



**Makale / Research Paper**

**Tarımda Kaliteli Tohum Üretimi için Kuru Fasulye Türlerinin Yapay Zekâ Tabanlı Sınıflandırılması**

Uğur KADIOĞLU<sup>1</sup>, Muhammed Kürşad UÇAR<sup>2</sup>, Saadettin YILDIRIM<sup>3</sup>

<sup>1</sup>Aydın Adnan Menderes Üniversitesi, Fen Bilimleri Enstitüsü, Tarım Makinaları Bölümü. Aydın/TÜRKİYE

<sup>2</sup>Sakarya Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği. Sakarya/TÜRKİYE

<sup>3</sup>Aydın Adnan Menderes Üniversitesi, Ziraat Fakültesi, Tarım Makinaları Bölümü. Aydın/TÜRKİYE  
ugrkadioglu@gmail.com

**Received/Geliş:** 25.06.2022

**Accepted/Kabul:** 07.11.2022

**Öz:** 2020 yılında Dünya genelinde 27,5 milyon ton, Türkiye de 279,5 bin ton kuru fasulye üretilmiştir. Kuru fasulye geniş bir çeşitliliğe sahiptir. Bir çeşidi soğuk iklim koşullarında verimli olabilirken, bir çeşidi daha ılıman iklim koşullarında verimli olabilmektedir. Günümüzde kuru fasulye tohumları arasında farklı çeşitlere ait kuru fasulye tohumları karışabilmektedir. Bu durum kuru fasulye verimini olumsuz etkilemektedir. Bitkisel üretimde tohum kalitesi önemlidir. Bu nedenle tohum sınıflandırılması sürdürülebilir tarım ve verimlilik için önemlidir. Kuru fasulye sınıflandırılması günümüzde elekler yardımı ile yapılmaktadır. Elek ile sınıflandırma yönteminin dezavantajları fasulyenin çeşidini, kırık ve bozuk fasulyeleri tespit edememektir. Hassas tohum seçimi yapılabilmesi için yeni teknolojilere ihtiyaç duyulmaktadır. Bu çalışmanın amacı kuru fasulyenin sınıflandırılması için yapay zekâ tabanlı bir model geliştirmektir. Çalışmada yedi çeşit 13.611 adet kuru fasulye örneği kullanılmıştır. Veriler dengesiz dağılması sebebiyle, öncelikle en az sınıfa ait veri sayısı (522) kadar dengelenmiş ve 3654 adet kuru fasulye örneği seçilmiştir. Fasulyelere ait 16 morfolojik özellik bulunmaktadır. Özellik seçme algoritması yardımıyla özellikler seçilerek performans artırımı amaçlanmıştır. Geliştirilen en iyi model performans değeri doğruluk oranı %98,2 ve AUC (area under the curve) 1, PPV (positive predicted values) %100, TPR (true positive rate) %100'dir. Elde edilen sonuçlara göre kuru fasulye tohumlarının yüksek başarı oranı ile sınıflandırılabilmesi değerlendirilmektedir.

**Anahtar Kelimeler:** Kaliteli Tohum Üretimi, Kuru Fasulye, Yapay Zekâ, Tohum Sınıflandırma, Tarımda Yapay Zeka

**Classification of Dry Bean Species Based on Artificial Intelligence for Quality Seed Production in Agriculture**

**Abstract:** 27.5 million tons of dry beans were produced worldwide and 279.5 thousand tons in Turkey in In 2020. Dry beans have a wide variety. While one type of dry bean seed can be productive in cold climate conditions, another variety can be productive in more temperate climate conditions. In addition, dried bean seeds of different varieties can mix with each other for many different reasons. This situation affects the dry bean yield negatively. High yield in plant production depends on seed quality as well as many factors affecting yield. For this reason, it is necessary to classify seeds in order to obtain a quality seed and therefore a high yield. Today, Classification of dried bean seeds is carried out by sieves. However, varieties of bean as well as broken and spoiled seeds cannot be detected at sieving method. Therefore new technologies are needed to overcome of this problem. The aim of this study is to develop an artificial intelligence-based model for the classification of dry beans. In the study, 13,611 dried bean samples of seven varieties were used. Due to the uneven distribution of the data, firstly, it was balanced as much as the number of data belonging to the class (522), and then 3654 dry bean samples were selected. After the data balancing at least as much as the number of data belonging to the class (522) Due to the distribution imbalance of the data, 3654 dry bean samples were selected. There are 16 morphological features of beans. by the feature selection algorithm, the performance has been increased. The

*How to cite this article*

Kadioğlu U., Uçar M.K., Yıldırım S., "Classification of Dry Bean Species Based on Artificial Intelligence for Quality Seed Production in Agriculture", El-Cezeri Journal of Science and Engineering, 2022, 9 (4); 1450-1465.

*Bu makaleye atıf yapmak için*

Kadioğlu U., Uçar M.K., Yıldırım S., "Tarımda Kaliteli Tohum Üretimi için Kuru Fasulye Türlerinin Yapay Zekâ Tabanlı Sınıflandırılması", El-Cezeri Fen ve Mühendislik Dergisi, 2022, 9 (4); 1450-1465.

best model performance accuracy rate was 98.2% and AUC (area under the curve) 1, PPV (positive predicted values) %100, TPR (true positive rate). The Results suggested that dry bean seeds can be classified with a high success rate by Artificial Intelligence Based Classification.

**Keywords:** Quality Seed Production, Dry Beans, Artificial Intelligence, Seed Classification, Artificial Intelligence in Agriculture.

## 1. Giriş

21. yüzyılın başlarında veri artışı üstel olarak artmaktadır. Bilgiden değer üretmek için yüksek performanslı veri değerlendirme sistemlerine ihtiyaç duyulmaktadır. Duyulan ihtiyacı belirli ölçüde makine öğrenmesi algoritmaları karşılamaktadır [1]. Makine öğrenmesi görüntü işleme, segmentasyon ve sınıflandırma arařtırmalarında kullanılmaya başlanmıştır [2]. Tarımda makine öğrenimi mahsul yönetimi, su yönetimi, toprak yönetimi, hayvancılık yönetimi ve sınıflandırmada kullanılmaya başlanmıştır [3].

