



**Makale / Research Paper**

**Makine Öğrenmesi Temelli Müzik Türü Sınıflandırma ve Öneri Sistemi**

**Pınar YILMAZ, Şeyma AKÇAKAYA, Şule Deniz ÖZKAYA, Aydın ÇETİN**

Gazi Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü. Ankara/TÜRKİYE  
pinar3ylmzz@gmail.com, seymakcakaya05@gmail.com, suledenizz05@gmail.com, acetin@gazi.edu.tr

**Received/Geliş:** 23.11.2022

**Accepted/Kabul:** 04.12.2022

**Öz:** Müzik insan yaşamında önemli bir yere sahiptir. İnternetin yaygın kullanımı müzik endüstrisinde önemli değişikliklere ve gelişmelere neden olmuştur. Gelişmelere örnek olarak çevrimiçi müzik dinleme ve satış platformlarının artması ve yaygın kullanılması, bu platformların sürekli güncellenmesi ve müzik türü sınıflandırılması verilebilir. Müzik türü sınıflandırması müzik öneri sistemi için önemli bir adımdır. Müziğin bireysel olarak sınıflandırılabilmesi için çok fazla şarkı dinlenmesi ve türünün seçilmesi gerekir. Bu zaman kaybı olmakla birlikte zor bir işlemdir. Bu çalışmada, makine öğrenmesi algoritmaları kullanarak müzik türlerine göre sınıflandırmak ve kullanıcıya benzer türde müzik önerilmesi amaçlanmıştır. Bu amaçla, müzik dosyalarının dijital sinyal işleme teknikleriyle öznitelikleri çıkarılmış ve elde edilen özniteliklerle makine öğrenmesi algoritmaları da kullanılarak müzik türleri otomatik olarak algılanmış ve öneri sistemi geliştirilmiştir. Çalışmada kullanılan GTZAN veri seti seçilmiştir. Jupyter Notebook ortamında sekiz farklı makine öğrenmesi modeli eğitilmiş ve bulgular karşılaştırılmıştır. Bu amaçla veri seti %80 eğitim, %20 test olmak üzere ikiye ayrılarak modellerin doğruluk oranlarına bakılmıştır. Test edilen modeller arasında en başarılı sonuç %91,792 doğruluk oranıyla XGBoost algoritması ile elde edilmiştir.

**Anahtar Kelimeler:** Müzik, Sınıflandırma, Makine Öğrenmesi.

**Machine Learning Based Music Genre Classification and Recommendation System**

**Abstract:** Music has an important role in daily life. The widespread use of the Internet has led to significant changes and developments in the music industry. The increase and widespread use of online music listening and sales platforms, the constant updating of these platforms and the classification of music genres can be given as examples of these developments. Music genre classification is an important step for the music recommendation system. In order for music to be classified by individuals require to listen to many songs and choose their genre. This is a difficult and time consuming process. In this paper, it is aimed to classify music according to its genres by using machine learning algorithms and to suggest similar types of music to the user. For this purpose, the features of the music files were extracted with digital signal processing techniques, and the music genres were automatically detected by using machine learning algorithms with the obtained features and a recommendation system was developed. The GTZAN dataset was chosen to be used in the study. Eight different machine learning models were trained in the Jupyter Notebook environment and the findings were compared. For this purpose, the data set was split into two sets as 80% training and 20% testing, and the accuracy of the models was evaluated. Among the tested models, the most successful result was obtained with the XGBoost algorithm with an accuracy rate of 91,792%.

**Keywords:** Music, Classification, Machine Learning.

*Bu makaleye atıf yapmak için*

Yılmaz P., Akçakaya Ş., Özkaya Ş.D., Çetin A., "Makine Öğrenmesi Temelli Müzik Türü Sınıflandırma ve Öneri Sistemi" El-Cezerî Fen ve Mühendislik Dergisi 2022, 9(4); 1560-1571.


*How to cite this article*

Yılmaz P., Akçakaya Ş., Özkaya Ş.D., Çetin A., "Machine Learning Based Music Genre Classification and Recommendation System" El-Cezerî Journal of Science and Engineering, 2022, 9(4); 1560-1571.

## 1. Giriş

Müzik insan yaşamında önemli bir yere sahiptir. Yapılan araştırmalara [1] göre müzik dinleyen ve müziğe maruz kalan çocukların müzik dinlemeyenlere göre daha başarılı oldukları tespit edilmiştir. Müziğin beyni zinde tuttuğu ve hafızayı güçlendirmeye yardımcı olduğu iddia edilmektedir. Müziğin ayrıca insan ruhunu dinlendirmeye ve güçlendirmeye yardımcı olduğu da kabul gören bir görüştür. İnternetin yaygın kullanımı müzik endüstrisinde önemli değişikliklere ve gelişmelere neden olmuştur. Gelişmelere örnek olarak çevrimiçi müzik dinleme ve satış platformlarının artması ve yaygın kullanılması, bu platformların sürekli güncellenmesi ve müzik türü sınıflandırılması verilebilir.

Şekil 1’de verilen grafiklerde yıllara göre Apple Music [2], ve Spotify [3] kayıtlı kullanıcı sayıları görülmektedir. Apple Music kullanıcı sayısı (a) son yılda 6 milyon, spotify (b) ücretli üye sayısında ise son bir yıl içerisinde 23 milyon artış gerçekleşmiştir. Spotify’nın global ölçekte kullanıcı sayısı 2022 yılının son çeyreğinde 456 milyona ulaşmıştır.



