



# Makine öğrenmesi algoritmalarıyla astronomik gözlem kalitesi tahminine yönelik karar destek sistemi geliştirilmesi ve uygulanması

Developing and implementing a decision support system for astronomical observation quality estimation with machine learning algorithms

Ömer Çağrı YAVUZ<sup>1</sup>

Ersin KARAMAN<sup>2</sup>

Cahit YEŞİLYAPRAK<sup>3</sup>

<sup>1</sup>Karadeniz Teknik Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, Trabzon, Türkiye

<sup>2</sup>Ankara Hacı Bayram Veli Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, Ankara, Türkiye

<sup>3</sup>Atatürk Üniversitesi, Fen Fakültesi, Astronomi ve Uzay Bilimleri Bölümü, Erzurum, Türkiye

## ÖZ

Kurulumunun tamamlanmasıyla birlikte araştırmacıların kullanımına sunulması planlanan Doğu Anadolu Gözlemevi (DAG) teleskopunun etkin ve verimli kullanımı önem arz etmektedir. Bu çalışma kapsamında araştırmacılar tarafından sunulan projelerin, gözlemevinin bulunduğu bölgenin yerel özellikleri dikkate alınarak gözlem türüyle eşleştirilmesi, değerlendirilmesi ve en uygun güne atanmasına yönelik karar destek sistemi geliştirilmesi amaçlanmaktadır. Bu amaç doğrultusunda öncelikle Naive Bayes, K En Yakın Komşu, Karar Ağacı ve Rastgele Orman algoritması kullanılarak dört farklı algoritmanın performansları değerlendirilmiş, yeniden örnekleme yöntemleri uygulanmış ve öz niteliklerin sonucu etkisi incelenmiştir. Sonrasında MAUT yönteminden esinlenerek her bir proje için yarar fonksiyonu formülünü barındıran fayda değerlerinin hesaplanması dayalı karar destek modeli geliştirilmiştir. Fayda değerleri projeler için başarı puanını temsil etmektedir. Projeler, gözlem türüne göre sınıflandırılarak başarı puanına göre büyükten küçüğe sıralanmıştır. Sonrasında önceden tahmin edilen gözlem türleri doğrultusunda projeler önceliklendirilerek ilgili günlere atanmıştır. Geliştirilen karar destek modeli ile teleskopun etkin ve verimli kullanımıyla birlikte değerlendirme sürecinin otomatikleştirilmesi amaçlanmaktadır.

**Anahtar Kelimeler:** Astronomik gözlem kalitesi, Doğu Anadolu Gözlemevi, tahmin, karar destek sistemleri, makine öğrenmesi

**JEL Kodları:** C53, C67, C80, L86, S44

## ABSTRACT

The effective and efficient use of the Eastern Anatolia Observatory telescope, which is planned to be made available to researchers upon completion of its installation, is important. Within the scope of this study, it is aimed to develop a decision support system for the projects presented by the researchers to be matched with the observation type, evaluated, and assigned to the most appropriate day, taking into account the local characteristics of the region where the observatory is located. For this purpose, first of all, the performances of four different algorithms were evaluated using naive Bayes, K nearest neighbor, decision tree, and random forest algorithms, resampling methods were applied, and the effect of attributes on the result was examined. Then, inspired by the multi-attribute utility theory method, a decision support model based on the calculation of utility values containing the utility function formula was developed for each project. Benefit values represent success points for projects. The projects were classified according to the type of observation and ordered from the largest to the smallest according to the success score. Afterward, projects were prioritized in line with the predicted types of observations and assigned to the relevant days. With the developed decision support model, it is aimed to automate the evaluation process together with the effective and efficient use of the telescope.

**Keywords:** Astronomical observation quality, decision support systems, Eastern Anatolia Observatory, estimation, machine learning

**JEL Codes:** C53, C67, C80, L86, S44



## Giriş

Atatürk Üniversitesi Astrofizik Araştırma ve Uygulama Merkezi (ATASAM) bünyesinde 2012 yılı itibarıyla yürütülen Doğu Anadolu Gözlemevi (DAG) projesi kapsamında teleskopun kurulumunun tamamlanmasıyla birlikte hem kırmızı ötesi hem de görünür gözlemlerin yapılması amaçlanmaktadır. Bu amaç çerçevesinde farklı kurumlarla işbirlikleri sağlanmaktadır. Bu işbirlikleri kapsamında elde edilen gözlem verilerinin anlaşılmalarılarak karar süreçlerine katkı sağlanması planlanmaktadır. Ancak bu gözlem verilerinin işlenmesi ve anlaşılmamasında çeşitli zorluklar yaşanmaktadır. Bu zorlukların aşılması amacıyla özellikle sınıflandırma problemlerinin çözümünde makine öğrenmesi algoritmalarının kullanımı son yıllarda artış göstermektedir. Örnek olarak Agarwal ve diğerleri (2021) Gaia DR2 verileriyle kümelerin olası üyelerini tahmin etmek için K En Yakın Komşu algoritmasını kullanmışlardır. Çalışma sonucunda kümelerin astronomik parametreler ile uyum içinde olduğu belirtilmiştir. Başka bir çalışmada Vavilova ve diğerleri (2021) galaksilerin otomatik morfolojik sınıflandırılması amacıyla lojistik regresyon, destek vektör makinesi, rastgele orman, naive bayes ve k en yakın komşu algoritmaları kullanılmıştır. Çalışma sonucunda destek vektör makinesi için %96,4, rastgele orman algoritması için de %95,5 başarı elde edilmiştir. Benzer bir çalışmada da blazarsların sınıflandırılması amacıyla rastgele orman, destek vektör makinesi, k en yakın komşu ve naive bayes algoritmaları kullanılmıştır. Çalışma sonucunda çok frekanslı spektral özelliklerin ayırt edilmesinde makine öğrenmesi algoritmalarının uygulanabilirliği vurgulanmıştır. Benzer şekilde asteroidlerin sınıflandırılması (Huang ve ark., 2016), fotometrik

süpernova patlamalarının sınıflandırılması (Lochner ve ark., 2016), K2 titreşen yıldızların sınıflandırılmasında (Saux ve ark., 2019) çeşitli makine öğrenmesi algoritmaları kullanılmaktadır.

Ek olarak astronomide makine öğrenmesi algoritmanın kullanımına yönelik benzer çalışmalar Tablo 1'de verilmiştir. Ayrıca bu çalışmalarda kullanılan gözetimli makine öğrenmesi algoritmalarından K En Yakın Komşu algoritması (KNN), Naïve Bayes algoritması (NB), Karar Ağacı algoritması (DT), Rastgele Orman algoritması (RF), Yapay Sinir Ağları (ANN), Destek Vektör Makineleri (SVM), Lojistik Regresyon (LR) algoritmaları da Tablo 1'de sunulmuştur.

Temelde iki aşamadan oluşan bu çalışma kapsamında da çeşitli kriterlere göre değişiklik gösteren astronomik gözlem türünün naive bayes, k en yakın komşu, karar ağacı ve rastgele orman algoritmalarıyla tahmin edilmesi ve araştırmacılar tarafından sunulan projelerin gözlemevinin bulunduğu bölgenin yerel özellikleri dikkate alınarak gözlem türüyle eşleştirilmesi ve en uygun güne atanması amaçlanmaktadır. Bu kapsamında araştırmacıların kullanımına sunulacak olan teleskopun etkin ve verimli kullanımı önem arz etmektedir.

İlk aşamada tahmin edilen gözlem türünün sürece dahil edilmesiyle birlikte DAG projelerinin değerlendirilmesi amacıyla ilgili projelerin astronomik gözlem türüne göre sınıflandırılması, değerlendirilmesi ve önceliklendirilmesi amaçlanmaktadır. Bu amaç doğrultusunda MAUT yönteminden esinlenerek her bir proje için yarar fonksiyonu formülünü barındıran fayda değerlerinin hesaplanması dayalı karar destek modeli geliştirilmiştir.

**Tablo 1.**  
Yapılan Çalışmalar

KNN	NB	DT	RF	ANN	SVM	LR
Agarwal ve ark. (2021)	Broos ve ark. (2011)	Barchi ve ark. (2017)	Teimoorinia ve ark. (2021)	Elyiv ve ark. (2020)	du Buisson ve ark. (2015)	Beitia-Antero, ve ark. (2018)
Kügler ve ark. (2015)	Du Buisson ve ark. (2015)	Niederhausen, (2018)	Jin-Meng ve Xiao-Qing, (2021)	Sharma ve ark. (2020)	Barchi ve ark. (2017)	Chastenay ve Riopel, (2019)
Gao, (2016)	Lochner ve ark. (2016)	Curran ve ark. (2021)	Liu ve ark. (2017)	Bluck ve ark. (2020)	Marton ve ark. (2016)	Korsós ve ark. (2021)
Luken ve ark. (2019)	Vavilova ve ark. (2021)	Petrusevich, (2020)	Breton ve ark. (2019)	Cheng ve ark. (2021)	Hartley ve ark. (2017)	Vavilova ve ark. (2021)
Chan ve Stott, (2021)	Arsioli ve Dedin, (2020)	Golob ve ark. (2021)	Yesuf ve ark. (2020)	Bellinger ve ark. (2020)	Ahmazdadeh, ve ark. (2021)	Petrusevich, (2020)
Curran ve ark. (2021).	Petrusevich, (2020)		Mucesh ve ark. (2021)	Garton ve ark. (2021)	Vavilova ve ark. (2021)	Norris, (2017)
Du Buisson ve ark. (2015)			Bellinger ve ark. (2016)	Norris, (2017)	Lochner ve ark. (2016)	
Vavilova ve ark. (2021)			Pawlak ve ark. (2019)		Arsioli ve Dedin, (2020)	
Lochner ve ark. (2016)			Saux ve ark. (2019)		Norris, (2017)	
Arsioli ve Dedin, (2020)			Huang ve ark. (2016)			
Elyiv ve ark. (2020)			Sharma ve ark. (2020)			
			Vavilova ve ark. (2021)			
			Arsioli ve Dedin, (2020)			
			Bluck ve ark. (2020)			

Fayda değerleri projeler için başarı puanını temsil etmektedir. Üretilen 10 farklı proje, gözlem türüne göre sınıflandırılarak başarı puanına göre büyükten küçüğe sıralanmıştır. Sonrasında önceden tahmin edilen gözlem türleri doğrultusunda projeler önceliklenerek ilgili günlere atanmıştır. Geliştirilen karar destek modeli ile teleskopun etkin ve verimli kullanımıyla birlikte değerlendirme sürecinin otomatikleştirilmesi amaçlanmaktadır.

