik 2’de gösterildiği gibi güncellenmektedir. Güncelleme işlemlerinde değerler yuvarlatılarak sınır değerleri kontrol edilmektedir.

Sunulan hibrit model Çizelge 3’de gösterildiği gibi 100 iterasyon boyunca koşturulmuştur. 100 iterasyon sonucunda elde edilen *gbest* değerine göre belirlenen en iyi konumdaki parçacığın yapısında bulunan YSA ağ parametreleri Çizelge 4’de sunulmuştur.

**Çizelge 4.** En iyi uygunluk değerine sahip parçacık yapısı

YSA Ağ Parametreleri	Değerler
GKS	3
Gizli Katmanlardaki Nöron Sayıları	4 – 4 - 6
Gizli Katmanlarda Kullanılan AKF değerler	tansig – radbas – radbas - purelin
Çıkış Katmanında Kullanılan AKF değeri	1
ÖF	purelin

### Deneysel Sonuçlar ve Tartışma

Kuru fasulyelerin çok sınıflı sınıflandırılması için gerçekleştirilen deneysel çalışmalarda KA, EYKA ve sunulan hibrit model uygulanmıştır. Her bir modelin performanslarının hesaplanabilmesi için modeller için karmaşıklık matrisleri oluşturulmuştur. Oluşturulan karmaşıklık matrisleri Çizelge 5-7’de sunulmuştur.

**Çizelge 5.** KA için karmaşıklık matrisi

Gerçek Değerler	Tahmin Edilen Değerler						
	Şeker	Barbunya	Bombay	Cali	Horoz	Sira	Dermason
Şeker	<b>483</b>	0	0	4	0	144	45
Barbunya	0	<b>0</b>	0	419	3	18	1
Bombay	0	0	<b>0</b>	173	1	0	0
Cali	0	0	0	<b>498</b>	41	4	0
Horoz	0	0	0	32	<b>574</b>	23	14
Sira	2	0	0	9	3	<b>679</b>	185
Dermason	33	0	0	1	0	0	<b>694</b>

**Çizelge 6.** EYKA için karmaşıklık matrisi

Gerçek Değerler	Tahmin Edilen Değerler						
	Şeker	Barbunya	Bombay	Cali	Horoz	Sira	Dermason
Şeker	<b>634</b>	4	0	0	0	17	21
Barbunya	3	<b>395</b>	0	32	4	5	2
Bombay	0	0	<b>174</b>	0	0	0	0
Cali	1	29	0	<b>494</b>	15	4	0
Horoz	0	2	0	9	<b>616</b>	10	6
Sira	16	8	0	4	57	<b>628</b>	165
Dermason	2	0	0	0	1	1	<b>724</b>

**Çizelge 7.** PSO-YSA için karmaşıklık matrisi

Gerçek Değerler	Tahmin Edilen Değerler						
	Şeker	Barbunya	Bombay	Cali	Horoz	Sira	Dermason
Şeker	<b>568</b>	58	13	11	8	10	8
Barbunya	4	<b>388</b>	23	20	3	3	0
Bombay	0	0	<b>173</b>	1	0	0	0
Cali	0	11	11	<b>499</b>	20	2	0
Horoz	0	0	1	14	<b>612</b>	11	5
Sira	0	6	7	5	56	<b>713</b>	91
Dermason	2	0	0	0	1	2	<b>723</b>



Çizelge 5-7’de her bir model ve her bir sınıf için oluşturulan karmaşıklık matrislerine göre her bir modelin performansı hesaplanmış olup Çizelge 8’de sunulmuştur.

**Çizelge 8.** Hibrit model ile klasik veri madenciliği yöntemlerinin değerlendirilmesi

Modeller	Doğruluk	Duyarlılık	Kesinlik
KA	0.71	0.71	0.70
EYKA	0.89	<b>0.80</b>	0.80
Hibrit Model	<b>0.90</b>	<b>0.80</b>	<b>0.83</b>

Çizelge 8’de sunulan performans değerlerine göre önerilen hibrit model ile kuru fasulye sınıflandırılmasında daha başarılı sonuçlar elde edilmiştir.