Kuru fasulye dünyada üretilen baklagiller arasında birinci sırayı almaktadır [4]. 2020 yılında Dünya genelinde 27,5 milyon ton, Türkiye de 279,5 bin ton kuru fasulye üretilmiştir [5]. Kuru fasulye önemli bir protein kaynağıdır. İnsanların bitkisel protein ihtiyacını karşılamaya yardımcı olur [6]. Kuru fasulye geniş bir çeşitliliğe sahiptir. Soğuk iklim koşullarında verimli olabileceği gibi daha ılıman iklim koşullarında verimli olabilmektedir. Günümüzde kuru fasulye tohumları arasında farklı çeşitlerin tohumları karışabilmektedir. Bu durum kuru fasulye verimini olumsuz etkilemektedir. Bitki verimini artırmak için tohum ıslahı ve tohum özelliklerinin belirlenmesi önemlidir [7].

Kuru fasulye tohumlarının sınıflandırılması günümüzde insan emeği veya seleksiyon yöntemi ile yapılmaktadır [8, 9]. Kuru fasulyenin çeşidini, kırık ve bozuk olanları tespit edememesi seleksiyon yöntemi ile sınıflamanın dezavantajlarıdır. İnsan emeği ile sınıflandırma yöntemi çok zaman almakta ve maliyetli olmaktadır.

İnsan gibi hassas, seleksiyon yöntemi gibi hızlı sınıflandırma yapabilen yeni teknolojilere ihtiyaç duyulmaktadır. Günümüzde bu amaçla yapay zeka yöntemleri kullanılmaktadır [10]. Kuru fasulye sınıflandırması için de yapay zeka destekli bir yöntem geliştirilmiştir [11]. Bu çalışma kapsamında çok katmanlı algılayıcı (Multi-Layer Perceptron - MLP), destek vektör makineleri (Support Vector Machines - SVMs), karar ağaçları (Decision Tree - DT), k-en yakın komşu algoritması (K-Nearest Neighborhood - kNN) gibi birçok yapı kullanılmıştır. Çalışmalarda elde edilen doğruluk oranı %84 -100 arasındadır [11]. Çalışmada yapay zeka algoritmasının eğitimi için 16 morfolojik özellik kullanılmıştır [11]. Elde edilen veri seti açık kaynak paylaşılmıştır [11]. Özellik toplamak maliyetli ve zaman alan bir iştir. Özelliklerin anlamlı bir şekilde azaltılması özellik seçme algoritmaları ile yapılmaktadır [12]. Yapay zekâ modelinin performansını etkileyen önemli etmenlerden bir tanesi özellik sayısıdır. Bir özellik performans üzerinde önemli bir etkiye sahip olabilir. Başka bir özelliğin performans üzerine etkisi göz ardı edilebilecek düzeyde kalabilir. Her bir özellik için veri toplamak zahmetli ve maliyetli bir iştir. En az özellik ile optimum yapay zekâ performansını elde etmek gereksiz özelliklerin verisini toplamak için gereken zaman ve maliyetten bizi kurtarır. Özelliklerin yapay zekâ modellerine etkisini gösteren özellik seçme algoritmaları geliştirilmiştir. Bunlardan bir tanesi Eta özellik seçme algoritmasıdır. Eta skoru (ES) sınıflandırma işlemi için en uygun özellikleri belirleyen yöntemlerden biridir. Yöntem hesaplamaları ayırıcı yöntemler ve üretken istatistiksel modellere dayanır. Her bir özellik için ES değeri hesaplanır. En yüksek puanı alan özellik sınıflar ile en uyumlu özelliği gösterir [12].

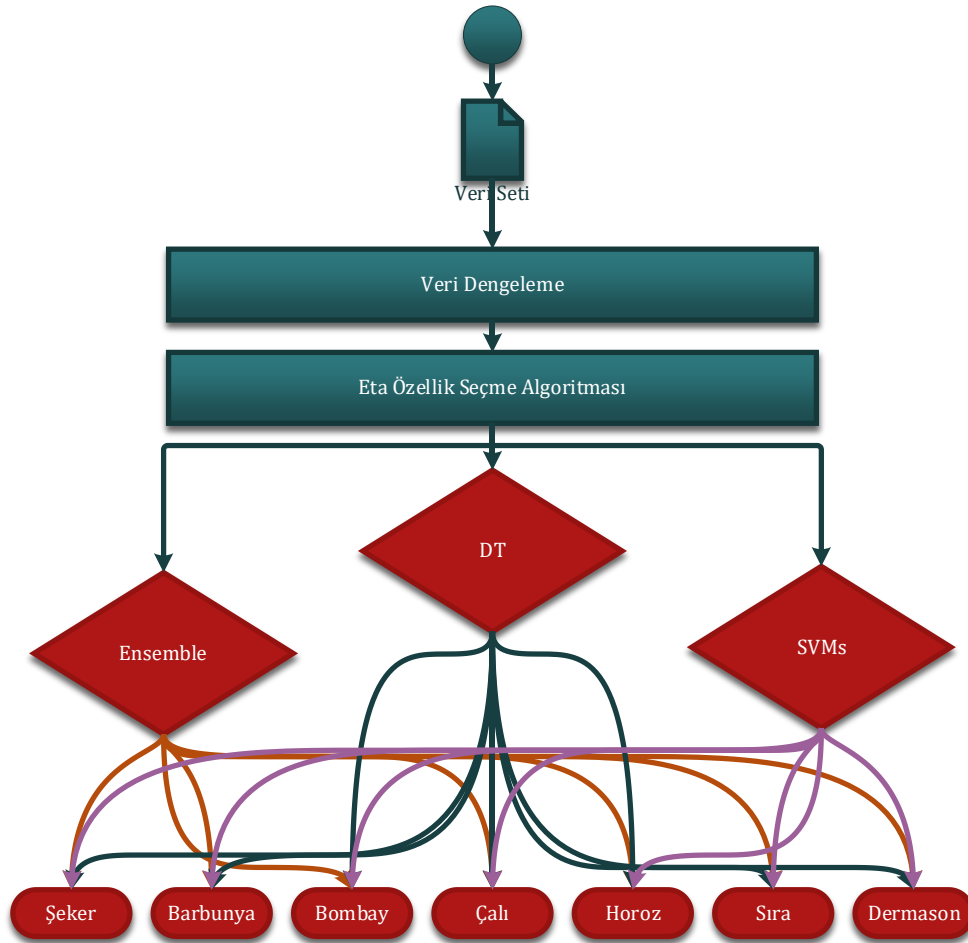
Bu çalışmanın amacı, insan emeğine ihtiyaç duyulmadan makine hızında kuru fasulyelerin sınıflandırılması için yapay zekâ yöntemleri ile kural tabanlı sınıflandırma algoritmaları geliştirebilmektir. Bu amaçla daha önce toplanmış içerisinde Türkiye’de en çok yetiştirilen 7 kuru