Günümüzde farklı kurum ve kuruluşlara yapılan projelerin değerlendirilmesinde çeşitli yöntemler kullanılmaktadır. Kullanılan bu yöntemler tek boyutlu ve çok boyutlu olmak üzere iki grupta ele alınmaktadır. Tek boyutlu yöntemlerde değerlendirmeler tek bir kriter üzerinden yapılır. Yapılan bu değerlendirmeler etkinlik ve verimlilik açısından çeşitli aksaklıkları ortaya çıkarmaktadır. Bu sebeple projeler değerlendirilirken tek bir kriter yerine birden fazla kriterle bağlı amaç fonksiyonunun göz önünde bulundurulması önerilmektedir (Yılmaz, 1980).

Çok boyutlu değerlendirmelerde birden fazla kriter çeşitli değişkenleri barındıran tekniklerle ölçülmekte olup bu kriterlere yönelik ağırlıkların tek bir fonksiyonda birleştirilmesi gerekmektedir (Daşdemir, 2012). Projelerin değerlendirme süreçlerinde problemin önemli yönleri, çeşitli amaçlara yönelik faydalaların artırılması amacıyla seçilebilecek birkaç değişkenle temsil edilmektedir. Böyle bir modelin etkili bir şekilde oluşturulması projelerin temel sonuçlarını tanımlar ve bu bilgiler hakkında nice veriler sağlar. Bu nice veriler için ölçme işlemi aynı birimlerde yapılmayabilir. Sonuç olarak proje değerlendirme süreci büyük bir karar verme sürecini bünyesinde barındırır (Smal, 1998). Bu karar verme sürecinin desteklenmesi amacıyla çeşitli karar verme yöntemleri kullanılmaktadır. Örnek olarak Kumar 2004, çalışmasında Ar-Ge projelerinin değerlendirilmesinde öznel değerlendirmelerin sayısallaştırılmasının amaçlayarak çok kriterli karar verme yöntemlerinde AHP'yi kullanmıştır. Bu kapsamında kriterler organizasyonel faktörler, teknik faktörler, stratejik faktörler ve finansal faktörler olmak üzere dört farklı grupta ele alınmıştır. Çalışma kapsamında araştırma projelerinin değerlendirilmesinde çok kriterli karar verme yöntemlerinin, ekonometrik yöntemlere göre daha uygun görüldüğü belirtilmiştir. Sonuç olarak yargışal değerlendirmeye dayalı projelerin seçilmesi ve sıralanmasında AHP kullanımının önem arz etiği ve benzer değerlendirme süreçlerindeki uygulanabilirliği vurgulanmıştır (Kumar, 2004). Benzer bir çalışmada da Ar-Ge projelerinin seçiminde sıralama sonuçlarının hassasiyetini artırmak amaçlanarak MAUT yöntemi kullanılmıştır. Çalışma kapsamında MAUT yönteminin uygulanabilirliği ve etkinliğinin ortaya konulması amaçlanarak gerçek bir Ar-Ge yatırım örneği ele alınmıştır. Çalışma sonucunda MAUT yönteminin ağırlıkların eş zamanlı değişimine izin vererek sağladığı göstergelere degenilerek bilgi çakışmalarını dengeleyebilecek modelin oluşturulmasında uygun niteliklerin belirlenmesinin gerekliliği vurgulanmıştır (Wang ve ark., 2010). Başka bir çalışmada da savunma sanayi projelerinin önceliklendirilmesi amaçlanarak AHP yöntemi kullanılmıştır. Çalışma kapsamında 11 kriter ele alınarak 6 alternatif için değerlendirme yapılmıştır. Çalışma sonucunda ilgili sektörde benzer durumların değerlendirilmesinde AHP yönteminin uygulanabilirliğinin karar verici açısından ifade edildiği belirtilmiştir (Balıca, 2020). Başka bir çalışmada da kent içi tafik sorunlarının çözümüne dayalı projelerin değerlendirilmesi 6 kriter üzerinden 10 alternatif TOPSIS yöntemi yardımıyla değerlendirilmiştir (Hamurcu ve Eren, 2018).

2012 itibarıyla Kalkınma Bakanlığı tarafından kabul edilen Doğu Anadolu Gözlemevi Projesi bünyesinde dört metrelık çapıyla Türkiye'nin en büyük teleskopu inşa edilmektedir. Hem görsel hem

de kırmızı ötesi bölgede gözlem yapacak olan bu teleskopun inşasının tamamlanmasıyla birlikte uluslararası araştırmacıların kullanımına sunulması planlanmaktadır. Görünür ve kırmızı ötesi bölgede yapılan gözlemler çeşitli faktörlere bağlı olarak değişiklik göstermektedir. Bahsedilen gözlemler gözlenen gökcisimlerine bağlı olarak hem farklı aygıtlarla hem de farklı amaçlarla yapılmaktadır. Etkin ve verimli bir gözlem süreci gerçekleştirilebilmesi açısından ileriye yönelik astronomik gözlem türünün tahmin edilmesi önem arz etmektedir. Ayrıca teleskop kullanımı için başvuran araştırmacıların projelerinin gözlem türü ile birlikte gözlem süresi, gözlem zamanı, gözlemeş alet çeşitliliği gibi parametrelerle bağlı olarak değerlendirilmesi de teleskopun etkin ve verimli kullanımı açısından önemli görülmektedir. Bu kapsamda öncelikle makine öğrenmesi algoritmalarıyla astronomik gözlem türünün tahmin edilmesi amaçlanmaktadır. Daha sonra gözlem süresi, gözlem zamanı gözlem amacı ve proje değerlendirme kriterleri dikkate alınarak projelerin önceliklendirilmesi ve değerlendirilmesine yönelik karar destek sistemi geliştirilmesi ve uygulanması amaçlanmıştır.

Son olarak uzman yönlendirmesi doğrultusunda yapılan mevcut gözlemlerin çeşitli kaynaklardan elde edilen verilerin işlenmesi ve analizine dayalı geliştirilen karar destek sistemi ile hem süreçlerin hem de teleskopun zekin ve verimli kullanımı açısından fayda sağlayacaktır. Ayrıca geliştirilen sistem, tüm teleskoplarda kullanılabilen olup DAG Projesi'nin tamamlanmasıyla birlikte teleskopun bilim dünyasında daha etkili ve verimli hizmet vermesi açısından önemli görülmektedir.

## Metodoloji

Çalışma kapsamında öncelikle dört farklı algoritma yardımıyla gözlem türü tahmin edilerek proje başvurularının değerlendirilmesi ve önceliklendirilmesine yönelik karar destek sistemi geliştirilmiştir. Bu amaç kapsamında öncelikle astronomik gözlem türü tahmininde makine öğrenmesi algoritmalarının uygulanabilirliğini test etmek için 12 nitelikten oluşan veri seti üzerinden uygulamalar gerçekleştirilmişdir. Yapılan ön testlerde kullanılan veri seti sınıflandırılmış olup K Ortalama Kümeleme algoritmasıyla sırasıyla 3, 4 ve 5 kümeye ayrılmış ve algoritma başarımları test edilmiştir (Yavuz & Karaman, 2020). Sonrasında uzman görüşü doğrultusunda giriş değerleri belirlenerek veri seti 6 öz niteliğe indirgenmiş ve gözlem verileri etiketlenmiştir. Uygulamalar iki sınıfı (Visible/VI-InfraRed/IR) ve dört sınıfı (VI Spect., VI Photo., IR Spect., IR Photo.) olmak üzere iki farklı veri seti ile yapılmıştır (Yavuz ve ark., 2021). Bu çalışmada da dört farklı algoritma kullanılarak yapılan uygulamalarda elde edilen performans metrikleri ortaya konulmuş ve dengeli-dengesiz veri setleri için başarımlar karşılaştırılmıştır. Ek olarak her bir niteliğin sonuca etkisinin belirlenmesi amaçlanarak her bir öz nitelik veri setinden çıkarılarak test edilmiştir. Son olarak MAUT yönteminden esinlenilerek proje değerlendirme ve önceliklendirmeye yönelik karar destek sistemi geliştirilmiş ve rastgele üretilen 10 proje için uygulanmıştır.

## Verilerin Toplanması ve Etiketlenmesi

Çalışma kapsamında kullanılan eğitim veri setinde yer alan astronomik gözlem türüne etki eden faktörler (giriş değerleri), astronomik gözlem türleri (çıkış değerleri) Doğu Anadolu Gözlemevi Projesi'nde görevli, bölgeyi iyi bilen, Astronomi ve Uzay Bilimleri alanında Profesör ünvanına sahip uzman görüşü doğrultusunda belirlenmiştir. Ek olarak proje değerlendirme sürecinde ele alınan kriterler, alt kriterler, kriter ağırlıkları ve faktörlerin değer aralıkları da yine uzman görüşü doğrultusunda belirlenmiştir. Çalışmada

**Tablo 2.**  
Kural Tabanı

KURAL TABANI
if (ACI is "1") AND (NEM < 40) AND (PWV <= 6) THEN GÖZLEM_TÜRÜ is "IR Spectrum"
if (ACI is "1") AND (NEM < 40) AND (PWV > 6) THEN GÖZLEM_TÜRÜ is "VI Spectrum"
if (ACI is "1") AND (NEM >= 40) AND (Seeing <= 1,5) THEN GÖZLEM_TÜRÜ is "VI Spectrum"
if (ACI is "1") AND (NEM >= 40) AND (Seeing > 1,5) THEN GÖZLEM_TÜRÜ is "VI Spectrum"
if (ACI is "2") AND (NEM < 40) AND (PWV <= 3) THEN GÖZLEM_TÜRÜ is "IR Photometric"
if (ACI is "2") AND (NEM < 40) AND (3 < PWV < 6) THEN GÖZLEM_TÜRÜ is "IR Spectrum"
if (ACI is "2") AND (NEM < 40) AND (PWV > 6) AND (Seeing <= 1,5) THEN GÖZLEM_TÜRÜ is "VI Photometric"
if (ACI is "2") AND (NEM < 40) AND (PWV > 6) AND (Seeing > 1,5) THEN GÖZLEM_TÜRÜ is "VI Spectrum"
if (ACI is "2") AND (NEM > 40) AND (Seeing > 1,5) THEN GÖZLEM_TÜRÜ is "VI Spectrum"
if (ACI is "0") OR (NEM > 80) OR (RUZGAR>20) OR (Seeing > 3) OR (Sıcaklık < -25) GÖZLEM_TÜRÜ is "Gözlem Yok"

eğitim veri setini oluşturan ve 2012–2019 yılları arasında günlük gözlem verilerinden oluşan kayıtlar Atatürk Üniversitesi Astrofizik Araştırma ve Uygulama Merkezi'nden alınmıştır. Gözlem verilerinden oluşan veri setinde yer alan 50 kayıt gözlem türleri göz önünde bulundurularak uzman tarafından etiketlenmiştir. Yapılan etiketleme işlemi doğrultusunda belirli kurallar ve bu kararlara bağlı karar ağacı oluşturulmuştur. 7 yıllık gözlem verilerinden oluşan eğitim veri seti, oluşturulan kural tabanı kullanılarak etiketlenmiştir. Etiketleme işlemi tamamlandıktan sonra elde edilen kayıtlar rastgele seçim yöntemiyle uzman tarafından doğrulanmıştır. Bu süreçte oluşturulan kural tabanı Tablo 2'de, karar ağacı da Şekil 1'de sunulmuştur. Her bir güne ait gözlem verilerinin

etiketlenmesi amacıyla uzman görüşü doğrultusunda kural tabanı oluşturulmuş olup kural tabanına ilişkin karar ağacı Şekil 1'de sunulmuştur. Aşağıdaki şekilde yer alan değerler eğitim veri setinde kullanılan öznitelikleri ifade etmekte olup ACI, astronomik açıklık endeksini, YSB yoğunşabil su buharını ifade etmektedir.