Şekil 1. Apple Music (a) ve Spotify (b) kayıtlı kullanıcı sayıları [2-3]

Günümüzde bu platformların gelişmesiyle insanlar her an ve her yerde müzik dinleyebilmekte, Spotify, Youtube Music, Apple Music gibi çeşitli müzik dinleme platformlarından yararlanabilmekte ve milyonlarca şarkıya ulaşabilmektedir. Açıklanan verilere [4] göre Spotify’ da şu anda 70 milyon, Youtube Music’ te ise 50 milyondan fazla şarkıya erişim sağlanabilmektedir. Spotify, Apple Music, Tidal, Amazon Music Unlimited ve You Tube Music günümüzde en yaygın kullanılan platformlar olarak karşımıza çıkmaktadır [5].

Müzik tür ve şarkı sayıları göz önüne alındığında doğal olarak sınıflandırma gereksinimi ortaya çıkmaktadır. Müzik türü sınıflandırması [6] müzik öneri sistemi için önemli bir adımdır. Sınıflandırma işleminin elle gerçekleştirilmesi için çok fazla şarkı dinlenmesi ve türünün seçilmesi gerekir. Bu zaman kaybı olmakla birlikte zor bir işlemdir. Bu nedenle müzik türü sınıflandırmasını otomatikleştirmek popüler türlerin veya tercih edilen türlerin kolayca bulunmasına yardımcı olmaktadır.

Müzik türü sınıflandırması ile ilgili olarak yapılan ilk kapsamlı çalışmalardan biri Tzanetakis ve Cook [7] tarafından gerçekleştirilmiştir. Bu çalışmada ses sinyallerinin müzik türlerine göre otomatik olarak sınıflandırılması araştırılmıştır. Bunu yaparken öncelikli olarak öznelik çıkarımı yapılmış ve daha sonra bu öznelikler K-En Yakın Komşu algoritması ve Gaussian Mixture modeli ile test edilmiştir. Çalışmada on farklı müzik türü için %61’lik bir sınıflandırma doğruluğu elde edilmiştir. Diğer bir çalışmada Li ve arkadaşları [8] yeni bir öznelik çıkarımı yöntemi olan yerel ve müzik sinyallerinin bilgilerini aynı anda yakalamak için Daubechies dalgacık histogramına

dayalı (Daubechies Wavelet Coefficient Histograms - DCWHs) bir yaklaşım önermişlerdir. Bu yeni yöntemin eski yöntemlere göre başarı yüzdesi karşılaştırılmış, bu amaçla MARYSAS (Music Analysis, Retrieval and Synthesis for Audio Signals) yazılımından yararlanılmıştır. Karatana ve yıldız [9] tarafından gerçekleştirilen çalışmada ise şarkılar, dijital ortamda, sinyal işleme yöntemleri ile incelenmiş, öznelik çıkarımı yapılmış ve makine öğrenmesi algoritmaları yardımıyla müzik türlerinin otomatik olarak algılanması gerçekleştirilmiştir. Bergstrave arkadaşları [10] müzik türü sınıflandırmak için AdaBoost sınıflayıcı, Benetos ve Kotropoulos [11] ise sınıflandırma işlemlerini otomatik olarak gerçekleştirmek için tensor tabanlı bir yaklaşım ortaya koymuşlardır. Bu çalışmaların ortak yönü GTZAN veri setini kullanmalarıdır. Aynı veri seti için önerilen algoritmaların doğruluk oranları Tablo 1’de verilmektedir.

**Tablo 1.** GTZAN veri seti kullanılan bazı çalışmaların doğrulukları

Referans	Algoritma	Doğruluk (%)
Tzanetakis et al. [6]	Gaussian Mixtures	61.00
Li et al. [7]	SVM	78.50
Karatana et al. [8]	SVM	88.90
Bergstra et al. [9]	AdaBoost	82.50
Benetos et al. [10]	SVM	75.00

Bu çalışmada, literatürde yer alan çalışmalardan farklı 6 sınıflandırma algoritmasının performansı araştırılmış, müzik türünü sınıflandırmaya ek olarak bu türde kullanıcıya müzik önerilmesi hedeflenmiştir. Şarkılar dijital ortamda sinyal işleme yöntemleri ile incelenmiş, öznelik çıkarımı yapılmış ve makine öğrenme algoritmaları kullanılarak müzik türleri otomatik olarak algılanmıştır. Çalışma için uygun veri setleri araştırılmış ve önceki çalışmalar incelenmiş [7-11], müzik türü sınıflandırma amacıyla kullanılacak veri setleri ( Tablo 2) araştırılmıştır. Çalışmada, önerilen modellerin başarımlarını kıyaslayabilmek amacıyla diğer çalışmalarda kullanılan GTZAN veri seti tercih edilmiştir.