fasulye çeşidinin bulunduğu veri seti kullanılmıştır. Daha sonra kuru fasulye çeşitleri Ensemble, DT, SVMs yardımıyla kural tabanlı sınıflandırma algoritmaları hazırlanmıştır.

Çalışma sonucunda elde edilen bulgular; gerçek pozitif oran (TPR) %30,8-100, pozitif tahmin oranı (PPV) %33,7-100, altındaki alan (AUC) 1, doğruluk %51,4 ile %98,2 arasındadır.

## 2. Materyal ve Metot

Bu çalışmada uygulama aşamaları Şekil 1'de gösterilen diyagrama göre yapıldı. Öncelikle 7 farklı kuru fasulye çeşidine ait 16 morfolojik özellik içeren veri seti elde edildi. Elde edilen veriler eşit dağılmadığı için veri dengeleme işlemi uygulandı. Daha sonra Eta özellik seçme algoritması kullanıldı. Ensemble, DT, SVMs algoritmaları ile sınıflandırma işlemi yapıldı.



Şekil 1. Çalışma akış diyagramı

### 2.1 Verilerin Toplanması

Çalışmada kullanılan veri seti UCI Machine Learning Repository sitesinden indirildi [11]. Veri seti şeker, barbunya, bombay, çalı, horoz, sıra, dermason olmak üzere 7 farklı kuru fasulye çeşidine ait 16 morfolojik özellik içeren 13,611 örneklemeden oluşmaktadır (Tablo 1). Çeşitler belirlenirken piyasa koşulları dikkate alınmıştır. Sınıflandırma için 7 kuru fasulye etiketi kullanılmıştır.

**Tablo 1.** Veri setinin dağılımı

No	Çeşit	Örnek Sayısı (n)	Örnek Yüzdesi (%)	Toplam Örnek
1	Şeker	2027	14,89	
2	Barbunya	1322	9,71	
3	Bombay	522	3,84	
4	Çalı	1630	11,98	13611
5	Horoz	3546	26,05	
6	Sıra	1928	14,17	
7	Dermason	2636	19,37	

## 2.2 Morfolojik Özellik Tespiti

Kullanılan veri setinde 16 morfolojik özellik bulunmaktadır. Tüm kuru fasulye çeşitleri için elde edilen özelliklerin maksimum, minimum, ortalama ve standart sapma verileri Tablo 2’de gösterilmiştir.

**Tablo 2.** Kuru fasulye çeşitlerinin özelliklerinin istatistiksel dağılımı (piksel)

No	Özellik	Minimum	Maksimum	Ortalama	Standart Sapma
1	Alan	20420,000	254616,000	53048,285	29324,096
2	Çevre	524,736	1985,370	855,283	214,290
3	Ana Eksen Uzunluğu	183,601	738,860	320,142	85,694
4	Küçük Eksen Uzunluğu	122,513	460,198	202,271	44,970
5	En Boy Oranı	1,025	2,430	1,583	0,247
6	Eksantriklik	0,219	0,911	0,751	0,092
7	Dışbükey Alan	20684,000	263261,000	53,68,200	29774,916
8	Eşdeğer Çap	161,244	569,374	253,064	59,177
9	Katılık	0,555	0,866	0,750	0,049
10	Yuvarlaklık	0,919	0,995	0,987	0,005
11	Kompaktlık	0,490	0,991	0,873	0,060
12	Yuvarlaklık	0,641	0,987	0,800	0,062
13	Şekil Faktörü 1	0,003	0,010	0,007	0,001
14	Şekil Faktörü 2	0,001	0,004	0,002	0,001
15	Şekil Faktörü 3	0,410	0,975	0,644	0,099
16	Şekil Faktörü 4	0,948	1,000	0,995	0,004

## 2.3 Dengeleme

Çalışmada kuru fasulyelere ait örneklemelerin sayıları dengesiz olduğu için (Tablo 1) yapay zekâ modelinin performansını yükseltmek amacıyla veri dengeleme yoluna gidildi. Veri dengeleme işlemi için aşağıdaki prosedürler izlendi.

1. Veri setinde en az örnekleme ait kuru fasulye çeşidi tespit edildi (Bombay; 522 adet).
2. MATLAB’da bir algoritma yazıldı. Kuru fasulye çeşitlerinin ilk 522 örnekleme alınarak yeni bir veri seti oluşturuldu. Verilerin dengelenmesi sonucunda Tablo 3’teki dağılım oluşturuldu.

**Tablo 3.** Dengelenmiş veri seti

No	Çeşit	Örnek Sayısı (n)	Örnek Yüzdesi (%)	Toplam Örnek
1	Şeker	522	14,29	
2	Barbunya	522	14.29	
3	Bombay	522	14.29	
4	Çalı	522	14.29	3654
5	Horoz	522	14.29	
6	Sıra	522	14.29	
7	Dermason	522	14.29	

## 2.4 Eta Özellik Seçme Algoritması

Bu çalışmada kuru fasulyenin morfolojik özellikleri Eta özellik seçme algoritması ile seçilerek sınıflandırma yapıldı. Veri setine ait özelliklerin ilişki düzeyi Tablo 4’de, oluşturulan özellik grupları Tablo 5’ de gösterildi.