Etiketleme işlemi tamamlandıktan sonra oluşturulan kural tabanı ve karar ağacının uygunluğunun değerlendirilmesi amaçlanarak veri madenciliği araçlarından Orange kullanılmıştır. Etiketlenmiş veri seti için Orange aracılığıyla oluşturulan karar ağacı Şekil 2'de verilmiştir.

### Makine Öğrenmesi Algoritmaları

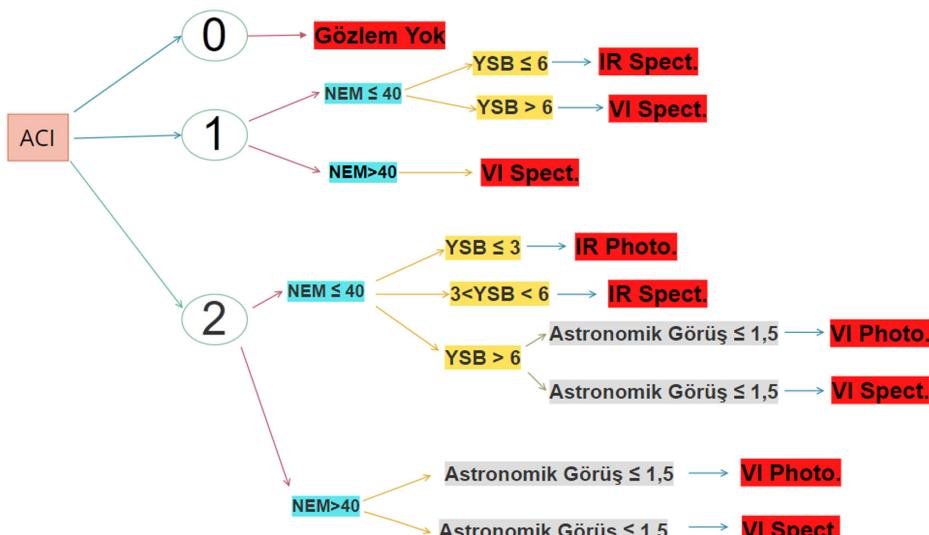
Bu çalışma kapsamında Naïve Bayes, K En Yakın Komşu, Karar Ağacı ve Rastgele Orman algoritmaları kullanılmıştır. Bu algoritmalar aşağıda kısaca anlatılmıştır.

**Naïve Bayes Algoritması:** Öğrenmenin eğitim veri üzerinden gerçekleştirildiği Naïve Bayes algoritmasında yapılan olasılıksal hesaplamalar Bayes teoremine dayanmaktadır. Olasılıksal hesaplamalar sonucunda elde edilen en yüksek değer ilgili sınıfı atanır. Bahsedilen olasılık hesaplamaları aşağıdaki formül yardımıyla yapılmaktadır.

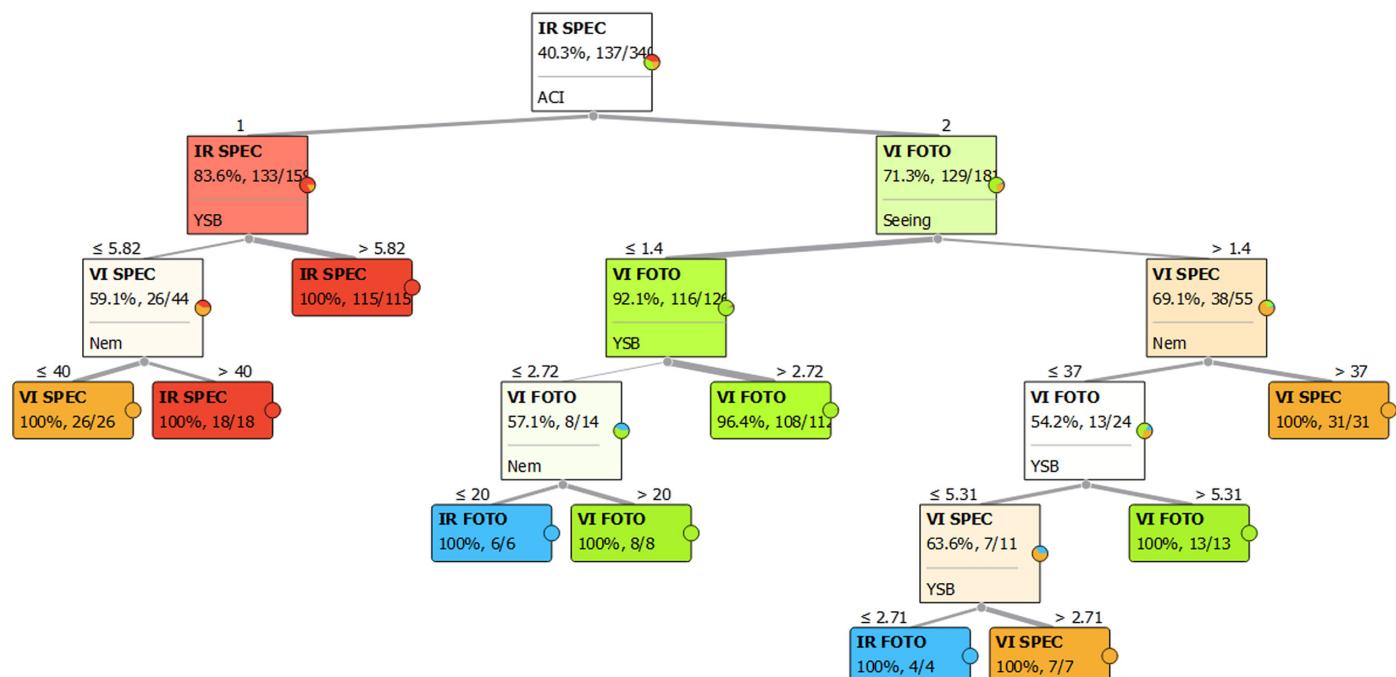
$$P\left(\frac{A}{B}\right) = \frac{P\left(\frac{B}{A}\right) * P(A)}{P(B)}$$

**K En Yakın Komşu Algoritması:** Sınıflandırılmamış değerin sınıflandırılmış değerlerden oluşan dizideki noktalara olan Öklid uzaklık ölçümlerine dayanan K En Yakın Komşu algoritması Cover ve Hart tarafından 1967 yılında geliştirimiştir. En yakın komşuların sayısını ifade eden K değeri kadar komşuya olan hesaplamalar yapılarak en yakın sınıfı atama yapılır (Cover ve Hart, 1967).

**Karar Ağacı Algoritması:** Sınıflandırma problemlerinin çözümünde sıklıkla kullanılan karar ağacıları, problemlerin çözümünde belirli karar adımları ve adımlara bağlı küçük kayıtların oluşturulmasını sağlar. Küçük kayıtlar doğrultusunda yapılan böleme işlemleriyle sınıf üyelerinin benzerlikleri arttırılır (Albayrak & Yılmaz, 2009).



**Şekil 1.**  
Karar Ağacı



**Şekil 2.**  
Orange ile Oluşturulan Karar Ağacı

Rastgele Orman Algoritması: Breiman (2001) tarafından geliştirilen Rastgele Orman Algoritması, karar ağaçlarının birleşimine dayanmaktadır. Öğrenme sürecinde her bir ağaç için bağımsız sınıflandırmaların yapılması amaçlanarak rastgele seçimler yapılır. Seçimler sonuçlandırıldıktan sonra ayrı ayrı yapılan sınıflandırmalara dayalı oylama gerçekleştirilerek en çok tekrarlanan değer sonuç olarak kabul edilir. İsmi de karar ağaçlarının birleştirilmesinden alan orman yapısı ile yüksek doğruluk değerlerinin elde edilmesi amaçlanmaktadır (Ercire, 2019).

### MAUT (Multi-Attribute Utility Theory)

Proje önceliklendirme süreci için en uygun yaklaşımlardan biri olarak belirtilen MAUT yöntemi, karar vericinin tercihlerine dayalı ön değerlendirme aşamasında çoklu hedefleri, soyut faktörleri, belirsizleri ve zamana bağlı sıralamanın etkilerini ele almak amacıyla biçimsel bir mekanizma sağlar (Dillon ve Perry, 1977). MAUT yöntemin problem çözümündeki kullanım kolaylığı ve karar vericilere sağlanan esneklik avantaj olarak belirtilmektedir. Ayrıca karar vericinin tercih yapısında ele alınan niteliklerle birlikte belirsizlik durumlarının dikkate alınması sağlanmaktadır (Lopes & Almeida, 2015). Ek olarak telafi edici çok kriterli karar verme yöntemleri kapsamında ele alınan MAUT yönteminde nitelikler birbirinden bağımsız olarak değerlendiriliyor ve nitel nitelikler sayısal değerlere dönüştürülür (Alinezhad & Khalili, 2019).

MAUT Yöntemi’nde takip edilen adımlar sırasıyla aşağıda verilmiştir.