**Tablo 2.** Araştırılan veri setleri

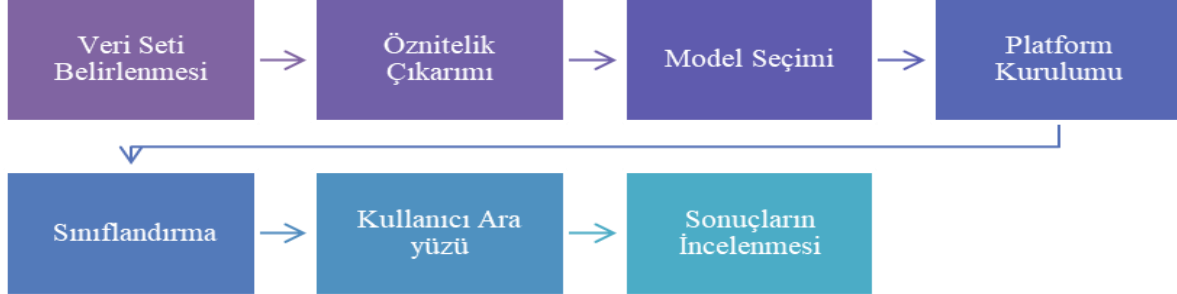
Veri Seti	Parça sayısı	Sanatçılar	Yıl
GTZAN	1000	~300	2002
Artist20	1.413	20	2007
MSD	1.000.000	44.745	2011
Dataset (songs in Spotify)	42.300	-	2020

Veri seti seçimi sonrası öznelik çıkarımı gerçekleştirilerek makine öğrenmesi algoritmaları ile sınıflandırma işlemleri gerçekleştirilmiştir. Her iki adımda da Python programlama dili ve bu dil için geliştirilmiş açık kaynaklı kütüphaneler kullanılmıştır. Geliştirme ortamı olarak ise Jupyter Notebook seçilmiştir.

Bu çalışmada, kullanılan veri setinin, makine öğrenmesi algoritmaları yardımıyla eğitilerek bir müzik türü sınıflandırma ve öneri sisteminin oluşturulmasına odaklanılmıştır. Ayrıca, sınıflayıcıların performansını arttırmak üzere farklı algoritmalar test edilerek sonuçlar literatürdeki çalışmalarla kıyaslanmıştır.

## 2. Yöntem ve Araçlar

Bu çalışmada, sisteme yüklenen müziğin makine öğrenmesi yöntemleri kullanılarak türünün belirlenmesi ve benzer müzik önerisi sunma işlemleri gerçekleştirilmiştir. Çalışmada izlenen süreçte dair iş akış çizelgesi Şekil 2’de sunulmaktadır.



Şekil 2. İş akış çizelgesi

İş akışında, veri setinin belirlenmesini müteakip öznitelik çıkarımı yapılarak model seçimi gerçekleştirilmiştir. Daha sonra bu model platform üzerinden eğitilerek sınıflandırma başarımları değerlendirilmiş ve sonuçlar bir kullanıcı arayüzü üzerinden incelenmiştir.

### 2.1 Veri Seti

Çalışmada araştırılan yöntemlerin başarımlarını Tablo 1’de sunulan diğer çalışmalarla karşılaştırmak üzere GTZAN [7] veri seti seçilmiştir. GTZAN, G. Tzanetakis tarafından önerilen müzik sinyal işlemede en yaygın kullanılan veri setidir. Bu veri setinde toplam on müzik türü yer almaktadır. Bunlar: blues, klasik, country, disko, hip-hop, caz, metal, pop, reggae ve rock türleridir (Tablo 3). GTZAN veri setinde 2 farklı .csv dosyası vardır. İlk .csv dosyasında her türden, 30 saniye uzunluğunda 100 tane ses dosyası bulunmaktadır. “Parçaların tümü .wav formatında 22050Hz Mono 16 bit ses dosyalarıdır” [12]. Diğer .csv dosyası da aynı yapıya sahiptir ancak şarkılar 3 saniyelik ses dosyalarına ayrılarak oluşturulmuştur.

Tablo 3. GTZAN veri seti içeriği


	Tür	Miktar
1	Blues	100
2	Classical	100
3	Country	100
4	Disco	100
5	Hiphop	100
6	Jazz	100
7	Metal	100
8	Pop	100
9	Reggae	100
10	Rock	100
	<b>Toplam</b>	<b>1000</b>

## 2.2 Öznitelik Çıkarımı

Müzik sınıflandırma işlemlerinde yaygın olarak Timbral doku özellikleri kullanılmaktadır [15]. Çalışmada, Sıfır Noktasını Geçme Oranı, Harmonikler, Algısal, Spektral Ağırlık Merkezi, Spektral Etek, Mel Frekansı, Chroma Frekansı ve Kepstral katsayıları öznitelikler olarak belirlenmiştir. Özniteliklere ait temel karakteristik özellikler aşağıda sırasıyla sunulmuştur.


- Sıfır Noktasını Geçme Oranı (Zero Crossing Rate): Bir ses sinyalinin ardışık iki değerinin farklı işaretlere sahip olduğu durumlara Sıfır Noktasını Geçme Oranı adı verilir. Bu durumun gözüktüğü anlar toplamının, zamana oranı Sıfır Noktasını Geçme Oranı'ını verir. Bu özellik sinyalin frekansını belirlemenin en basit yollarından biridir ve sinyalin spektral özelliklerinin tahmin edilmesinde fayda sağlar [9].
- Harmonikler (Harmonics): İnsanların ayırt edemediği özelliklerdir. Ses rengini temsil eder.
- Algısal (Perceptual): Şok dalgası, ses ritmini ve duyguyu temsil eder.
- Spektral Ağırlık Merkezi (Spectral Centroid): Spektrumun kütle merkezini ifade eder. Ses sinyalinin izgesel gösteriminin denge noktası olarak da ifade edilir [9].
- Spektral Etek (Spectral Rolloff): Rolloff, spektral şeklin ölçüsüdür. Spektrumdaki dağılımın belirli bir oranına karşılık gelen frekans değeri olarak tanımlanır[9].
- Mel Frekansı Kepstral Katsayıları (Mel-Frequency Cepstral Coefficients): Mel frekans ölçeklendirmesine dayalı spektral özelliklerin temsildir [13].
- Chroma Frekansı (Chroma Frequencies): Spektrumun müzikal oktavin 12 farklı yarım tonunu temsil eden 12 kutuya yansıtıldığı müzik sesi için güçlü bir temsildir [14].
- Kepstral katsayılar doğrusal ölçeklidir ancak insan 1Khz'in altındaki frekansları doğrusal ölçekli, üstündeki frekansları ise logaritmik ölçekli olarak duymaktadır. MFCC'nin kullanım amacı kepsral katsayıların, insan işitme sistemiyle uyumlu hale getirmektir [9].