**Tablo 4.** Özellik seçme algoritması sonucu ilişki düzeyi

Özellik Numarası	Eta Score
6	1,00
15	0,94
12	0,90
14	0,79
5	0,79
11	0,69
3	0,46
16	0,44
10	0,40
2	0,34
8	0,27
7	0,26
1	0,26
9	0,26
13	0,12
4	0,00

## 2.5 Sınıflandırma Algoritmaları

Bu çalışmada sınıflandırma algoritması olarak Ensemble, DT, SVMs algoritmaları kullanıldı. Dengeleme yapıldıktan sonra herhangi bir özellik seçilmeden çeşitli sınıflandırma algoritmaları ile eğitim yapıldı. En yüksek performans değerlerini Ensemble, DT, SVMs algoritmaları elde etmiştir.

**Tablo 5.** Seçilmiş özellikler

Seçim	Seçilen Özellikler Numarası	Özellik Sayısı
1	6	1
2	6 15	2
3	6 15 12	3
4	6 15 12 14	4
5	6 15 12 14 5	5
6	6 15 12 14 5 11	6
7	6 15 12 14 5 11 3	7
8	6 15 12 14 5 11 3 16	8
9	6 15 12 14 5 11 3 16 10	9
10	6 15 12 14 5 11 3 16 10 2	10
11	6 15 12 14 5 11 3 16 10 2 8	11
12	6 15 12 14 5 11 3 16 10 2 8 7	12
13	6 15 12 14 5 11 3 16 10 2 8 7 1	13
14	6 15 12 14 5 11 3 16 10 2 8 7 1 9	14
15	6 15 12 14 5 11 3 16 10 2 8 7 1 9 13	15
16	6 15 12 14 5 11 3 16 10 2 8 7 1 9 13 4	16

## 2.6 Performans Deęerlendirme Kriterleri

Çalışma kapsamında performans deęerlendirme kriteri olarak doğru pozitif oran (True Positive Rate TPR), pozitif tahmin deęeri (Positive predictive value PPV), karakteristik eğri altında kalan alan (area under the receiver operating characteristic curve Curve AUC) ve doğruluk oranı kriterleri kullanıldı [13-15].

## 2.7 Eğitim ve Test Süreci

Yapılan literatür taramasında veri seti %80 eğitim, %20 test olarak ayrıldığında en yüksek başarı elde edilebileceęi görüldü [16]. Veri seti %80 eğitim, %20 test olmak üzere ikiye ayrıldı. Veri setinin dağılımı Tablo 6'da gösterildi.

**Tablo 6.** Eğitim ve test süreci için veri dağılımı

Çeşit	Eđitim Örnek Sayısı	Test Örnek Sayısı	Toplam Örnek Sayısı
Şeker	418	104	522
Barbunya	418	104	522
Bombay	418	104	522
Çalı	418	104	522
Horoz	418	104	522
Sıra	418	104	522
Dermason	418	104	522

## 3. Sonuçlar

Tüm özellikler kullanılarak yapılan sınıflandırma işleminde yedi farklı çeşit için yapılan deęerlendirmede en yüksek doğruluk oranına sırası ile SVMs %97,3, ensemble %97, DT %96,2 ile ulaşıldı.

**Tablo 7.** Tüm özelliklerden seçilmiş 4 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	96,2	87,6	100	80	98,1	92,3	91,3
	PPV	94,3	78,6	100	85,7	97,1	99	92,2
	AUC				0,99			
	Doğruluk				92,2			
	Doğruluk (k(5)-fold)				92,2			
Ensemble	TPR	96,2	90,5	100	82,9	99	94,2	97,1
	PPV	96,2	83,3	100	90,6	100	100	91
	AUC				1			
	Doğruluk				94,2			
	Doğruluk (k(5)-fold)				93,5			
SVMs	<b>TPR</b>	<b>97,1</b>	<b>91,4</b>	<b>100</b>	<b>88,6</b>	<b>100</b>	<b>95,2</b>	<b>96,2</b>
	<b>PPV</b>	<b>97,1</b>	<b>88,1</b>	<b>100</b>	<b>91,2</b>	<b>100</b>	<b>99</b>	<b>93,5</b>
	AUC				1			
	<b>Doğruluk</b>				<b>95,5</b>			
	<b>Doğruluk (k(5)-fold)</b>				<b>94,4</b>			

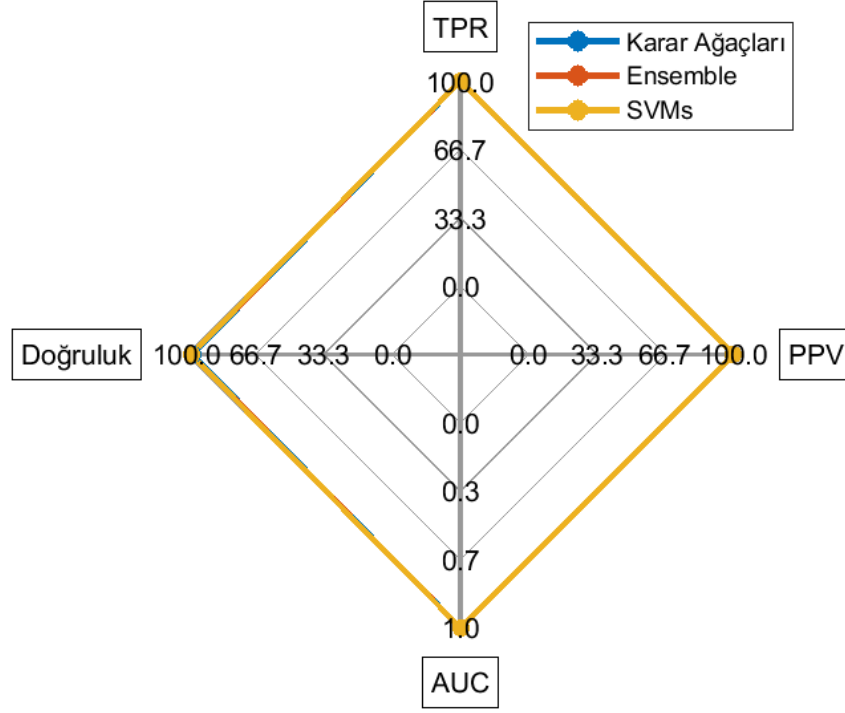
**Tablo 8.** Tüm özelliklerden seçilmiş 12 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	97,1	99	100	87,6	100	100	98,1
	PPV	99	88,9	100	98,9	100	99	97,1
	AUC				1			
	Doğruluk				97,4			
	Doğruluk (k(5)-fold)				95,7			
Ensemble	TPR	100	97,1	100	91,4	100	100	97,1
	PPV	99	91,9	100	97	100	98,1	100
	AUC				1			
	Doğruluk				97,9			
	Doğruluk (k(5)-fold)				97,2			
SVMs	<b>TPR</b>	<b>100</b>	<b>97,1</b>	<b>100</b>	<b>93,3</b>	<b>100</b>	<b>99</b>	<b>98,1</b>
	AUC				1			
	<b>Doğruluk</b>				<b>98,2</b>			
	<b>Doğruluk</b>				<b>97,3</b>			
	<b>Doğruluk (k(5)-fold)</b>				<b>97,3</b>			