## SONUÇ

Besin değeri olarak insan yaşamında önemli bir yeri olan kuru fasulyenin, farklı toprak türlerinde daha verimli bir hasat sağlanabilmesi ancak toprak türüne göre doğru türde tohum ekimi yapılması ile mümkün olmaktadır. Bu amaç doğrultusunda, ekilen tohumların türleri ve bu tohumların doğru bir şekilde sınıflandırılması gerekmektedir. Kuru fasulyelerin doğru bir şekilde sınıflandırılması geleneksel yöntemlerle hem zahmetli hem de maliyetli bir işlemdir. Konusunda uzman kişiler olmadan bu sınıflandırmanın yapılabilmesi neredeyse imkânsızdır. Bu sebeple, kuru fasulyelerin çok sınıflı sınıflandırılabilmesinde karar destek sistemlerinin geliştirilmesi çok büyük önem arz etmektedir. Bunun yanında sürdürülebilir tarımın devam ettirilebilmesi doğru tür toprakta doğru tür kuru fasulye yetiştirilmesi ile elde edilebilir. Tüm bunların ışığında, kuru fasulye tanelerinin doğru bir şekilde sınıflandırılabilmesi amacıyla YSA ve PSO tabanlı hibrit bir model önerilmiştir. Önerilen hibrit model ile birlikte kuru fasulyelerin doğru bir şekilde sınıflandırılabilmesi için gerekli YSA ağ yapısı ve bu ağ yapısında bulunan hiper-parametreler PSO kullanılarak optimize edilmiştir. Sunulan model ile elde edilen YSA ağ yapısı, çalışmada kullanılan diğer makine öğrenme yöntemlerinden daha başarılı sonuçlar elde etmiştir. Gelecekte, bu ağ parametreleri kullanılarak mobil bir uygulama rahatlıkla geliştirilebilir.

## Çıkar Çatışması

Yazar herhangi bir çıkar çatışması olmadığını beyan etmiştir.

## KAYNAKLAR

- Alhaj, Y. A., Dahou, A., Al-qaness, M. A., Abualigah, L., Abbasi, A. A., Almaweri, N. A. O., ... & Damaševičius, R. (2022). A novel text classification technique using improved particle swarm optimization: A case study of Arabic language. *Future Internet*, 14(7), 194.
- Baldin, R. C., Kavalco, S. A. F., Woyann, L. G., Rodrigues Junior, A. A., Gobatto, D. R., Silva, G. R. D., ... & Finatto, T. (2021). Yield stability of common bean genotypes in the state of Santa Catarina, Brazil. *Pesquisa Agropecuária Brasileira*, 56.
- Bayat, S., & Işık, G. (2020, October). Identification of Aras Birds with convolutional neural networks. In *2020 4th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 1-5). IEEE
- Bayat, S., & Işık, G. (2022). Aras Kuş türlerinin ses özellikleri bakımından derin öğrenme yöntemleriyle tanınması. *Journal of the Institute of Science and Technology*, 12(3), 1250-1263.
- Blanquero, R., Carrizosa, E., Molero-Río, C., & Morales, D. R. (2021). Optimal randomized classification trees. *Computers & Operations Research*, 132, 105281.
- Bülbül, M. A., Harirchian, E., Işık, M. F., Aghakouchaki Hosseini, S. E., & Işık, E. (2022). A hybrid