Öznitelik çıkarımında, müzik ve ses analizi için açık kaynaklı Librosa [15] kütüphanesi kullanılmıştır. Bu aşamada veri setindeki sinyallerin öndeki ve sondaki sessizlik kırılmıştır. Veri setinden rastgele bir örnek seçilmiş, seçilen şarkının ses dalgası ( Şekil 3) oluşturulmuştur.




Şekil 3. Seçilen örneğin ses dalgası grafiği

Short Time Fourier (STF) dönüşümü kullanılarak Reggea40 numaralı örnek için zamana ve frekansa göre karmaşık genliği tanımlanmıştır. Reggea40 numaralı örneğin STF dönüşümü Şekil 4 'de görülmektedir.




Şekil 4. Reggea40 numaralı örnek için STF dönüşümü

Fourier dönüşüm işleminden sonra genlik spektrogramı, desibel ölçekli spektrograma dönüşümü yapılmış ve elde edilen spektrogram ( Şekil 5) incelenmiştir.



Şekil 5. . Reggea40 numaralı örnek için Spektrogram incelenmesi

Sınıflandırma aşamasından önce verilerin ölçeklendirilmesi yapılmış, standartlaştırma işlemi gerçekleştirilerek veri setindeki öznitelikler indirgenmiştir. Temel bileşen analiziyle (Principal Component Analysis- PCA) tüm olası müzik tür grupları Şekil 6'daki gibi görselleştirilerek veri seti, sınıflandırma aşamasında kullanılacak duruma getirilmiştir.



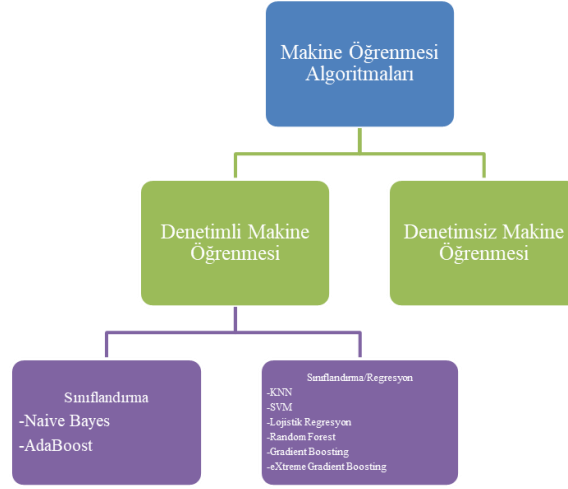
Şekil 6. Müzik türleri üzerinde temel bileşen analizi

### 2.3 Model Seçimi ve Sınıflandırma Algoritmaları

Makine öğrenmesi, matematiksel ve istatistiksel işlemler ile verilerden anlamlı bilgiler çıkararak tahminlerde bulunan sistemlerin bilgisayar ile modellenmesinin yapıldığı yapay zekâ ve bilgisayar bilimi dalıdır. Makine öğrenmesi, bünyesinde birçok farklı algoritma barındırmaktadır. Bu algoritmalar, karmaşık veri setlerinden anlamlı bilgi çıkarabilmeye ve analiz edip bir model oluşturabilmeye yardımcı olmaktadır. Makine öğrenmesi algoritmaları kendi arasında dört gruba ayrılmaktadır. Bunlar denetimli, denetimsiz, yarı denetimli ve takviyeli algoritmalarıdır. Denetimli öğrenmede, giren veriler ile çıkan veriler arasında bir bağlantı kurulur ve bunun sonucunda bir tahmin yapılır. Denetimsiz öğrenmede kümeleme işlemi gerçekleştirilir. Kullanılan veriler sınıflandırma barındırmaz. Yarı denetimli öğrenmede hem etiketli hem de etiketlenmemiş veri kullanılır. Etiketlenmemiş veriler büyük miktarda olurken etiketli veriler küçük miktarda kullanılır. Takviyeli makine öğrenmesi, geçmiş deneyimlerden yararlanır ve sonuca ulaştıracak en iyi adapte sonucu ortaya koymaktadır. Çalışmada hedeflenen sınıflandırma işlemi olduğundan dolayı denetimli algoritmalar tercih edilmiştir.

Denetimli öğrenme algoritmaları da kendi içinde ikiye ayrılmaktadır. Bunlar sınıflandırma algoritmaları ve regresyon algoritmalarıdır. Bazı algoritmalar ise hem sınıflandırma hem de regresyon mantığını kullanmaktadır (Şekil 7). Regresyon algoritmalarında, hedef olan değişken sürekli değerlerden oluşmaktadır. Bu değerler tahmin edilmeye çalışılır. Sınıflandırma algoritmalarında ise hedef değişken kategorik verilerden oluşmaktadır. Çalışmada, denetimli öğrenme algoritmaları incelenmiş ve bu amaçla en çok tercih edilen algoritmalar belirlenmiştir.