Tüm özelliklerin test sonuçlarına göre dört özellikten önce modelin doğruluk oranının %51,4 – %54,5 aralığında olduğu görülmektedir. Dört özellik kullanılarak oluşturulan modelin performansı %94,4'dır (Tablo 7). Dört özellikten sonra modelin doğruluk oranının %91,1 ve %98,2 aralığına yükseldiği ve doğruluk oranında fazla bir değişiklik olmadığı görülmektedir. Performansı en iyi olan 12 özellik ve SVMs kullanılarak elde edilen modeldir (Tablo 8).

Sınıflandırma modelinin en iyi doğruluk, TPR, PPV, AUC oranları Şekil 2'de gösterildi. En iyi performansı SVMs'de elde edilmiştir. Tüm özelliklerden seçilmiş 12 özellikten oluşturulan modelin

karmaşıklık matrisine bakıldığında en yüksek performansı horoz fasulyede elde edildiđi görölmektedir (Şekil 3).



Şekil 2. En iyi model performans değeri değerlendirme sonuçlarının grafiksel gösterimi

Model 1.1

True Class	1	2	3	4	5	6	7
1	102						2
2		93		7		2	2
3			104				
4		8		96		1	
5					105		
6				2		101	1
7						5	99

Predicted Class

Şekil 3. Tüm özelliklerden seçilmiş 12 özellik için karmaşıklık matrisi (confusion matrix) gösterimi (En iyi performansı elde eden model)



#### 4. Tartışma ve Sonuç

Farklı tür kuru fasulyelerin birlikte ekimi verimi olumsuz yönde etkilemektedir [17]. Kuru fasulye tohumlarının sınıflandırılması verimin artırılması açısından büyük öneme sahiptir [18]. Bu çalışmada, kuru fasulyelerin sınıflandırmasını kolaylaştırabilen, insan emeğine ve hassasiyetine gerek duymayan yapay zekâ sınıflandırma modeli geliştirilmiştir.

Literatürde yapay zeka ile kuru fasulye çeşidi sınıflandırması yapılan kısıtlı çalışmalar mevcuttur. Yapılan çalışmalarda özellik seçimi kullanılmamıştır. Bu çalışmada 16 morfolojik özellik kullanılarak 7 kuru fasulye çeşidi sınıflandırılmaya çalışılmış ve herhangi bir özellik seçme algoritması kullanılmamıştır ve doğruluk oranı SVM’de %93,12, DT’de %87,92’dir. [11]. Çalışmamızda da makine öğrenmesi algoritmaları kullanılmış, bu çalışmadan farklı olarak özellik seçimi için Eta özellik seçme algoritmaları kullanılmıştır. Bu sayede özellik sayısı azaltılmıştır. Literatürde özellik seçme algoritmalarının kullanıldığı çalışmalarda doğruluk oranı yaklaşık %94-100 arasında duyarlılık değeri ise %92-100 arasındadır [19, 20]. Tablo 4’de belirtilen ilk 3 özellik için doğruluk oranları %51-54 arasındadır. Dört ve üzerinde özellik kullanıldığında ise doğruluk oranı anlamlı bir şekilde %91-98’e yükselmiştir. Özellik elde etmek zahmetli bir iş olduğu için 16 morfolojik özelliğe gerek kalmadan daha az özellik ile yüksek performansta sınıflandırma yapılabilmesi kuru fasulye sınıflandırmasında Eta özellik seçme algoritmaları ve yapay zekanın kullanılabilceğini göstermektedir.

Bu çalışmayı literatürden ayıran en önemli özellik geliştirilen modelin bir kuru fasulye sınıflandırma makinesinde kullanılabilir olmasıdır. Literatürde geliştirilen yüksek başarı oranına sahip sistemler bilgisayar ortamında çalışmaya uygun sistemlerdir [21-23].

Sonuç olarak, günümüzdeki kuru fasulye sınıflandırma makineleri bilgisayar sistemlerine uygun değildir. Geliştirilen modelin kuru fasulye sınıflandırma makinesinde kullanılabilmesi için yeni bir makine tasarımına ihtiyaç vardır. Bu çalışmada önerilen modelinin bir kuru fasulye sınıflandırma makinesinde kullanılabilceğini değerlendirilmektedir. Çalışmamız ayrıca bize farklı seçme algoritmaları ile özellik seçimlerinin yapılmasının ve algoritmaların karşılaştırılmasının literatüre katkı sağlayabileceğini düşündürmektedir.

**Yazar beyanları eksik**

#### Kaynaklar

- [1]. Mahesh, B., "Machine learning algorithms-a review", in International Journal of Science and Research (IJSR).[Internet]. 2020. s. 381-386.
- [2]. Pandey, R., S. Naik, ve R. Marfatia, "Image processing and machine learning for automated fruit grading system: A technical review", in International Journal of Computer Applications. 2013. s. 29-39.
- [3]. Liakos, K.G., vd., "Machine learning in agriculture: A review", in Sensors. 2018. s. 2674.
- [4]. Smith, K.J. ve W. Huyser, "World distribution and significance of soybean", in Agronomy. 1987.
- [5]. FAO, Crops and livestock products. [2022; 11 Mayıs 2022]; erişim adresi: <https://www.fao.org/faostat/en/#data/QCL>.
- [6]. Adak, M., M. Güler, ve N. Kayan, "Yemelik baklagillerin üretimini artırma olanakları", in Türkiye Ziraat Mühendisliği VII. Teknik Kongresi. 2010. s. 329-341.