- Kriterler ve kriterlere yönelik alt kriterlerin belirlenmesi: Proje önceliklendirme sürecinde 6 temel kriter, 20 alt kriter belirlenmiştir.
- Kriter ağırlıklarının belirlenmesi: Her bir kriter için belirlenen ağırlık değerleri kriterlerin sonucu etkisini ifade etmektedir. Bu kriterlere ilişkin ağırlık değerleri toplamının bir olması gerekmektedir.

$$\sum_i^n w_i = 1$$

- Her bir kriter için değer ölçülerinin atanması: Ağırlık değerleri belirlendikten sonra her bir alt kriter için değer ölçüsü atanır. Bu atama işlemi beşlik, onluk veya yüzlük sistem üzerinden yapılmaktadır.
- Değerlerin normalizasyonu: Atanan değer ölçülerinin normalizasyonu aşağıdaki formül yardımıyla yapılmaktadır.

$$x_i = \frac{x - \text{Min}(x_i)}{\text{Max}(x_i) - \text{Min}(x_i)}$$

- Fayda değerlerinin hesaplanması: Son olarak her bir alternatif için fayda değeri hesaplanmaktadır. Bu değerler aşağıda verilen yarar fonksiyonu formülü kullanılarak yapılmaktadır.

$$U(x_i) = \sum_1^n (x_i * w_i)$$

### Uygulama

Python sklearn kütüphanesi kullanılarak geliştirilen tahmin aracı yardımıyla yapılan tahminler doğrultusunda karar destek modeli geliştirilmiştir. Dört farklı algoritma ile tahmin edilen gözlem türleri aynı excel dosyası üzerinde farklı sütunlara yazdırılmıştır. Sonrasında her bir algoritmayı sürece dahil etmek amaçlanarak oylama yöntemine dayalı olarak her bir satırın modu alınmış ve ayrı bir dosyaya yazdırılmıştır. Geliştirilen tahmin aracı yardımıyla tahmin edilen gözlem türleri web tabanlı karar destek sisteminde kullanılmak üzere Şekil 3'te görüldüğü üzere veri tabanına kaydedilmiştir. Veri tabanına kaydedilen gözlem türlerine yönelik oluşturulan takvim de Şekil 4'te verilmiştir.

	id	proje_tarih	proje_tahmin	proje_id	durum	created_at	updated_at
1	313	2021-01-01		1	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:52:16
2	314	2021-01-02		4	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:52:16
3	315	2021-01-03		4	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:52:16
4	316	2021-01-04		2	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:52:16
5	317	2021-01-05		2	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:52:16
6	318	2021-01-06		2	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:36:05
7	319	2021-01-07		1	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:52:16
8	320	2021-01-08		2	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:36:05
9	321	2021-01-09		4	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:36:05
10	322	2021-01-10		4	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:36:05
11	323	2021-01-11		2	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:36:05
12	324	2021-01-12		2	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:36:05
13	325	2021-01-13		4	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:36:05
14	326	2021-01-14		4	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:36:05
15	327	2021-01-15		4	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:36:05
16	328	2021-01-16		3	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:52:16
17	329	2021-01-17		2	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:36:05
18	330	2021-01-18		1	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:52:16
19	331	2021-01-19		3	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:52:16
20	332	2021-01-20		1	<null> Boş	2021-12-03 12:36:05	2021-12-03 12:52:16

**Şekil 3.**  
Tahmin Sonuçları

#### Atanmış Proje Takvim

Proje Adı	Sahibi	Türü	Puan	Tarih	Durum	İşlemler
		Visible Photometric		2021-01-06	Boş	
		Visible Photometric		2021-01-08	Boş	
		Infrared Photometric		2021-01-09	Boş	
		Infrared Photometric		2021-01-10	Boş	
		Visible Photometric		2021-01-11	Boş	
		Visible Photometric		2021-01-12	Boş	
		Infrared Photometric		2021-01-13	Boş	
		Infrared Photometric		2021-01-14	Boş	
		Infrared Photometric		2021-01-15	Boş	
		Visible Photometric		2021-01-17	Boş	
		Visible Spectrum		2021-01-21	Boş	
		Infrared Photometric		2021-01-22	Boş	
		Infrared Spectrum		2021-01-23	Boş	
		Infrared Photometric		2021-01-24	Boş	
		Visible Photometric		2021-01-25	Boş	
		Visible Photometric		2021-01-26	Boş	

**Şekil 4.**  
Takvim

Proje değerlendirme sürecinde ele alınan gözlem türünün tahmini amaçlanarak geliştirilen tahmin aracı oluşturulurken takip edilen adımlar Şekil 5'te verilmiştir.

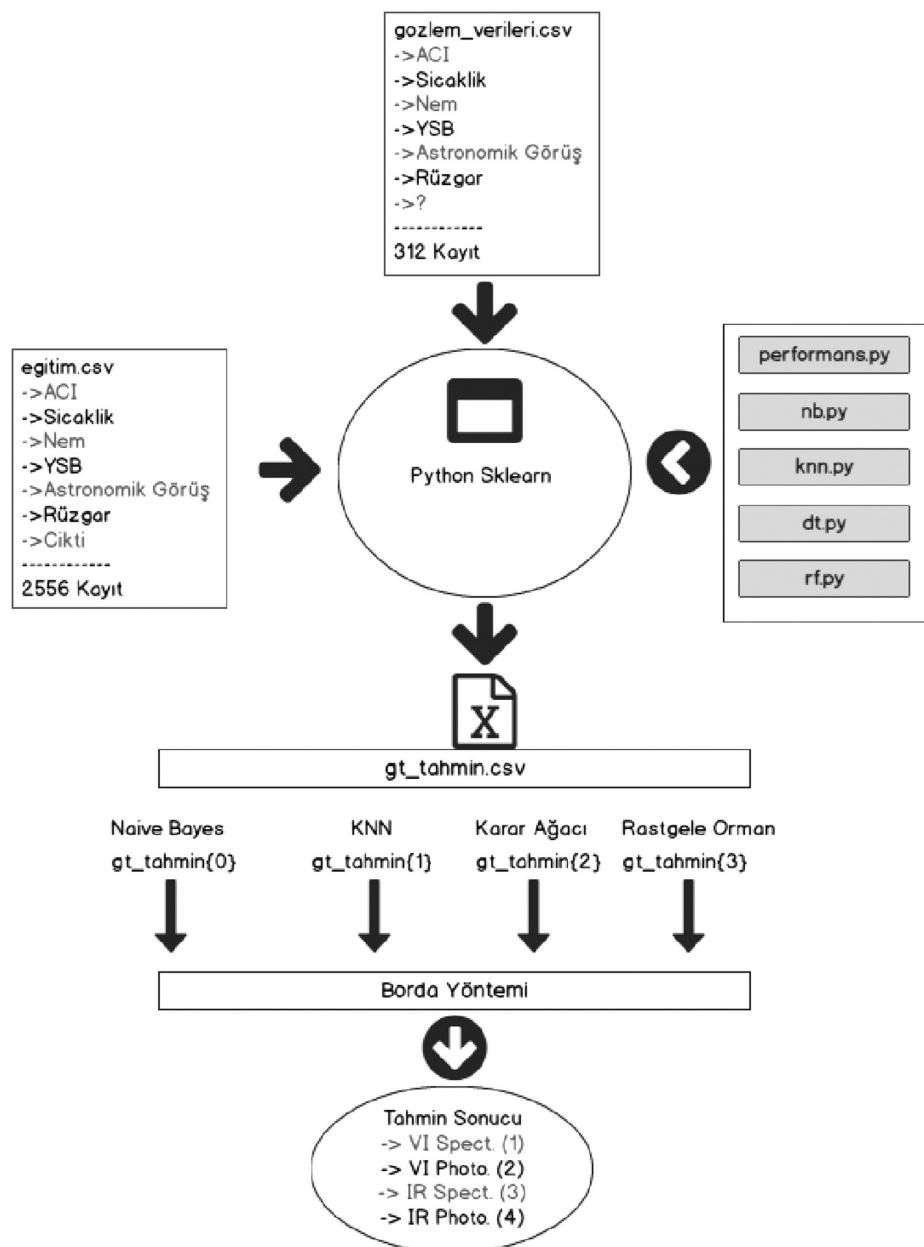
Sonrasında projelerin değerlendirilmesi amacıyla hakemlere sunulması planlanan form oluşturulmuştur. Kabul edilen her bir proje için hakem tarafından doldurulması planlanan form Şekil 6'da verilmiştir.

Hakemler tarafından değerlendirilerek sisteme kaydedilen projeler için başarı puanı hesaplanarak değerlendirilmek üzere yöneticiye sunulmaktadır. Başarı puanı hesaplanan projelerin atama işlemi, sistem yöneticisinin onayıyla gerçekleştirilmektedir. Atama işlemi sonrasında eklenen projeler "Bekleme" durumunda olup sürece dahil edilip atama işlemi tamamlanan projeler Şekil 7'de görüldüğü üzere başarı puanlarıyla birlikte yöneticiye sunulmaktadır.

MAUT yönteminden esinlenerek geliştirilen sistemde öncelikle proje değerlendirme sürecinde ele alınan kriterler, alt kriterler ve kriterlerin ağırlıkları belirlenmiştir. Sonrasında üretilen 10 adet proje değerlendirilerek önceliklendirilmiştir. Proje önceliklendirme işlemi teleskopun etkin ve verimli kullanımı amaçlanmaktadır. Mevcut sistem Php 'nin Laravel 8.64.0 frameworkü kullanılarak geliştirilmiş olup veritabanında da 10.3.28 MariaDB kullanılmıştır. Geliştirilen sistemde takip edilen adımlar veri akış diyagramı ile gösterilerek Şekil 8'de verilmiştir.

Son olarak sistem yönetici, hakemler ve araştırmacılar olmak üzere farklı kullanıcılar tarafından kullanılması planlanan sistemde yer alan kullanıcı yetkileri Şekil 9'da sunulmuştur.

Çalışmanın Giriş Bölümü'nde astronomi alanında makine öğrenmesi algoritmalarının kullanımına yönelik benzer çalışmalar Tablo 1'de sunulmuştur. Yapılan inceleme sonucunda en çok kullanılan



**Değerlendirme**

---

Proje Adı *	Proje Adı	
Proje Sahibi *	Ad	Soyad
Ağırlıklı Gözlem Zamanı *	Proje Süresi (Gün)	Gözlem Süresi (Saat)
Gözlem Türü *	Gözlem Türü Seçiniz...	
Gerekçe	<input type="checkbox"/> Olağanüstü <input type="checkbox"/> Özgün <input type="checkbox"/> Rekabetçi <input type="checkbox"/> Olağan	
İş Birliği	<input type="checkbox"/> Uluslararası <input type="checkbox"/> Ulusal <input type="checkbox"/> Tek	
Çıktı	<input type="checkbox"/> Uluslararası Makale <input type="checkbox"/> Uluslararası Bildiri <input type="checkbox"/> Tez <input type="checkbox"/> Ulusal Yayın <input type="checkbox"/> Yeni Yöntem <input type="checkbox"/> Yeni Araştırmacı ve Yeni Proje Potansiyeli	
Gözlemsel Alet Çeşitliliği	<input type="checkbox"/> Adaptif Optik <input type="checkbox"/> Tek Aygit <input type="checkbox"/> Çoklu Aygit <input type="checkbox"/> VI <input type="checkbox"/> IR	
Çıktıya Dönüşüm Süresi *	Çıktıya Dönüşüm Süresi (Ay)	

---

Kaydet

**Şekil 6.**  
Proje Değerlendirme Formu

algoritmaların Naïve Bayes, K En Yakın Komşu, Destek Vektör Makineleri, Yapay Sinir Ağları, Karar Ağacı, Rastgele Orman algoritması olduğu görülmüştür. Bu çalışmada da bu algoritmaların uygulanabilirliği test etmek amaçlanarak ön testler yapılmıştır. MATLAB Neural Network Toolbox aracılığıyla uygulanan Yapay Sinir Ağları algoritması için yüksek başarım elde edilememiştir. Ek olarak iki elemanlı veri setleri üzerinde kullanılan Vektör Destek Makineleri ve Lojistik Regresyon algoritmaları, veri seti dört farklı gözlem türü bulunmadığından sürece dahil edilmemiştir.