Model seçimi ile sınıflandırma işleminde kullanılacak olan makine öğrenme algoritmaları olarak; K-En Yakın Komşu, Gaussian Naive Bayes , Support Vector, Random Forest, Ada Boost ,Gradient Boosting , Lojistik Regresyon ve eXtreme Gradient Boosting algoritmaları seçilmiştir.



Şekil 7. Çalışmada seçilen ML algoritmaları

Naive Bayes Sınıflandırıcı [16] (Naive Bayes Classifier), olasılık tabanlı bir sınıflandırma algoritmasıdır. Amacı girdi verilerinin kategorisini (sınıfını) belirlemektir. Bu algoritma ile sınıflandırma yapılırken ilk işlemde belirlenen oranda eğitilmiş veri sisteme girdi olarak girer. Bu verilerin sınıfları baştan belirtilmiş olmalıdır. Girdi verileri üzerinde olasılık işlemleri yapılır. Daha sonrasında sisteme test verileri girilir ve bu test verilerinin kategorileri önceden eğitilmiş verilere uygulanan olasılık işlemlerinin sonucuna göre belirlenir

AdaBoost Sınıflandırma [17] (AdaBoost Classification), kolektif öğrenme yöntemlerinden artırma (boosting) kullanan bir sınıflandırma algoritmasıdır. Amacı zayıf sonuç getirecek birçok veriyi bir araya getirerek daha güçlü sonuç getirecek veriyi oluşturmaktır. AdaBoost ilk boosting algoritmasıdır. Eğitim veri seti öncelikle zayıf öğrenici veri seti ile eğitilir. Daha sonrasında yanlış olarak öğretilmiş olan eğitim verilerine daha fazla ağırlık verilerek sistem tekrardan eğitilir. En iyi sonuç alınana kadar işlem devam ettirilir.

K-En Yakın Komşu [18] (K- Nearest Neighbors), sınıflandırma ve regresyon işlemlerinde kullanılan bir denetimli algoritma çeşididir. Bu algoritma da öncelikle yapılacak olan işlem, bir nesnenin hangi sınıfa dahil olacağını belirlemek için kendisine yakın kaç tane komşu olacağını sayısını olan k belirlenir. Bu komşulara olan mesafe belirlenen bir yöntem ile hesaplanır. Bu k sayısına göre test edilen nesne en çok hangi sınıfa yakınsa o sınıfın üyesi kabul edilir.

Destek Vektör Makinesi [19] (Support Vector Machine), sınıflandırma ve regresyon işlemlerinde kullanılan bir algoritmadır. Çalışma mantığında önce her bir veri, belirli bir koordinatın değeri olan her bir özellik ile sahip olduğumuz özelliklerin sayısı kadar boyutlu boşluğa bir nokta olarak çizilir. Ardından en iyi sınıflandırmanın yapılabileceği bir hiper düzlem belirlenir. Daha sonra test edilen veriler bu hiper düzleme göre sınıflandırılır.

Lojistik Regresyon [20] (Logistic Regression), istatistiksel tabanlı, sınıflandırma ve regresyon işlemlerinde kullanılan bir algoritmadır. Bu algoritmanın amacı bir dizi birbirinden bağımsız değişken arasındaki ilişkiyi bulabilecek bir model oluşturmaktır.

Rassal Orman [21] (Random Forest), sınıflandırma ve regresyon işlemlerinde kullanılan bir topluluk öğrenme yöntemidir. Öğrenme sürecinden karar ağaçlarından yararlanır. Bu karar ağaçlarını oluşturduktan sonra girilen yeni test verilerinin hangi sınıfa dahil olduğuna karar verir ve sınıflandırma işlemini gerçekleştirir.

Gradyan Arttırma Sınıflandırıcı[223] (Gradient Boosting Classification), kolektif öğrenme yöntemlerinden boostingi (arttırma) kullanan bir sınıflandırma ve regresyon algoritmasıdır. Amacı tahmine dayalı modeller oluşturmaktır. Güçlü bir öğrenici veri setini oluşturmak için zayıf öğrenici veri setini birleştirerek yükseltme tekniğini kullanır. Bu sayede sınıflandırma ve regresyon işlemini yapacak en iyi model bulunur.

Ekstrem Gradyan Arttırma [23] (eXtreme Gradient Boosting Classification–XGBoost), hız ve performans için tasarlanmış olan gradyan destekli karar ağaçlarının bir uygulamasıdır. Gradient Boosting çerçevesi altında makine öğrenmesi algoritmalarını uygular.

## 2.4. Deneysel çalışma

Çalışma, Python programlama dili kullanılarak Jupyter Notebook ortamında geliştirilmiştir. Jupyter Notebook [24], çeşitli programlama dilleri için etkileşimli ortam sağlayan açık kaynak kodlu programdır. Jupyter Notebook kurulumu Anaconda Enterprise Navigator (AEN) üzerinden yapılmıştır. Kurulum için kullanılan sistem özellikleri Tablo 4. 'de verilmiştir. AEN Anaconda sunucusu, dizüstü bilgisayarların yönetimsel ön yüzüdür. Ağ geçidi ise, kullanıcıların kimliğini doğrulayan ve onları otomatik olarak projeleri için uygun AEN bilgi işlem düğümüne yönlendiren bir ters proxy'dir.