- [7]. Ceyhan, E., A. Kahraman, ve M. Onder, "The impacts of environment on plant products", in *International Journal of Bioscience, Biochemistry and Bioinformatics*. 2012. s. 48.
- [8]. BIYIKLI, B., E. ELKOCA, ve M. AYDIN, "İspir kuru fasulye (*phaseolus vulgaris* l.) popölasyonunun karakterizasyonu ve seleksiyon yoluyla islahı", in *Anadolu Tarım Bilimleri Dergisi*. 2015. s. 20-33.
- [9]. Espinosa-Pérez, E.N., vd., "Classification of common dry bean landraces from the south-center of mexico by seed morphology", in *Revista fitotecnia mexicana*. 2015. s. 29-38.
- [10]. Yılmaz, D.Ö.Ü.A. Ve K. Yayın, *Yapay zeka. 2021: KODLAB YAYIN DAĞITIM YAZILIM LTD. ŞTİ.*
- [11]. Koklu, M. ve I.A. Ozkan, "Multiclass classification of dry beans using computer vision and machine learning techniques", in *Computers and Electronics in Agriculture*. 2020. s. 105507.
- [12]. Uçar, M.K., "Eta correlation coefficient based feature selection algorithm for machine learning: E-score feature selection algorithm", in *Journal of Intelligent Systems: Theory and Applications*. 2019. s. 7-12.
- [13]. Oriola, O. ve E. Kotzé, "Evaluating machine learning techniques for detecting offensive and hate speech in south african tweets", in *IEEE Access*. 2020. s. 21496-21509.
- [14]. Uçar, M.K., vd., "Automatic sleep staging in obstructive sleep apnea patients using photoplethysmography, heart rate variability signal and machine learning techniques", in *Neural Computing and Applications*. 2018. s. 1-16.
- [15]. Uçar, M.K., vd., "Automatic detection of respiratory arrests in osa patients using ppg and machine learning techniques", in *Neural Computing and Applications*. 2017. s. 2931-2945.
- [16]. Uçar, M.K., vd., "The effect of training and testing process on machine learning in biomedical datasets", in *Mathematical Problems in Engineering*. 2020.
- [17]. Şahin, A., "Bazı kuru fasulye çeşitlerinde (*phaseolus vulgaris* l.) bakteri aşılama ve azot dozlarının verim ve verim unsurları üzerine etkisinin belirlenmesi". 2018, Yüksek Lisans Tezi, Dicle Üniv. Fen Bil. Enst. Diyarbakır.
- [18]. Cengiz, B., "Sakarya ve eskişehir lokasyonlarında yetiştirilen bazı kuru fasulye çeşitlerinin kalite özellikleri". 2007, Namık Kemal Üniversitesi.
- [19]. Abdi, M.J. ve D. Giveki, "Automatic detection of erythematous-squamous diseases using psosvm based on association rules", in *Engineering Applications of Artificial Intelligence*. 2013. s. 603-608.
- [20]. Verma, A.K., S. Pal, ve S. Kumar, "Comparison of skin disease prediction by feature selection using ensemble data mining techniques", in *Informatics in Medicine Unlocked*. 2019. s. 100202.
- [21]. Übeyli, E.D., "Multiclass support vector machines for diagnosis of erythematous-squamous diseases", in *Expert Systems with Applications*. 2008. s. 1733-1740.
- [22]. Übeyli, E.D. ve I. Güler, "Automatic detection of erythematous-squamous diseases using adaptive neuro-fuzzy inference systems", in *Computers in biology and medicine*. 2005. s. 421-433.
- [23]. Jha, S.K., vd., "A comprehensive search for expert classification methods in disease diagnosis and prediction", in *Expert Systems*. 2019. s. e12343.

**Ekler****Tablo 9.** Tüm özelliklerden seçilmiş 2 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	94,2	27,9	17,3	76	40	81	39,4
	PPV	93,3	33,7	29,5	46,5	45,7	93,4	32,8
	AUC				0,99			
	Doğruluk				53,7			
	Doğruluk (k(5)-fold)				52,2			
Ensemble	TPR	94,2	9,6	4,8	80,8	45,7	82,9	55,8
	PPV	93,3	33,3	71,4	44,9	42,1	98,5	29,9
	AUC				1			
	Doğruluk				53,4			
	Doğruluk (k(5)-fold)				52,2			
<b>SVMs</b>	<b>TPR</b>	<b>96,2</b>	<b>26,9</b>	<b>15,4</b>	<b>78,8</b>	<b>40</b>	<b>82,9</b>	<b>41,3</b>
	<b>PPV</b>	<b>88,5</b>	<b>35,9</b>	<b>44,4</b>	<b>48,8</b>	<b>40,4</b>	<b>92,6</b>	<b>31,4</b>
	<b>AUC</b>				<b>0,99</b>			
	<b>Doğruluk</b>				<b>54,5</b>			
	<b>Doğruluk (k(5)-fold)</b>				<b>53,5</b>			

**Tablo 10.** Tüm özelliklerden seçilmiş 3 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	92,3	27,9	13,3	67,3	45,2	78,8	36,2
	PPV	91,4	33,3	34,1	46,7	35,9	88,2	30,9
	AUC				0,98			
	Doğruluk				51,5			
	Doğruluk (k(5)-fold)				51,9			
Ensemble	TPR	92,3	32,7	21	60,6	47,1	79,8	26,7
	PPV	92,3	27,6	32,4	54,8	37,1	91,2	28,9
	AUC				0,98			
	Doğruluk				51,4			
	Doğruluk (k(5)-fold)				52,2			
<b>SVMs</b>	<b>TPR</b>	<b>94,2</b>	<b>13,5</b>	<b>22,9</b>	<b>66,3</b>	<b>47,1</b>	<b>79,8</b>	<b>39</b>
	<b>PPV</b>	<b>89,1</b>	<b>29,8</b>	<b>35,3</b>	<b>49,3</b>	<b>36,8</b>	<b>89,2</b>	<b>29,5</b>
	<b>AUC</b>				<b>0,99</b>			
	<b>Doğruluk</b>				<b>51,8</b>			
	<b>Doğruluk (k(5)-fold)</b>				<b>54,7</b>			