## Bulgular

Çalışma kapsamında astronomik gözlem türünün tahmin edilmesi amaçlanarak Naive Bayes, K En Yakın Komşu, Karar Ağacı ve Rastgele Orman algoritmaları kullanılmıştır. Bu amaç doğrultusunda uzman görüşü doğrultusunda oluşturan veri setinde yer alan giriş ve çıkış değerleri Tablo 3'te verilmiştir.

Çalışma kapsamında kullanılan veri seti 01.01.2012-30.12.2018 tarihleri arasında günlük gözlem verilerini içeren 2556 kayıttan

Proje	Yürütücü	Spektrum Tipi	Değer	Durum
Proje 1	Yürütücü 1	Visible Spectrum	95.187166	Atandı
Proje 5	Yürütücü 5	Visible Photometric	63.101604	Atandı
Proje 2	Yürütücü 3	Visible Photometric	63.151604	Atandı
Proje 3	Yürütücü 3	Infrared Photometric	64.101604	Atandı
Proje 4	Yürütücü 4	Infrared Photometric	60.101604	Atandı
Proje 11	Yürütücü 11	Visible Spectrum	95.107166	Bekleme
Proje 12	Yürütücü 12	Infrared Spectrum	90.187166	Beklemede

**Şekil 7.**  
Proje Atama İşlemi

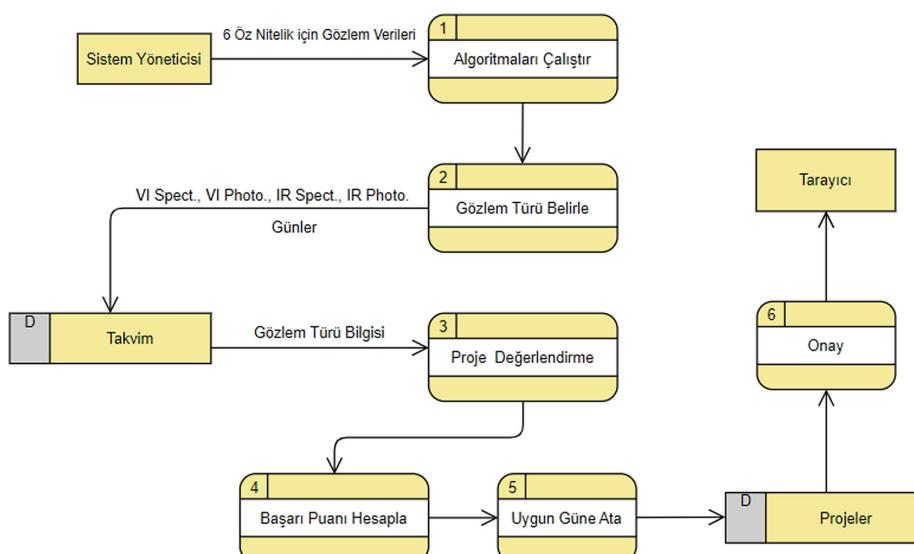
olmaktadır. Ancak ACI'nin sıfır, nemin 80'den büyük, rüzgârin 20'den büyük, astronomik görüşün üçten büyük ve sıcaklığın -25'ten küçük olduğu durumlarda gözlem yapılması mümkün görülmemektedir. Buna bağlı olarak gözlem yapılması mümkün görülmeyen 162 gün veri setinden çıkarılmıştır. Veri setinde yer alan kayıtların %70'i eğitim için %30'u da test için kullanılmıştır. Veri setinde her bir sinifa düşen veri sayısı aşağıda verilmiştir.

- VI Spectrum: 943
- VI Photometric: 470

- IR Spectrum: 55
- IR Photometric: 926

#### **İki Sınıflı Veri Seti Üzerinde Yapılan Uygulama**

Hem görsel (VI) hem de yakın kırmızı ötesi (NIR) gözlemlerinin yapılmasına imkân sağlayacak DAG teleskopu için öncelikle bu ayrılmış yapılması amaçlanarak iki sınıflı veriler üzerinden tahminler yapılmıştır. Bu doğrultuda görsel (VI) gözlem türüne 1 değeri, kızılıötesi gözlem türüne ise 2 değeri atanarak Naive Bayes, K En Yakın Komşu, Karar Ağacı ve Rastgele Orman algoritması uygulanmıştır.



**Şekil 8.**  
Veri Akış Diyagramı



**Sekil 9.**  
Kullanıcı Yetkileri

Yapılan uygulamalar 01.01.2018-30.12.2018 arasında günlük gözlem değerlerini içeren ve gözlem yapılması mümkün görülen 349 kayıt üzerinde test edilmiştir. İlk uygulamada her bir algoritma için elde edilen Doğruluk değerleri Tablo 4' te, F1 Skorları da Tablo 5'te verilmiştir.

#### Dört Sınıflı Veri Seti Üzerinde Yapılan Uygulama

VI ve IR gözlemler de kendi aralarında spektrum ve fotometrik olmak üzere ikiye ayrılmıştır. Bu ayırmaya dikkate alınarak VI Spect., VI Foto., IR Spect, IR Foto olmak üzere dört sınıfa ayrılan gözlem türlerini içeren veri seti oluşturularak tahminler yapılmıştır. İlk uygulamada olduğu gibi testler 349 kayıt üzerinden gerçekleştirilemiştir.

**Tablo 3.**  
Astronomik Gözlem Türüne Etki Eden Faktörler

<b>Giriş Değerleri</b>	
ACI (Astronomik Açıklık Endeksi)	H (Nem)
S (Astronomik Görüş)	P (PWV-Yoğunlaşabilen Su Buharı)
T (Sıcaklık)	Rüzgâr
<b>Çıkış Değerleri</b>	
<b>İki Sınıf İçin</b>	<b>Dört Sınıf</b>
VI (Visible)	VI Spectrum (VI Spect.), IR Spectrum (IR Spect.)
IR (InfraRed)	VI Photometry (VI Foto.) IR Photometry (IR Foto.)

**Tablo 4.**  
Doğruluk Değerleri (İki Sınıf)

Algoritma	Doğruluk
Naive Bayes	0,956
K En Yakın Komşu	0,982
Karar Ağacı	0,999
Rastgele Orman	0,998

irilmiştir. Dört farklı algoritma için elde edilen Doğruluk değerleri Tablo 6'da, F1 Skorları da Tablo 7'de verilmiştir.

Tablo 6'da görüldüğü üzere ağaç yapısına sahip algoritmalarla yüksek performans elde edilse de Naive Bayes algoritması için VI Foto. (2) değerine yönelik elde edilen F1 skorunun sıfır olduğu gözlelmektedir. Bu durumun gözlem türlerine ilişkin veri setindeki dağılımın dengesiz olmasından kaynaklanması ihtimaleline karşı veri setini dengeli hale getirmek amaçlanarak çeşitli

**Tablo 5.**  
F1 Skorları (İki Sınıf)

Algoritma	F1 Skoru	
Naive Bayes	0,956	0,89
K En Yakın Komşu	0,99	0,97
Karar Ağacı	1,00	1,00
Rastgele Orman	1,00	1,00

**Tablo 6.**  
Doğruluk Değerleri (Dört Sınıf)

Algoritma	Doğruluk			
Naive Bayes	0,787			
K En Yakın Komşu		0,751		
Karar Ağacı			0,997	
Rastgele Orman				0,991

**Tablo 7.**  
F1 Skorları (Dört Sınıf)

Algoritma	F1 Skoru			
NB	0,87	0,00	0,80	0,89
KNN	0,79	0,73	0,60	0,78
DT	1,00	1,00	0,96	1,00
RF	1,00	0,98	1,00	0,99

**Tablo 8.**  
Doğruluk Değerleri (SpreadSubSample)

Algoritma	Doğruluk
Naive Bayes	0,70
K En Yakın Komşu	0,738
Karar Ağacı	0,967
Rastgele Orman	0,971

yeniden örnekleme yöntemleri uygulanmıştır. İlk olarak WEKA 3.8.5 aracılığıyla SpreadSubSample az örnekleme uygulanarak elde edilen Doğruluk değerleri Tablo 8'de, F1 Skorları da Tablo 9'da sunulmuştur.

SpreadSubSample uygulanan veri seti mevcut veri setinin rastgele alt kümesini ifade etmektedir. Tablo 8'de görüldüğü üzere Naïve Bayes algoritması ile yapılan uygulamada 2 değeri için elde edilen F1 Skoru değişiklik göstermemiştir. Buna bağlı olarak veri setine bir başka yeniden örnekleme tekniği olan SMOTE algoritması uygulanmıştır. Interpolasyona dayalı SMOTE algoritmasının dengesiz veri setine yönelik uygulamalarda başarı gösterdiği belirtilmektedir (Goy ve ark., 2019). SpreadSubSample yönteminde farklı olark SMOTE yöntemi, veri setinde yer alan kayıtların dengeli bir şekilde artırmayı amaçlayarak ele alınan kayıtların en yakın komşuları dikkate alınarak yapay kayıtlar üretir. SMOTE uygulanan veri seti üzerinde Naive Bayes algoritması ile yapılan uygulamada elde edilen F1 Skorları Tablo 10'da verilmiştir.

SMOTE uygulanan veri setinde de Naive Bayes algoritması için VI Foto. değerine ait F1 Skoru yeniden sıfır olarak hesaplanmıştır. Son olarak astronomik gözlem türüne etki eden her bir faktörün sonuç üzerindeki etkisinin belirlenmesi amaçlanarak giriş değerleri sırasıyla veri setinden çıkarılarak algoritmalar test edilmiştir. İki sınıfı veri seti üzerinde yapılan uygulamalarda en yüksek değişimin nem verilerinin çıkarılması durumunda elde edildiği görülmüştür. Nem değerlerine ilişkin kayıtların çıkarılarak yapılan uygulamalarda elde edilen Doğruluk değerleri Tablo 11'de, F1 Skorları da Tablo 12'de verilmiştir.