**Tablo 4.** Sistem özellikleri

	<b>Bellek</b>	<b>İşlemci</b>	<b>Depolama</b>
<b>AEN Sunucu</b>	2+ GB	2+ çekirdek	20 GB
<b>AEN Gateway</b>	2 GB	2 çekirdek	3 MB (minimal storage required)
<b>AEN Project Nodes (N-machines)</b>	2 GB	2 çekirdek	3 GB/project

Çalışmada açık kaynaklı Scikit-Learn, Pandas, Numpy ve Librosa kütüphanelerinden yararlanılmıştır.

Scikit- Learn, denetimli ve denetimsiz makine öğrenmeyi destekleyen açık kaynak kodlu bir kütüphanedir. NumPy, SciPy ve Matplotlib üzerine kuruludur. Kümeleme, sınıflandırma ve regresyon yöntemlerini içerir. Veri ön işleme, boyut küçültme, öznitelik seçme ve çapraz doğrulama olmak üzere birçok işlemi gerçekleştirmek için çeşitli araçlar sunar.

Pandas, veri işleme ve analizinde kullanılan Python dilinde yazılmış bir kütüphanedir. BSD lisansına sahiptir ve açık kaynak kodludur. Pandas kütüphanesi ile veriler hakkında istatistiksel sonuçlar elde edilir. Farklı türlerdeki dosyaları (“.csv”, “.text”) okumak, veri seti boyutlandırılması gibi birçok işlemi gerçekleştirmek için kullanılır. Pandas, Matplotlib ve Numpy olmak üzere iki temel kütüphane üzerine kurulmuştur. Matplotlib kütüphanesi, veri görselleştirme için; Numpy



kütüphanesi, matematiksel işlemler için kullanır. Pandas kütüphanesi, Numpy ve Matplotlib yöntemlerini daha az kodla erişilmesini sağlar.

Numpy, açık kaynaklı, BSD lisansına sahip Python kütüphanesidir. Bilimsel hesaplamalar için kullanılır. Çok boyutlu diziler, matrisler üzerinde matematiksel ve mantıksal, şekil işleme, sıralama ve seçme işlemleri için araçlar sağlar. Lineer cebir, istatistiksel işlemler ve Fourier dönüşümleri için de kullanılır. Numpy, özünde önceden derlenmiş, optimize edilmiş C kodu barındırır. Derlenmiş kodlar sayesinde performans yükselir. Çeşitli donanım ve bilgi işlem platformlarını destekler.

Librosa müzik ve ses analizinde kullanılan Python paketidir. Açık kaynaklı ve ISC lisanslıdır. Kısa ses parçalarının işlenmesi için geliştirilmiştir. Ses bölümlerinden ritim, tempo ve vuruş gibi ses özelliklerini belirlemek için kullanılır. Librosa, ses sinyallerinin görselleştirilmesinde ve ses özelliklerinin çıkarımı işlemleri için araç sağlar. Bu kitaplık ile diskten ses yükleme, spektrogram temsillerini hesaplama, harmonik-vurmali kaynak ayırma, gibi işlemler gerçekleştirilir.

## 2.5. Kullanıcı Arayüzü

İstenilen makine öğrenmesi yöntemi seçilerek sınıflandırma yapılması ve o müzik türünde müzik önerilmesi için Python' da bir grafik kullanıcı ara yüzü tasarlanmıştır. Python' da ara yüz tasarlamak için PyQt5 kütüphanesi kullanılmıştır. Öncelikle bir form oluşturulmuş, formun içine de etiketler, butonlar ve comboBox eklenmiştir ( Şekil 8).

Kullanıcı arayüzü üzerinden sisteme müzik yüklenebilir, yüklü olan bir müzik dinlenebilir. Makine öğrenmesi yöntemi seçilerek hangi algoritma kullanılacağı seçilip sınıflandır butonu ile müzik türü sınıflandırması yaptırılabilir, seçilen yöntemin hangi doğruluk oranında sınıflama yaptığı izlenebilir ve şarkı öner butonu ile yüklenen müzik türüne yakın müzikler listelenebilir.

Öneri sistemdeki ilk aşama da veri seti bir veri tabanına dönüştürülmüş ve sisteme yüklenmiştir. Scikit- Learn kütüphanesi yardımı ile model oluşturulmuştur. Yüklenen müziğin öznelikleri kullanarak eğitim işlemi tamamlanmıştır. Öneri işlemi için müzik türüne uygun müzikler belirlenmiştir. Ve bu müziklerden 5 tanesinin ismi ekranda kullanıcıya sunulmuştur.



Şekil 8. Kullanıcı arayüzü

Şekil 8'da görüldüğü üzere kullanıcı istediği herhangi bir müziği yükleyebilmekte ve istediği makine öğrenmesi yöntemi seçerek müziğin türünü sınıflandırabilmektedir. Aynı zamanda şarkı öner butonu ile seçilen türünde ve türüne yakın müzikler önerilmektedir. Yapılan kullanıcı testlerine

göre türü caz olan bir müzik sisteme yüklenip sınıflandırılmıştır. Yüklenen şarkıya benzer olarak klasik türdeki şarkıların da önerildiği gözlemlenmiştir.

### 3. Bulgular ve Değerlendirme

Çalışmada 8 algoritma ele alınmış, eğitim sonucunda performansı yüksek olan algoritmalar belirlenmiştir. Algoritmaların sisteme dâhil edilmesi ve veri setinin eğitilmesi için bir fonksiyon oluşturulmuş, oluşturulan bu fonksiyon modeli, sisteme entegre edilmiş ve veri seti eğitilmiştir. Veri seti eğitim ve test verisi olmak üzere ikiye ayrılmıştır.