**Tablo 11.** Tüm özelliklerden seçilmiş 5 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	96,2	85,6	100	68,3	96,2	96,2	95,2
	PPV	93,5	75,4	99	88,8	98	93,5	90,9
	AUC				0,97			
	Dođruluk				91,1			
	Dođruluk (k(5)-fold)				92			
Ensemble	TPR	99	88,5	100	71,2	97,1	96,2	96,2
	PPV	94,5	76,7	100	89,2	100	95,3	94,4
	AUC				1			
	Dođruluk				92,6			
	Dođruluk (k(5)-fold)				93,5			
SVMs	<b>TPR</b>	<b>99</b>	<b>90,4</b>	<b>100</b>	<b>79,8</b>	<b>100</b>	<b>96,2</b>	<b>96,2</b>
	<b>PPV</b>	<b>98,1</b>	<b>82,5</b>	<b>100</b>	<b>90,2</b>	<b>100</b>	<b>97,1</b>	<b>94,4</b>
	AUC				1			
	<b>Dođruluk</b>				<b>94,5</b>			
	<b>Dođruluk (k(5)-fold)</b>				<b>94,7</b>			

**Tablo 12.** Tüm özelliklerden seçilmiş 6 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	94,2	88,6	100	90,4	100	91,4	93,3
	PPV	97	89,4	99	90,4	99	94,1	89
	AUC				0,96			
	Dođruluk				94			
	Dođruluk (k(5)-fold)				93,8			
Ensemble	TPR	94,2	88,6	100	90,4	100	93,3	94,2
	PPV	95,1	91,2	100	90,4	99	96,1	89,1
	AUC				1			
	Dođruluk				94,4			
	Dođruluk (k(5)-fold)				93,5			
SVMs	<b>TPR</b>	<b>99</b>	<b>89,5</b>	<b>100</b>	<b>97,1</b>	<b>99</b>	<b>93,3</b>	<b>96,2</b>
	<b>PPV</b>	<b>96,3</b>	<b>96,3</b>	<b>100</b>	<b>91,8</b>	<b>100</b>	<b>97</b>	<b>92,6</b>
	AUC				1			
	<b>Dođruluk</b>				<b>96,3</b>			
	<b>Dođruluk (k(5)-fold)</b>				<b>96,2</b>			

**Tablo 13.** Tüm özelliklerden seçilmiş 7 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	98,1	90,5	100	84,6	99	96,2	91,3
	PPV	95,3	84,8	100	90,7	99	95,2	95
	AUC				0,99			
	Doğruluk				94,2			
	Doğruluk (k(5)-fold)				94,3			
Ensemble	TPR	98,1	92,4	100	87,5	100	95,2	94,2
	PPV	95,3	86,6	100	93,8	99,1	99	94,2
	AUC				0,99			
	Doğruluk				95,3			
	Doğruluk (k(5)-fold)				95,6			
<b>SVMs</b>	<b>TPR</b>	<b>99</b>	<b>94,3</b>	<b>100</b>	<b>93,3</b>	<b>100</b>	<b>94,2</b>	<b>96,2</b>
	<b>PPV</b>	<b>96,3</b>	<b>92,5</b>	<b>100</b>	<b>94,2</b>	<b>100</b>	<b>100</b>	<b>94,3</b>
	<b>AUC</b>				<b>1</b>			
	<b>Doğruluk</b>				<b>96,7</b>			
	<b>Doğruluk (k(5)-fold)</b>				<b>96,4</b>			

**Tablo 14.** Tüm özelliklerden seçilmiş 8 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	99	96,2	100	90,4	99	92,3	95,2
	PPV	97,2	91,7	100	95,9	100	97	90,9
	AUC				0,99			
	Doğruluk				96			
	Doğruluk (k(5)-fold)				94,7			
Ensemble	TPR	99	96,2	100	91,3	100	90,4	95,2
	PPV	96,3	9,99	100	97,9	100	98,9	89,3
	AUC				1			
	Doğruluk				96			
	Doğruluk (k(5)-fold)				95,9			
<b>SVMs</b>	<b>TPR</b>	<b>99</b>	<b>97,1</b>	<b>100</b>	<b>96,2</b>	<b>100</b>	<b>91,3</b>	<b>96,2</b>
	<b>PPV</b>	<b>97,2</b>	<b>96,2</b>	<b>100</b>	<b>97,1</b>	<b>100</b>	<b>99</b>	<b>91</b>
	<b>AUC</b>				<b>1</b>			
	<b>Doğruluk</b>				<b>97,1</b>			
	<b>Doğruluk (k(5)-fold)</b>				<b>96,6</b>			

**Tablo 15.** Tüm özelliklerden seçilmiş 9 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	98,1	88,5	100	93,3	100	94,2	93,3
	PPV	100	90,2	100	90,7	100	92,5	94,2
	AUC				0,99			
	Dođruluk				95,3			
	Dođruluk (k(5)-fold)				94,5			
Ensemble	TPR	98,1	93,3	100	95,2	99	93,3	96,2
	PPV	99	95,1	100	94,3	100	95,1	91,8
	AUC				1			
	Dođruluk				96,4			
	Dođruluk (k(5)-fold)				96,4			
<b>SVMs</b>	<b>TPR</b>	<b>98,1</b>	<b>96,2</b>	<b>100</b>	<b>98,1</b>	<b>100</b>	<b>91,3</b>	<b>97,1</b>
	<b>PPV</b>	<b>100</b>	<b>97,1</b>	<b>100</b>	<b>96,2</b>	<b>100</b>	<b>96,9</b>	<b>91,1</b>
	<b>AUC</b>				<b>0,99</b>			
	<b>Dođruluk</b>				<b>97,3</b>			
	<b>Dođruluk (k(5)-fold)</b>				<b>97,1</b>			