Dört sınıfı veri seti üzerinde yapılan uygulamalarda ise en yüksek değişimin ACI verilerinin çıkarılması durumunda elde edildiği görülmüştür. Algoritmaların Doğruluk değerlerinde düşüş görülse de dört sınıfı veri seti üzerinde Naive Bayes algoritması ile yapılan uygulamada 2 değeri için elde edilen F1 Skoru artış göstermiştir. ACI değerleri çıkarılmış veri seti ile yapılan uygulamalarda elde edilen F1 Skorları Tablo 13'te verilmiştir.

**Tablo 9.**  
F1 Skorları (SpreadSubSample)

Algoritma	F1 Skoru			
NB	0,79	0,00	0,91	0,81
KNN	0,76	0,73	0,84	0,65
DT	1,00	0,93	1,00	0,94
RF	1,00	0,97	0,97	0,95

**Tablo 10.**  
F1 Skorları (SMOTE)

Algoritma	F1 Skoru			
NB	0,78	0,00	0,97	0,80

**Tablo 11.**  
Doğruluk Değerleri (Nem Değerleri Çıkarılmış Veri Seti)

Algoritma	Doğruluk
NB	0,819
KNN	0,915
DT	0,831
RF	0,844

**Tablo 12.**  
F1 Skorları (Nem Değerleri Çıkarılmış Veri Seti)

Algoritma	F1 Skoru	
Naive Bayes	0,88	0,63
K En Yakın Komşu	0,95	0,80
Karar Ağacı	0,89	0,66
Rastgele Orman	0,89	0,58

**Tablo 13.**  
F1 Skorları (ACI Değerleri Çıkarılmış Veri Seti)

Algoritma	F1 Skoru			
NB	0,48	0,45	0,43	0,47
KNN	0,74	0,68	0,50	0,71
DT	0,44	0,59	0,47	0,47
RF	0,48	0,64	0,17	0,51

### Proje Önceliklendirme Sürecine İlişkin Bulgular

DAG teleskopunun kullanımına yönelik başvuruların değerlendirilmesinde ele alınan, uzman görüşü doğrultusunda belirlenen altı temel kriter aşağıda verilmiştir.

- Araştırmamanın Gerekçesi
- Araştırma Kapsamında İşbirliği Yapılan Kurum ve Kuruluşlar
- Araştırmamanın Çıktısı
- Ağırlıklı Gözlem Zamanı
- Çıkıtxa Dönüşme Süresi (ay)
- Gözlemsel Alet Çeşitliliği

Araştırma gerekçesi kriterine yönelik değer ölçüleri atanırken olağanüstü, özgün, rekabetçi ve olağan olmak üzere dört farklı kriter ele alınmış olup atama işleminde 10'luk sistem esas alınmıştır. İkinci kriter olan işbirlikleri de Uluslararası, Ulusal ve Tek olmak üzere üç farklı alt kriter üzerinden değerlendirilmiştir. Uluslararası işbirliğine sahip projelerin diğer projelere göre mevcut kriterler açısından daha yüksek bir öneme sahip olduğu belirtilmiştir.

Araştırmamanın olası sonuçları altı gruba ayrılarak değerlendirilmiş olup bu alt kriterler aşağıda sunulmuştur.

- Uluslararası Makale
- Uluslararası Bildiri
- Tez
- Ulusal Yayın
- Yeni Yöntem
- Yeni Araştırma ve Proje Potansiyeli

Proje süresi ve gözlem süresi üzerinden hesaplanan Ağırlıklı Gözlem Zamanı (PG) kriteri için ilgili sürelerin yüksek olması teleskopun etkin kullanımı için bir dezavantaj olarak görülmektedir. Proje süresi en fazla 365 gün, gözlem süresi de gecelik en fazla 10 saat

olacak şekilde planlanmaktadır. Ağırlıklı Gözlem Zamanı aşağıdaki formül yardımıyla hesaplanmaktadır.

$$PG_i = \frac{1}{\left( \text{Max}(PG) - \text{Min}(PG) \right) * \left( PG - \text{Max}(PG) \right)}$$

Astronomik gözlem türüne göre gözlemlerde kullanılan aletlerde çeşitlilik göstermektedir. DAG teleskopu bünyesinde gözlemsel alet çeşitliliği için belirlenen beş alt kriter aşağıda verilmiştir.

- Adaptif Optik
- Çoklu Aygit
- Tekli Aygit
- Görünür Gözlem
- Kızılıtesi Gözlem

Projelerin en fazla 24 ay içerisinde sonuclandırılması planlanmaktadır. Bu doğrultuda 1-24 arasında olması planlanan değerler belirli bir standart sapmaya sahip olacak şekilde yeniden ölçeklendirilmiştir. Çıktıya dönüşme süresinin 1-10 arası değerlere dönüştürülmesini sağlayan standardizasyon formülü aşağıda verilmiştir.

$$\text{CDS}_i = \frac{100 - (\text{CDS} * 4)}{10}$$

Son olarak kriterlere yönelik belirlenen ağırlık değerleri Tablo 14'te sunulmuştur.

Ağırlıklar belirlendikten sonra modelin test edilmesi amacıyla 10 farklı proje üretilmiştir. İlk olarak projeler gözlem türüne göre sınıflandırılmıştır. Daha sonra fayda fonksiyonuna dayalı olarak projelerin başarı puanları hesaplanmış ve projeler bu puana göre büyükten küçüğe sıralanmıştır. Son olarak aracılıkla tahmin edilen gözlem türlerine öncelik verilerek ilgili günlere atanır. Atanan değer ölçüleri yine uzman görüşü alınarak rastgele seçim yöntemiyle doğrulanmıştır. Ayrıca DAG Teleskopu henüz tamamlanmasa da Atatürk Üniversitesi'nde yer alan ATA50 Teleskopu aracılığıyla geçmiş zamanlara ait gözlemleri barındıran projeler ayırtılarak sistem üzerinden test edilmiş ve sonuçlar uzman görüşleriyle doğrulanmıştır.

### Sonuç

Bu çalışmada dört farklı makine öğrenmesi algoritması kullanılarak geleceğe yönelik astronomik gözlem türünün belirlenmesi ve bu doğrultuda projelerin değerlendirilmesi, önceliklendirilmesi MAUT yöntemine dayalı karar destek sistemi geliştirilmiştir. Bu doğrultuda Naive Bayes, K En Yakın Komşu, Karar Ağacı ve Rastgele Orman algoritmalarının astronomik gözlem türü tahmininde

uygulanabilirliği ortaya konularak gözlem türü tahminine dayalı tahmin aracı geliştirilmiştir. Sonrasında proje değerlendirme ve önceliklendirme sürecinde çok kriterli karar verme yöntemlerinin uygulanabilirliği ortaya konularak elde edilen astronomik gözlem türleri proje değerlendirme sürecine dahil edilmiştir.

Dört sınıfı veri seti üzerinde Naive Bayes algoritması ile yapılan uygulamalarda 0,78 başarıım elde edilmiştir. Ancak VI Foto. (2) gözlem türüne ait F1 Skoru sıfır olarak hesaplanmıştır. Bu durumdan yola çıkararak makine öğrenmesi algoritmalarıyla yapılan uygulamalarda Doğruluk (Accuracy) değerine ek olarak diğer performans metriklerinin hesaplanması ve değerlendirilmesi çalışmaların güvenilirliğine katkı sağlayacaktır. Ayrıca dengeli ve dengesiz veri setlerine bağlı olarak da performans metrikleri değişiklik gösterebilmektedir. Özellikle veri sayısının kısıtlı olduğu çalışmalarda yeniden örneklemeye yöntemlerinin kullanımı sürece katkı sağlayabilir. Ek olarak birden fazla algoritmanın kullanıldığı çalışmalarda her bir algoritmanın sürece dahil edilmesi amacıyla oylama yöntemlerinden faydalananmak performansa katkı sağlayacaktır.

İki sınıfı ve dört sınıfı veri setleriyle yapılan uygulamalarda ağaç yapısına sahip algoritmaların diğer algoritmalarla göre yüksek başarım gösterdiği görülmüştür. Astronomik gözlem verileri üzerinde makine öğrenmesi algoritmalarının uygulanabilirliği ortaya koymak amacıyla oluşturulan veri setinde astronomik gözlem türleri (çıkış değerleri), geçmiş dayalı gözlem bulunmadından kural tabanı yardımıyla etiketlenmiştir. Etiketleme işleminde kullanılan ağaç yapısına bağlı olarak bazı değerlerde %100 başarım elde edilmiştir. İlerleyen yıllarda DAG teleskopunun kurulmasıyla birlikte oluşturulan eğitim veri setiyle yapılan uygulamalar sonuçların güvenilirliği açısından katkı sağlayacaktır.

Dört sınıfı veri setinden ACI değerine ilişkin kayıtların çıkarılması durumunda Naive Bayes algoritmasında 2 değeri için artış görülse de diğer algoritmaların ait F1 skorlarında düşüş görülmüştür. Kural tabanı incelendiğinde ACI değerinin etiketleme işleminde önem arz ettiği görülmektedir. Fakat ilgili değerlere ilişkin kayıtlar VI Foto. gözlem türünün tahmininde olumsuz etkiye sebep olmaktadır. Naive Bayes algoritmasının yapısında her bir giriş değerinin bağımsız olduğu varsayımyi gerçek problemlerde uygun bulunmasa da genellikle yüksek başarım elde edilmektedir. Naive Bayes algoritması kullanılan çalışmalarda bağımlılıkların dikkate alınması ve bağımlı öz niteliklerin veri setinden çıkarılmasıyla performans arttırılabilir.

Bu çalışmada yapılan etiketleme işlemine bağlı olarak bulanık mantık ve kural tabanlı uzman sistem yaklaşımının kullanımı da sürece katkı sağlayabilir. Ancak ilerleyen süreçte eğitim veri setine cisimlerin parlaklık düzeyi gibi faktörlerin eklenmesi ve yapılan tahminlerin günlük değil saatlik yapılması planlanmaktadır. Bu durumda kural tabanında yer alan bulanıklıkların giderilmesi ve sürecin esnekliğinin artırılması amaçlanarak makine öğrenmesi algoritmalarından faydalanilmıştır.