Her bir model için elde edilen doğruluk oranları karşılaştırılmış ve en iyi doğruluk oranına sahip algoritma belirlenmiştir. Veri seti ayırma oranları ve doğruluk oranları Tablo 5’ de verilmiştir. Eğitim setinin test setine oranı düşürüldüğünde doğruluk oranlarının düştüğü gözlemlenmiştir. Çalışmada, KNN ile XGBoost her iki test grubunda da %90 üzerinde doğruluk elde etmiştir.

**Tablo 5.** Model eğitim test sonuçları

Eğitim/Test Verisi Oranları	80 % Eğitim - 20 % Test	70 %Eğitim - 30 % Test
<b>Kullanılan Algoritmalar</b>		
Naive Bayes	0,52302	0,51952
<b>KNN</b>	<b>0,91592</b>	<b>0,91204</b>
RandomForest	0,89089	0,87688
SVM	0,75976	0,75475
Logistic Regresyon	0,70120	0,69770
Gradient Boosting	0,83584	0,83483
Adaboost	0,49149	0,46480
<b>XGBoost</b>	<b>0,91792</b>	<b>0,90224</b>

### 4. Sonuç ve Öneriler

Gerçekleştirilen çalışmada müzik türü sınıflandırma ve öneri sisteminin yapılması amaçlanmıştır. Müziğin günlük yaşamda kullanılmasının artması ile müzik türü sınıflandırma çalışmaları da yaygınlaşmıştır. Müzik türü sınıflandırma öneri sistemi için önemli bir adımdır.

Çalışma iki temel aşamada gerçekleştirilmiştir: Öznitelik çıkarımı ve öneri sistemi. Yapılan çalışmada ilk olarak sınıflandırma işleminde ve öneri sisteminde kullanılacak öznitelikler, veri setindeki öznitelik değerlerine bakılarak belirlenmiş ve çıkarılmıştır.

Veri ilk olarak %80 eğitim, %20 test olmak üzere ikiye ayrılıp doğruluk oranlarına bakılmıştır. Karşılaştırma yapılması için veri %70 eğitim, %30 test olmak üzere ikiye ayrılıp tekrar eğitilmiş ve sonuçlara bakılmıştır. Tablo 6’da görüldüğü üzere veri %80-%20 oranında ayrıldığında daha yüksek doğruluk oranına erişilmiştir. Aynı tablo incelendiğinde en yüksek doğruluk oranına XGBoost algoritması ile ulaşılmıştır. XGBoost algoritmasından sonra en yüksek doğruluk oranını KNN algoritması sağlamıştır.

**Tablo 6** Diğer çalışmalarla karşılaştırma

Referans	Algoritma	Doğruluk Oranı
Tzanetakakis et al. [6]	Gaussian Mixtures	61.00%
Li et al. [7]	SVM	78.50%
Karatana et al. [8]	SVM	88.90%
Bergstra et al. [9]	AdaBoost	82.50%
Benetos et al. [10]	SVM	75.00%
Önerilen Çalışma	<b>XGBoost</b>	<b>91.72%</b>

Yapılan diğer çalışmalarla kıyaslandığında müzik türü sınıflandırmanın yanı sıra bu çalışmada öneri sistemi de bulunmaktadır. Aynı zamanda Tablo 4.1 'de görüldüğü üzere daha önceden elde edilen doğruluk oranlarında %3 üzerinde iyileşme sağlanmıştır.

Gelecekteki çalışmalarda, özniteliklerin etkileri daha kapsamlı şekilde ele alınarak üst düzey öznitelik çıkarma yöntemleri üzerine çalışılabilir. Derin öğrenme yöntemleri yüksek performanslı hesaplama mimarilerine ihtiyaç duyduğu için projenin ilerideki gelişimi açısından kullanılabilir. Günümüzde, kullandığımız veri setine göre daha fazla müzik türü ve şarkı bulunduğu için veri setine daha fazla tür ve müzik eklenip uygulamanın kullanılabilirliği artırılabilir.

### Yazarların Katkıları

Kavramsal tasarım, P.Y, Ş.A, ve DŞ.Ö tarafından gerçekleştirildi. Yöntem, A.Ç tarafından belirlendi ve analiz, araştırma kaynak çalışmaları ile veri seti temini P.Y, Ş.A, ve DŞ.Ö tarafından gerçekleştirildi. Yazılım geliştirme, Ş.A, ve DŞ.Ö; doğrulama ve geçerleme işlemleri P.Y ve A.Ş. tarafından gerçekleştirildi. Makale yazımı ve görselleştirme işlemleri P.Y, Ş.A, ve DŞ.Ö, makale inceleme ve düzeltme işlemleri ile danışmanlık A.Ç tarafından yapıldı. Tüm yazarlar makalenin son halini okudu ve onayladı.

### Çıkar Çatışması

Yazarlar, çıkar çatışması olmadığını beyan eder.