**Tablo 16.** Tüm özelliklerden seçilmiş 10 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	99	87,6	100	93,3	99	92,3	91,3
	PPV	97,2	91,1	100	88,2	100	92,3	94,1
	AUC				0,99			
	Dođruluk				94,7			
	Dođruluk (k(5)-fold)				95,0			
Ensemble	TPR	100	90,5	100	94,2	100	93,3	98,1
	PPV	99,1	92,2	100	92,5	100	97	95,3
	AUC				1			
	Dođruluk				96,6			
	Dođruluk (k(5)-fold)				96,7			
<b>SVMs</b>	<b>TPR</b>	<b>99</b>	<b>93,3</b>	<b>100</b>	<b>94,2</b>	<b>100</b>	<b>91,3</b>	<b>98,1</b>
	<b>PPV</b>	<b>100</b>	<b>94,2</b>	<b>100</b>	<b>94,2</b>	<b>100</b>	<b>96,9</b>	<b>91,1</b>
	<b>AUC</b>				<b>0,99</b>			
	<b>Dođruluk</b>				<b>96,6</b>			
	<b>Dođruluk (k(5)-fold)</b>				<b>97,0</b>			

**Tablo 17.** Tüm özelliklerden seçilmiş 11 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	96,2	84,6	100	92,4	100	95,2	98,1
	PPV	99	89,8	100	86,6	100	99	92,7
	AUC				0,99			
	Doğruluk				95,2			
	Doğruluk (k(5)-fold)				95,6			
Ensemble	TPR	98,1	93,3	100	93,3	100	96,2	98,1
	PPV	98,1	92,4	100	93,3	100	100	95,3
	AUC				1			
	Doğruluk				97			
	Doğruluk (k(5)-fold)				96,7			
<b>SVMs</b>	<b>TPR</b>	<b>97,1</b>	<b>94,2</b>	<b>100</b>	<b>96,2</b>	<b>100</b>	<b>97,1</b>	<b>97,1</b>
	<b>PPV</b>	<b>98,1</b>	<b>96,1</b>	<b>100</b>	<b>94,4</b>	<b>100</b>	<b>98,1</b>	<b>95,3</b>
	<b>AUC</b>				<b>1</b>			
	<b>Doğruluk</b>				<b>97,4</b>			
	<b>Doğruluk (k(5)-fold)</b>				<b>96,9</b>			

**Tablo 18.** Tüm özelliklerden seçilmiş 13 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	100	93,3	100	85,6	100	99	99
	PPV	98,1	86,6	100	93,7	100	92	100
	AUC				1			
	Doğruluk				97,4			
	Doğruluk (k(5)-fold)				95,9			
Ensemble	TPR	100	97,1	100	92,3	100	96,2	97,1
	PPV	98,1	89,4	100	97	100	99	100
	AUC				1			
	Doğruluk				97,5			
	Doğruluk (k(5)-fold)				96,7			
<b>SVMs</b>	<b>TPR</b>	<b>100</b>	<b>98,1</b>	<b>100</b>	<b>92,3</b>	<b>100</b>	<b>98,1</b>	<b>98,1</b>
	<b>PPV</b>	<b>99</b>	<b>92,7</b>	<b>100</b>	<b>99</b>	<b>100</b>	<b>99</b>	<b>97,2</b>
	<b>AUC</b>				<b>1</b>			
	<b>Doğruluk</b>				<b>98,1</b>			
	<b>Doğruluk (k(5)-fold)</b>				<b>97,0</b>			

**Tablo 19.** Tüm özelliklerden seçilmiş 14 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	98,1	89,5	100	92,4	100	97,1	93,3
	PPV	96,2	92,2	100	89,8	100	96,2	96
	AUC				0,98			
	Dođruluk				95,8			
	Dođruluk (k(5)-fold)				95,3			
Ensemble	TPR	98,1	94,3	100	93,3	100	97,1	95,2
	PPV	96,2	92,5	100	95,1	100	98,1	96,1
	AUC				1			
	Dođruluk				96,8			
	Dođruluk (k(5)-fold)				97,0			
<b>SVMs</b>	<b>TPR</b>	<b>98,1</b>	<b>92,4</b>	<b>100</b>	<b>98,1</b>	<b>100</b>	<b>97,1</b>	<b>96,2</b>
	<b>PPV</b>	<b>98,1</b>	<b>98</b>	<b>100</b>	<b>92,8</b>	<b>100</b>	<b>98,1</b>	<b>95,2</b>
	<b>AUC</b>				<b>0,99</b>			
	<b>Dođruluk</b>				<b>97,4</b>			
	<b>Dođruluk (k(5)-fold)</b>				<b>97,0</b>			

**Tablo 20.** Tüm özelliklerden seçilmiş 15 özellik için sınıflandırma sonuçları

Yöntem	PDK	Sınıf						
		1	2	3	4	5	6	7
DT	TPR	98,1	89,5	100	92,4	100	97,1	93,3
	PPV	96,2	92,2	100	89,8	100	96,2	96
	AUC				0,98			
	Dođruluk				95,8			
	Dođruluk (k(5)-fold)				95,5			
Ensemble	TPR	98,1	94,3	100	93,3	100	97,1	95,2
	PPV	96,2	92,5	100	95,1	100	98,1	96,1
	AUC				1			
	Dođruluk				96,8			
	Dođruluk (k(5)-fold)				96,8			
<b>SVMs</b>	<b>TPR</b>	<b>98,1</b>	<b>92,4</b>	<b>100</b>	<b>98,1</b>	<b>100</b>	<b>97,1</b>	<b>96,2</b>
	<b>PPV</b>	<b>98,1</b>	<b>98</b>	<b>100</b>	<b>92,8</b>	<b>100</b>	<b>98,1</b>	<b>95,2</b>
	<b>AUC</b>				<b>0,99</b>			
	<b>Dođruluk</b>				<b>97,4</b>			
	<b>Dođruluk (k(5)-fold)</b>				<b>97,2</b>			