Kumar (2004), çalışmasında bu çalışmadan farklı olarak Ar-Ge projelerinin değerlendirimesinde AHP yönteminden faydalılmıştır. İlerleyen süreçte DAG teleskopunun kurulmasıyla birlikte değerlendirme sürecine yeni kriterlerin eklenmesi planlanmaktadır. Bu bağlamda ilgili süreçte yeni bir kriter eklenmesi durumunda ağırlık değerlerinin güncellenmesi ve yeni kriter için değer ölçüsü atanarak sürecin aksamadan kolay bir şekilde yürütülebileceği öngörmektedir. AHP kullanımında yeni bir kriter eklenmesi durumunda ikili karşılaşmalar göz önünde bulundurularak karar matrislerinde yer alan değerlerin revize edilmesi gerekmektedir.

**Tablo 14.**  
Kriterlere Yönelik Ağırlık Değerleri

Kriter	Ağırlık
Gerekçe	0,35
İşbirliği	0,15
Çıktı	0,15
Ağırlıklı Gözlem Zamanı	0,15
Gözlemsel Alet Çeşitliliği	0,05
Çıktıya Dönüşme Süresi	0,15

Hamurcu ve Eren (2018) ise çalışmalarında proje seçiminde TOPSIS yönteminden faydalananmışlardır. AHP kullanımında belirtilen durumlara benzer şekilde TOPSIS kullanımında da eklenen her bir kriter için ağırlıklı normalize karar matrisinde yer alan değerlerin yeniden hesaplanması ve pozitif ideal, negatif ideal çözüm değerlerinin yeniden hesaplanması gerekebilmiştir. Bu sebeple önceliklendirme sürecinde zaman tasarrufu, kullanım kolaylığı ve esneklik açısından MAUT kullanımının fayda sağlayacağı söylenebilir.

Son olarak çeşitli kaynaklardan elde edilen gözlem verilerinin işlenmesi ve anlaşılmaları astroenformatik alanı açısından önemli görülmektedir. Bu çalışma kapsamında geliştirilen sistem ile uluslararası gözlemevlerinin bilim dünyasında etkin ve verimli bir şekilde kullanımına katkı sağlanması amaçlanmaktadır.

**Hakem Değerlendirmesi:** Dış bağımsız.

**Yazar Katkıları:** Fikir - E.K.; Tasarım - Ö.C.Y.; Denetleme - C.Y., E.K.; Kaynaklar - Ö.C.Y.; Veri Toplanması ve/veya İşlemesi - C.Y.; Analiz ve/veya Yorum - Ö.C.Y., E.K.; Literatür Taraması - Ö.C.Y.; Yazımı Yazan - Ö.C.Y., E.K.; Eleştirel İnceleme - E.K.

**Cıkar Çatışması:** Yazarlar, çıkar çatışması olmadığını beyan etmişlerdir.

**Finansal Destek:** Yazarlar bu çalışma için finansal destek almadıklarını beyan etmişlerdir.

**Peer-review:** Externally peer-reviewed.

**Author Contributions:** Concept - E.K.; Design - Ö.C.Y.; Supervision - C.Y., E.K.; Materials - Ö.C.Y.; Data Collection and/or Processing - C.Y.; Analysis and/or Interpretation - Ö.C.Y., E.K.; Literature Review - Ö.C.Y.; Writing - Ö.C.Y., E.K.; Critical Review - E.K.

**Declaration of Interests:** The authors declare that they have no competing interest.

**Funding:** The authors declare that this study had received no financial support.

## Kaynaklar

- Agarwal, M., Rao, K. K., Vaidya, K., & Bhattacharya, S. (2021). ML-MOC: Machine learning (kNN and GMM) based membership determination for open clusters. *Monthly Notices of the Royal Astronomical Society*, 502(2), 2582–2599. [\[CrossRef\]](#)
- Ahmazdadeh, A., Aydin, B., Georgoulis, M. K., Kempton, D. J., Mahajan, S. S., & Angryk, R. A. (2021). How to train your flare prediction model: Revisiting robust sampling of rare events. *Astrophysical Journal Supplement Series*, 254(2), 23. [\[CrossRef\]](#)
- Albayrak, A. S., & Yılmaz, S. K. (2009). Veri madenciliği: Karar ağaçları algoritmaları ve İMKB verileri üzerine bir uygulama. *Süleyman Demirel University Journal of Faculty of Economics & Administrative Sciences*, 14(1), 31–52.
- Alinezhad, A., & Khalili, J. (2019). *New Methods and Applications in Multiple Attribute Decision Making (MADM)*. (Vol. 277), Springer.
- Arsioli, B., & Dediu, P. (2020). Machine learning applied to multifrequency data in astrophysics: Blazar classification. *Monthly Notices of the Royal Astronomical Society*, 498(2), 1750–1764. [\[CrossRef\]](#)
- Balıca, Y. (2020). *Savunma Sanayi Projelerinin Analitik Hiyerarşî Süreci Yöntemi Kullanılarak Önceliklendirilmesi*. (Yüksek Lisans Tezi), Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü.
- Barchi, P., da Costa, F., Sautter, R., Rosa, R., & Carvalho, R. (2017). Improving galaxy morphology with machine learning. *Journal of Computational Interdisciplinary Sciences*, 7(3). [\[CrossRef\]](#)
- Beitia-Antero, L., Yáñez, J., & de Castro, A. I. G. (2018). On the use of logistic regression for stellar classification. *Experimental Astronomy*, 45(3), 379–395. [\[CrossRef\]](#)
- Bellinger, E. P., Angelou, G. C., Hekker, S., Basu, S., Ball, W. H., & Guggenberger, E. (2016). Fundamental parameters of main-sequence stars in an instant with machine learning. *Astrophysical Journal*, 830(1), 31. [\[CrossRef\]](#)
- Bellinger, E. P., Kanbur, S. M., Bhardwaj, A., & Marconi, M. (2020). When a period is not a full stop: Light-curve structure reveals fundamental parameters of Cepheid and RR lyrae stars. *Monthly Notices of the Royal Astronomical Society*, 491(4), 4752–4767. [\[CrossRef\]](#)
- Bluck, A. F. L., Maiolino, R., Sánchez, S. F., Ellison, S. L., Thorp, M. D., Piotrowska, J. M., Teimoorinia, H., & Bundy, K. A., & Bundy, K. A. (2020). Are galactic star formation and quenching governed by local, global, or environmental phenomena? *Monthly Notices of the Royal Astronomical Society*, 492(1), 96–139. [\[CrossRef\]](#)
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. [\[CrossRef\]](#)
- Breton, S. N., Bugnet, L., Santos, A. R. G., Sauv, A. L., Mathur, S., Palle, P. L., & Garcia, R. A. (2019). Determining surface rotation periods of solar-like stars observed by the Kepler mission using machine learning techniques. *arXiv preprint arXiv:1906.09609*.
- Broos, P. S., Getman, K. V., Povich, M. S., Townsley, L. K., Feigelson, E. D., & Garmire, G. P. (2011). A naive Bayes source classifier for X-ray sources. *Astrophysical Journal Supplement Series*, 194(1), 4. [\[CrossRef\]](#)
- Chan, M. C., & Stott, J. P. (2021). Z-sequence: Photometric redshift predictions for galaxy clusters with sequential random k-nearest neighbours. *Monthly Notices of the Royal Astronomical Society*, 503(4), 6078–6097. [\[CrossRef\]](#)
- Chastenay, P., & Riopel, M. (2019). A logistic regression model comparing astronomy and non-astronomy teachers in Québec's elementary schools. *Journal of Astronomy and Earth Sciences Education*, 6(1), 1–16. [\[CrossRef\]](#)
- Cheng, Q. B., Feng, C. J., Zhai, X. H., & Li, X. Z. (2021). Artificial neural network spectral light curve template for type Ia supernovae and its cosmological constraints. *Modern Physics Letters. Part A*, 36(21), 2150149. [\[CrossRef\]](#)
- Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21–27. [\[CrossRef\]](#)
- Curran, S. J., Moss, J. P., & Perrott, Y. C. (2021). QSO photometric redshifts using machine learning and neural networks. *Monthly Notices of the Royal Astronomical Society*, 503(2), 2639–2650. [\[CrossRef\]](#)
- Daşdemir, İ. (2012). *Orman Mühendisliği için Planlama ve Proje Değerlendirme*. Bartın Üniversitesi.
- Dillon, J. L., & Perry, C. (1977). Multiattribute utility theory, multiple objectives and uncertainty in ex ante project evaluation. *Review of Marketing and Agricultural Economics*, 45, 3–27.
- Du Buisson, L., Sivanandam, N., Bassett, B. A., & Smith, M. (2015). Machine learning classification of SDSS transient survey images. *Monthly Notices of the Royal Astronomical Society*, 454(2), 2026–2038. [\[CrossRef\]](#)
- Elyiv, A. A., Melnyk, O. V., Vavilova, I. B., Dobrycheva, D. V., & Karachentseva, V. E. (2020). Machine-learning computation of distance modulus for local galaxies. *Astronomy and Astrophysics*, 635, A124. [\[CrossRef\]](#)
- Ercire, M. (2019). *Kısa Süreli Güç Kalitesi Bozulmalarının Dalgacık Analizi ve Rastgele Orman Yöntemi ile Sınıflandırılması*. (Yüksek Lisans Tezi), Kütahya Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü.
- Gao, X. H. (2016). An application of the k-th nearest neighbor method to open cluster membership determination. *Research in Astronomy and Astrophysics*, 16(12), 184. [\[CrossRef\]](#)
- Garton, T. M., Jackman, C. M., Smith, A. W., Yeakel, K. L., Maloney, S. A., & Vandegriff, J. (2021). Machine learning applications to Kronian magnetospheric reconnection classification. *Frontiers in Astronomy and Space Sciences*, 7. [\[CrossRef\]](#)
- Golob, A., Sawicki, M., Goulding, A. D., & Coupon, J. (2021). Classifying stars, galaxies, and AGNs in CLAUDS+ HSC-SSP using gradient boosted decision trees. *Monthly Notices of the Royal Astronomical Society*, 503(3), 4136–4146. [\[CrossRef\]](#)
- Goy, G., Gezer, C., & Gungor, V. C. (2019). *Credit Card Fraud Detection with Machine Learning Methods*. In 4th International Conference on