### Kaynaklar

- [1]. Brown, L. L. "The benefits of music education." PBS KIDS for Parents, 2012.
- [2]. İnternet: Number of Apple Music subscribers worldwide from October 2015 to June 2021, 2022, <https://www.statista.com/statistics/604959/number-of-apple-music-subscribers/>, Erişim Tarihi: Kasım 2022
- [3]. İnternet: Number of Spotify premium subscribers worldwide from 1st quarter 2015 to 3rd quarter 2022, 2022, <https://www.statista.com/statistics/244995/number-of-paying-spotify-subscribers/> Erişim Tarihi: Kasım 2022
- [4]. İnternet: Spotify Investors Quick Facts, 2021, <https://investors.spotify.com/home/default.aspx>, Youtube Offical Blog, 2020, <https://blog.youtube/news-and-events/youtube-music-transfer-google-play-music-library/>, Erişim Tarihi: Ocak 2022
- [5]. İnternet: The 5 best music streaming services you can subscribe to in 2022, <https://www.businessinsider.com/guides/tech/best-music-streaming-service-subscription>, Erişim Tarihi: Kasım 2022

- [6]. İnternet: Music Genres List, <https://www.musicgenreslist.com/>, Erişim Tarihi: Kasım 2022
- [7]. Tzanetakis, G., Cook, P. "Musical genre classification of audio signal", IEEE Transactions on Speech and Audio Processing, Vol. 10, No. 3, pp. 293-302, July 2002.
- [8]. Li, T., Ogihara, M., Li, Q. "A comparative study on content-based music genre classification", SIGIR '03 Proceedings of the 26th annual international ACM SIGIR conference on Research and development in informaion retrieval, pp. 282-289, 2003.
- [9]. Karatana, A., Yildiz, O. "Music genre classification with machine learning techniques," in Signal Processing and Communications Applications Conference (SIU), 2017 25th, IEEE, 2017, pp. 1-4.
- [10]. Bergstra, J., Casagrande, N., Erhan, D., Eck, D., Kegl, B. "Aggregate features and AdaBoost for music classification", Machine Learning, Vol. 65, No. 2-3, pp. 473-484, 2006.
- [11]. Benetos, E., Kotropoulos C. "A tensor-based approach for automatic music genre classification", Proceedings of te European Signal Processing Conference, Lausanne, Switzerland, 2008
- [12]. İnternet: Tensorflow GTZAN Description, 2021, <https://www.tensorflow.org/datasets/catalog/gtzan>, Erişim Tarihi: Ocak 2022
- [13]. Banitalebi-Dehkordi, M., Banitalebi-Dehkordi, A. "Music Genre Classification Using Spectral Analysis and Sparse4Representation of the Signals" ,Computer Science, Engineering,Journal of Signal Processing Systems ,Published 1 February 2014
- [14]. Dan Ellis,Chroma Feature Analysis and Synthesis, 2007/04/21, Published with MATLAB®7.3
- [15]. McFee, B., Raffel, C., Liang, D., Ellis, D. P., McVicar, M., Battenberg, E., Nieto, O. "librosa: Audio and Music Signal Analysis in Python", Proc. Of the 14th python in science conf. (SCIPY 2015), 2015.
- [16]. Webb, G.I. (2011). Naïve Bayes. In: Sammut, C., Webb, G.I. (eds) Encyclopedia of Machine Learning. Springer, Boston, MA. [https://doi.org/10.1007/978-0-387-30164-8\\_576](https://doi.org/10.1007/978-0-387-30164-8_576)
- [17]. Freund, Y. and Schapire, R.E., A Short Introduction to Boosting, Journal of Japanese Society for Artificial Intelligence, 14(5):771-780, 1990
- [18]. K. Taunk, S. De, S. Verma and A. Swetapadma, "A Brief Review of Nearest Neighbor Algorithm for Learning and Classification," 2019 International Conference on Intelligent Computing and Control Systems (ICCS), 2019, pp. 1255-1260, doi: 10.1109/ICCS45141.2019.9065747.
- [19]. Jair Cervantes, Farid Garcia-Lamont, Lisbeth Rodríguez-Mazahua, Asdrubal Lopez, A comprehensive survey on support vector machine classification: Applications, challenges and trends, Neurocomputing, Volume 408, 2020,Pages 189-215,
- [20]. L. Liu, "Research on Logistic Regression Algorithm of Breast Cancer Diagnose Data by Machine Learning," 2018 International Conference on Robots & Intelligent System (ICRIS), 2018, pp. 157-160, doi: 10.1109/ICRIS.2018.00049
- [21]. J. K. Jaiswal and R. Samikannu, "Application of Random Forest Algorithm on Feature Subset Selection and Classification and Regression," 2017 World Congress on Computing and Communication Technologies (WCCCT), 2017, pp. 65-68, doi: 10.1109/WCCCT.2016.25.
- [22]. A. A. Karcioğlu and H. Bulut, "Performance Evaluation of Classification Algorithms Using Hyperparameter Optimization," 2021 6th International Conference on Computer Science and Engineering (UBMK), 2021, pp. 354-358, doi: 10.1109/UBMK52708.2021.9559003.
- [23]. N. Fazakis, G. Kostopoulos, S. Karlos, S. Kotsiantis and K. Sgarbas, "Self-trained eXtreme Gradient Boosting Trees," 2019 10th International Conference on Information, Intelligence, Systems and Applications (IISA), 2019, pp. 1-6, doi: 10.1109/IISA.2019.8900737.
- [24]. İnternet: TIBCO Jupyter Notebooks Requirements, [https://docs.tibco.com/pub/sfire-dsc/6.5.0/doc/html/TIB\\_sfiredsc\\_sys-req/GUID-291ABBD3-9DC6-4659-8595-3F208F24565A.html](https://docs.tibco.com/pub/sfire-dsc/6.5.0/doc/html/TIB_sfiredsc_sys-req/GUID-291ABBD3-9DC6-4659-8595-3F208F24565A.html), Erişim Tarihi: Ocak 2022