- ANN-GA model for an automated rapid vulnerability assessment of existing RC buildings. *Applied Sciences*, 12(10), 5138.
- Bülbül, M. A., & Öztürk, C. (2022). Optimization, modeling and implementation of plant water consumption control using genetic algorithm and artificial neural network in a hybrid structure. *Arabian Journal for Science and Engineering*, 47(2), 2329-2343.
- Bülbül, M. A., Öztürk, C., & Işık, M. F. (2022). Optimization of climatic conditions affecting determination of the amount of water needed by plants in relation to their life cycle with particle swarm optimization, and determining the optimum irrigation schedule. *The Computer Journal*, 65(10), 2654-2663.
- Dinesh, T., & Rajendran, T. (2021). Higher classification of fake political news using decision tree algorithm over naive Bayes algorithm. *Revista Geintec-Gestao Inovacao E Tecnologias*, 11(2), 1084-1096.
- Kennedy, J., & Eberhart, R. (1995, November). Particle swarm optimization. In *Proceedings of ICNN'95-international conference on neural networks* (Vol. 4, pp. 1942-1948). IEEE.
- Eryigit, R., & Tugrul, B. (2021). Performance of various deep-learning networks in the seed classification problem. *Symmetry*, 13(10), 1892.
- Espinosa-Pérez, E. N., Ramírez-Vallejo, P., Crosby-Galván, M. M., Estrada-Gómez, J. A., Lucas-Florentino, B., & Chávez-Servia, J. L. (2015). Clasificación de poblaciones nativas de frijol común del centro-sur de México por morfología de semilla. *Revista fitotecnica mexicana*, 38(1), 29-38.
- Granitto, P. M., Navone, H. D., Verdes, P. F., & Ceccatto, H. A. (2002). Weed seeds identification by machine vision. *Computers and Electronics in agriculture*, 33(2), 91-103.
- de Gusmão, R. P., & de Carvalho, F. D. A. (2019). Clustering of multi-view relational data based on particle swarm optimization. *Expert Systems with Applications*, 123, 34-53.
- Işık, E., Işık, M. F., & Bülbül, M. A. (2017). Web based evaluation of earthquake damages for reinforced concrete buildings. *Earthquakes and Structures*, 13(4), 423-432.
- Işık, G., Ekici, S., & Şahin, G. (2020). A neural network model for UAV propulsion system. *Aircraft Engineering and Aerospace Technology*, 92(8), 1177-1184.
- Işık, M. F., Işık, E., & Bülbül, M. A. (2018). Application of iOS/Android based assessment and monitoring system for building inventory under seismic impact. *Gradjevinar*, 70 (12), 1043-1056.
- Kılıçarslan, S. (2022). Kurum Üzüm Tanelerinin Sınıflandırılması İçin Hibrit Bir Yaklaşım. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 4(1), 62-71.
- Kılıç, K., Boyacı, I. H., Köksel, H., & Küsmenoğlu, İ. (2007). A classification system for beans using computer vision system and artificial neural networks. *Journal of Food Engineering*, 78(3), 897-904.
- Koklu, M., & Ozkan, I. A. (2020). Multiclass classification of dry beans using computer vision and machine learning techniques. *Computers and Electronics in Agriculture*, 174, 105507.
- Krüger, F. (2016). *Activity, context, and plan recognition with computational causal behaviour models* (Doctoral dissertation, University).
- Loddo, A., Loddo, M., & Di Ruberto, C. (2021). A novel deep learning based approach for seed image classification and retrieval. *Computers and Electronics in Agriculture*, 187, 106269.
- Cansız, Ö. F., Çelik, R., & Genç, O. (2022). Türkiye demiryollarında taşınan yük miktarının yapay sinir ağları yöntemi ile tahmini. *International Korkut Ata Scientific Researches Conference*, 28-30 Haziran 2022, Osmaniye.

- Pacal, I., Karaboga, D., Basturk, A., Akay, B., & Nalbantoglu, U. (2020). A comprehensive review of deep learning in colon cancer. *Computers in Biology and Medicine*, *126*, 104003..
- Pacal, I., & Karaboga, D. (2021). A robust real-time deep learning based automatic polyp detection system. *Computers in Biology and Medicine*, *134*, 104519.
- Pacal, I., Karaman, A., Karaboga, D., Akay, B., Basturk, A., Nalbantoglu, U., & Coskun, S. (2022). An efficient real-time colonic polyp detection with YOLO algorithms trained by using negative samples and large datasets. *Computers in biology and medicine*, *141*, 105031.
- Qian, Y., Xu, Q., Yang, Y., Lu, H., Li, H., Feng, X., & Yin, W. (2021). Classification of rice seed variety using point cloud data combined with deep learning. *International Journal of Agricultural and Biological Engineering*, *14*(5), 206-212.
- Quang-Huy, T., Doan, P. T., Yen, N. T. H., & Tran, D. T. (2021). Shear wave imaging and classification using extended Kalman filter and decision tree algorithm. *Math. Biosci. Eng*, *18*, 7631-7647.
- Reeves, W. T. (1983). Particle systems—a technique for modeling a class of fuzzy objects. *ACM Transactions On Graphics (TOG)*, *2*(2), 91-108.
- Soydaş, V., Aydın, M., Elkoca, E., & İlhan, E. (2019). Gümüşhane ili yerel fasulye genotiplerinin morfolojik ve tarımsal özellikler yönünden karakterizasyonu üzerine bir ön çalışma. *Anadolu Ege Tarımsal Araştırma Enstitüsü Dergisi*, *31*(2), 143-160.
- Wahab, S. N., Sulaiman, N. S., Aziz, N. A., Zakaria, N. L., & Aziz, A. A. A. (2022). An Intrusion Detection System Based on Hybrid of Particle Swarm Optimization (PSO) and Magnetic Optimization Algorithm (MOA). In *Proceedings of International Conference on Emerging Technologies and Intelligent Systems: ICETIS 2021 Volume 2* (pp. 579-588). Springer International Publishing.
- Yavuz, Ö. Ç., Karaman, E., & Yeşilyaprak, C. (2022). Makine öğrenmesi algoritmalarıyla astronomik gözlem kalitesi tahminine yönelik karar destek sistemi geliştirilmesi ve uygulanması. *Trends in Business and Economics*, *36*(3), 289-303.