- Computer Science and Engineering (UBMK), 2019 (pp. 350–354). IEEE Publications.
- Hamurcu, M., & Eren, T. (2018). Kamu Kurumunda Bulanık TOPSIS Yaklaşımı ile Proje Seçimi için bir Grup Karar Verme Uygulaması. *Transist 11 Uluslararası Ulaşım Teknolojileri sempozyumu ve Fuarı*, 08-10 Kasım 2018, İstanbul, Türkiye, 11–20.
- Hartley, P., Flamary, R., Jackson, N., Tagore, A. S., & Metcalf, R. B. (2017). Support vector machine classification of strong gravitational lenses. *Monthly Notices of the Royal Astronomical Society*, 471(3), 3378–3397. [\[CrossRef\]](#)
- Huang, C., Ma, Y. H., Zhao, H. B., & Lu, X. P. (2016). Spectral classification of asteroids by random forest. *Acta Astronomica Sinica*, 57(5), 526–533.
- Jin-Meng, Y., Xiao-Qing, W., & Min, Z. (2021). The regression of effective temperatures in APOGEE and LAMOST. *New Astronomy*, 86, 101568. [\[CrossRef\]](#)
- Korsós, M. B., Erdélyi, R., Liu, J., & Morgan, H. (2021). Testing and validating two morphological flare predictors by logistic regression machine learning. *Frontiers in Astronomy and Space Sciences*, 7, 113. [\[CrossRef\]](#)
- Kügler, S. D., Polsterer, K., & Hoecker, M. (2015). Determining spectroscopic redshifts by using k nearest neighbor regression-I. *Astronomy and Astrophysics*, 576, A132. [\[CrossRef\]](#)
- Kumar, S. S. (2004). AHP-based formal system for R&D project evaluation. *Journal of Scientific and Industrial Research (JSIR)*, 63(11), 888–896.
- Liu, C., Deng, N., Wang, J. T. L., & Wang, H. (2017). Predicting solar flares using SDO/HMI vector magnetic data products and the random forest algorithm. *Astrophysical Journal*, 843(2), 104. [\[CrossRef\]](#)
- Lochner, M., McEwen, J. D., Peiris, H. V., Lahav, O., & Winter, M. K. (2016). Photometric supernova classification with machine learning. *Astrophysical Journal Supplement Series*, 225(2), 31. [\[CrossRef\]](#)
- Lopes, Y. G., & de Almeida, A. T. (2015). Assessment of synergies for selecting a project portfolio in the petroleum industry based on a multi-attribute utility function. *Journal of Petroleum Science and Engineering*, 126, 131–140. [\[CrossRef\]](#)
- Luken, K. J., Norris, R. P., & Park, L. A. F. (2019). Preliminary results of using k-nearest-neighbor regression to estimate the redshift of radio-selected data sets. *Publications of the Astronomical Society of the Pacific*, 131(1004), 108003. [\[CrossRef\]](#)
- Marton, G., Tóth, L. V., Paladini, R., Kun, M., Zahorecz, S., McGehee, P., & Kiss, C. (2016). An all-sky support vector machine selection of WISE YSO candidates. *Monthly Notices of the Royal Astronomical Society*, 458(4), 3479–3488. [\[CrossRef\]](#)
- Mucesh, S., Hartley, W. G., Palmese, A., Lahav, O., Whiteway, L., Bluck, A. F. L., Alarcon, A., Amon, A., Bechtol, K., Bernstein, G. M., Carnero Rosell, A., Carrasco Kind, M., Choi, A., Eckert, K., Everett, S., Gruen, D., Grudendl, R. A., Harrison, I., Huff, E. M., Kuropatkin, N., ..., Wilkinson, R. D. (2021) A machine learning approach to galaxy properties: Joint redshift–stellar mass probability distributions with Random Forest. *Monthly Notices of the Royal Astronomical Society*, 502(2), 2770–2786. [\[CrossRef\]](#)
- Niederhausen, H. (2018). Measurement of the High Energy Astrophysical Neutrino Flux Using Electron and Tau Neutrinos Observed in Four Years of Icecube Data. (Doctoral Dissertation), State University of New York at Stony Brook.
- Norris, R. P. (2017). Discovering the unexpected in astronomical survey data. *Publications of the Astronomical Society of Australia*, 34. [\[CrossRef\]](#)
- Pawlak, M., Pejcha, O., Jakubčík, P., Jayasinghe, T., Kochanek, C. S., Stanek, K. Z., Shappee, B. J., Holoiien, T. W., Thompson, T. A., Prieto, J. L., Dong, S., Shields, J. V., Pojmanski, G., Britt, C. A., & Will, D., Holoiien, T. W., Thompson, T. A., Prieto, J. L., Dong, S., Shields, J. V., Pojmanski, G., Britt, C. A., & Will, D. (2019). The ASAS-SN catalogue of variable stars—IV. Periodic variables in the APOGEE survey. *Monthly Notices of the Royal Astronomical Society*, 487(4), 5932–5945. [\[CrossRef\]](#)
- Petrusevich, D. (2020). Investigation of pulsar stars astronomical dataset by means of machine learning algorithms. *International Multidisciplinary Scientific Geoconference: SGEM*, 20(2.1), 199–206.
- Saux, A. L., Bugnet, L., Mathur, S., Breton, S. N., & Garcia, R. A. (2019). Automatic classification of K2 pulsating stars using machine learning techniques. *SF2A*. [arXiv:1906.09611v1](#).
- Sharma, K., Singh, H. P., Gupta, R., Kembhavi, A., Vaghmare, K., Shi, J., Zhao, Y., Zhang, J., & Wu, Y., Zhang, J., & Wu, Y. (2020). Stellar spectral interpolation using machine learning. *Monthly Notices of the Royal Astronomical Society*, 496(4), 5002–5016. [\[CrossRef\]](#)
- Smal, K. A. (1998). *Project Evaluation*. The University of California Transportation Center. Retrieved from <https://escholarship.org/uc/item/3ff1w6pr>.
- Teimoorinia, H., Jalilkhany, M., Scudder, J. M., Jensen, J., & Ellison, S. L. (2021). A reassessment of strong line metallicity conversions in the machine learning era. *Monthly Notices of the Royal Astronomical Society*, 503(1), 1082–1095. [\[CrossRef\]](#)
- Vavilova, I. B., Dobrycheva, D. V., Vasylenko, M. Y., Elyiv, A. A., Melnyk, O. V., & Khramtsov, V. (2021). Machine learning technique for morphological classification of galaxies from the SDSS-I. Photometry-based approach. *Astronomy and Astrophysics*, 648, A122. [\[CrossRef\]](#)
- Wang, Z., Zhang, S., & Kuang, J. (2010). A dynamic MAUT decision model for R&D project selection. In International Conference on Computing, Control and Industrial Engineering, 5–6 June 2010, Wuhan, China, (pp. 423 –427). IEEE Publications.
- Yavuz, Ö. Ç., & Karaman, E. (2021). Astronomik gözlem kalitesi tahmininde makine öğrenmesi algoritmalarının kullanımı. *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 5(1), 12–19.
- Yavuz, Ö. Ç., Karaman, E., & Yeşilyaprak, C. (2021). *Doğu Anadolu Gözlemevi Teleskopu için Astronomik Gözlem Türü Belirlenmesi*. 8th International Management Information Systems Conference (IMISC2021), İstanbul, Türkiye.
- Yesuf, H. M., Faber, S. M., Koo, D. C., Woo, J., Primack, J. R., & Luo, Y. (2020). The activation of galactic nuclei and their accretion rates are linked to the star formation rates and bulge-types of their host galaxies. *Astrophysical Journal*, 889(1), 14. [\[CrossRef\]](#)
- Yılmaz, Z. (1980). Proje değerlendirme yöntemleri. *Bursa Üniversitesi İktisadi ve Sosyal Bilimler Fakültesi Dergisi*, 1(2), 51–62.

## Extended Summary

### Background

The type of astronomical observation varies depending on parameters such as temperature, humidity, wind, cloud, condensable water vapor, and astronomical sight. These observations can be made both for different purposes and different devices to examine all celestial bodies (stars, planets, satellites, galaxies, etc.). Estimating the type of prospective observation from historical observation data will ensure an effective and efficient observation process. In this context, it is aimed to predict the type of observation with naïve Bayes, K nearest neighbor, decision tree, and random forest algorithms. Afterward, it is aimed to develop and implement a decision support system for the evaluation and prioritization of projects, taking into account the observation time, observation period, observation purpose, and project evaluation criteria.

### Methods

Within the scope of the study, first of all, the performance metrics obtained by applying naïve Bayes, K nearest neighbor, decision tree, and random forest algorithms to the data set created in line with the expert opinion were revealed, and the performances for the balanced-unbalanced data set were compared. In addition, each attribute was extracted from the data set and tested with the aim of determining the effect of each attribute on the result. Finally, a decision support system for project evaluation and prioritization was developed, inspired by the multi-attribute utility theory (MAUT) method, and implemented for 10 randomly generated projects. In the system, which was inspired by the MAUT method, first of all, the criteria, sub-criteria, and the weights of the criteria were determined in the project evaluation process. Afterward, 10 projects produced were evaluated and prioritized. With the project prioritization process, it is aimed to use the telescope effectively and efficiently. The current system was developed using Hypertext Preprocessor (PHP) Laravel 8.64.0 framework, and 10.3.28 MariaDB was used in the database.

### Results

Machine learning algorithms used in applications where data sets with different class numbers are used showed higher performance than similar studies in the literature. However, in the application made with the naïve Bayes algorithm with the four-class dataset, VI Photo (2) observation type, sufficient results could not be obtained. For this reason, performance metrics were compared by applying resampling methods to the data set. In addition, features were extracted from the data set, respectively, and the results were evaluated. When records related to ACI values were removed from the four-class data set, the accuracy of the algorithms decreased, but the f1 score for VI Photo increased. In addition, the MAUT method steps followed in the development process were explained, and the criteria, sub-criteria, and criterion weights that were handled in the project evaluation process determined in line with the expert opinion were mentioned.

### Discussion and Conclusion

In the application made with the naïve Bayes algorithm on the four-class data set, the f1 score of the VI Photo (2) observation type was calculated as zero. Based on this situation, the calculation and evaluation of other performance metrics in addition to the accuracy in applications made with machine learning algorithms will contribute to the reliability of the studies. In addition, performance metrics may vary depending on balanced and unbalanced data sets. The use of resampling methods can contribute to the process, especially in studies where the number of data is limited. In addition, in studies where more than one algorithm is used, using voting methods to include each algorithm in the process will contribute to performance.

In the literature, unlike this study, it is seen that AHP (Analytic Hierarchy Process) and TOPSIS (Technique for Order Preference by Similarity to Ideal Solution) methods are also used in the project evaluation process. In the future, it is planned to add new criteria to the evaluation process with the establishment of the DAG (Eastern Anatolia Observatory) telescope. In this context, if a new criterion is added to the relevant process, it is foreseen that the process can be carried out easily without interruption by changing the weight values and assigning a value to measure the new criterion. In case of adding a new criterion in the use of AHP, the values in the decision matrices should be revised by considering the pairwise comparisons. Similar to the situations stated in the AHP usage, it may be necessary to recalculate the values in the weighted, normalized decision matrix and recalculate the positive ideal and negative ideal solution values for each criterion added in the use of TOPSIS. For this reason, it can be said that the use of MAUT will be beneficial in terms of time-saving, ease of use, and flexibility in the prioritization process.