

Makine Öğrenmesi Yöntemleri Kullanılarak Ses Verilerinden Cinsiyet Tahmin Edilmesi

M. Hanefi CALP*¹

¹Hacı Bayram Veli Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, 06500, Ankara, Türkiye

(Alınış / Received: 25.11.2024, Kabul / Accepted: 07.03.2025, Online Yayınlanma / Published Online: 25.04.2025)

Anahtar Kelimeler
Ses,
Cinsiyet,
Tanıma,
Tahmin,
Makine Öğrenmesi

Öz: Makine öğrenmesi, bilgisayar ve robot gibi insan yapımı araçları kullanarak doğal sistemleri taklit etmekte, sınıflandırma ve tahmin yapabilmektedir. Bu yöntem, bilginin bellekte kayıt altına alınması ve örnek veriden öğrenerek bu bilgiden otomatik olarak birtakım çıkarımlar yapabilmesini sağlamaktadır. Bu çalışmada, makine öğrenmesi yöntemleri kullanılarak ses ve konuşma analizi ile kişilerin cinsiyetleri tahmin edilmiştir. Çalışma için gerekli olan veri seti Kaggle açık kaynak veri paylaşım platformundan temin edilmiştir. Bu veri seti, sesi Erkek veya Kadın olarak tanımlamak amacıyla sesin ve konuşmanın akustik özelliklerine göre oluşturulmuştur. Veri setindeki verilerin en doğru şekilde tahmin edilebilmesi için K-En Yakın Komşu (KNN), Karar Ağacı (KA), Naive Bayes (NB) ve Yapay Sinir Ağları (YSA) yöntemlerinden yararlanılmıştır. Yararlanılan tüm bu yöntemlerde "Meanfun, Sd, Q25, IQR, Label" parametreleri temel alınarak süreç iletirilmiştir. Bununla birlikte, veri seti farklı eğitim-test oranlarında (%75-%25, %80, %20, %70, %30) birçok defa denenerek modeller oluşturulmuş olup sonuçlar test edilmiştir. Daha sonra her bir yöntem oluşturulan modeller üzerinde uygulanarak deneysel çalışmalar yapılmıştır. Modeller hem kendi içerisinde hem de diğer modeller arasında kıyaslanmış ve en iyi performansa sahip model belirlenmiştir. Ayrıca elde edilen bulgular, kolay analiz edilebilmesi amacıyla şekil ve grafikler ile görselleştirilmiştir. Sonuç olarak, en yüksek sınıflandırma başarısı, veri setinin %75 eğitim ve %25 test kümesine bölünerek, %98.96'lık bir oranla YSA modeli ile elde edildiği ortaya çıkmıştır.

Predicting of the Gender from Audio Data Using Machine Learning Methods

Keywords
Voice,
Gender,
Recognition,
Prediction,
Machine Learning

Abstract: Machine learning uses man-made tools such as computers and robots to imitate natural systems, and make classifications and predictions. This method allows the information to be recorded in memory, learn from sample data, and make some inferences from this information automatically. In this study, the gender of individuals was estimated using machine learning methods through voice and speech analysis. The data set required for the study was obtained from the Kaggle open-source data-sharing platform. This data set was created according to the acoustic properties of the voice and speech in order to define the voice as Male or Female. In order to estimate the data in the data set in the most accurate way, K-Nearest Neighbor (K-NN), Decision Tree (DT), NB (NB), and Artificial Neural Networks (ANN) methods were used. In all these methods used, the process was advanced based on the parameters "Meanfun, Sd, Q25, IQR, Label". In addition, the data set was tried many times at different training-test ratios (75%-25%, 80%, 20%, 70%, 30%) and models were created and the results were tested. Then, experimental studies were conducted by applying each method to the created models. The models were compared both within themselves and among other models, and the model with the best performance was determined. In addition, the obtained findings were visualized with figures and graphics for easy analysis. As a result, it was revealed that the highest classification success was obtained with the ANN model with a rate of 98.96% by dividing the data set into 75% training and 25% test sets.

1. Giriş

Teknolojinin gelişmesiyle birlikte kişisel bilgisayarlar hem bilgi kaynağına erişim amacıyla hem de karar süreçlerinde kullanılmaya başlanmıştır. Günümüzde ise düşük maliyetle karar verebilme yeteneği, karmaşık problemlerin çözebilmesi, yüksek işlem hızına sahip olması, detayları atlamaması gibi birtakım nedenlerle yapay zeka teknolojisi hemen hemen her alanda yaygın ve etkin bir şekilde kullanılmaktadır. Yapay zeka, insan gibi düşünen, hareket eden makineler veya sistemler olarak tanımlanabilir. Yapay zeka makinelerin daha akıllı olmalarını sağlamayı, bilgisayarlar kullanılarak insan zekasını taklit etmeyi ve makinelerin belirli bir seviyede öğrenme özelliğine sahip olmalarını sağlamayı amaçlamaktadır [1].

Bu çerçeveden bakıldığında, normalde özellikle duygu veya yaratıcılık bakımından bilgisayarlar hiçbir şekilde insanların yerine geçemeyecek ve sadece basit fonksiyonları çalıştırabilecekken günümüzde yapay zeka sayesinde insanların yerine geçebilecek elektromekanik bir cihaz olarak kullanılabilir. Yapay zeka, insan zekasının fonksiyonlarını taklit ederek matematiksel işlemler yapabildiği gibi çok daha büyük ve karmaşık problemleri nano saniyeler mertebesinde çözümleme konusunda da oldukça etkilidir. Ayrıca, manuel gerçekleştirilen birçok iş ve işlemi otomatize ederek bir otomasyon yapısı sağlar. Bununla birlikte, bilgisayara dayalı bilgi sistemleri ile entegre edilerek yeteneğini daha da arttırabilmektedir. Yapay zeka, sadece verinin bilgisayarlar ile işlenmesi olarak düşünülmemelidir. Aynı zamanda, bilgisayar yazılımları aracılığıyla geleneksel algoritmaların ötesinde işlemler gerçekleştirebilmektedir [2]. Bu bağlamda, çalışmada da kullanılan makine öğrenmesi yöntemlerinden yararlanılabilmektedir. Makine öğrenmesi, daha önce geçmiş veya yaşanmış tecrübelerden öğrenme yeteneğine sahip olan yapay zekâ teknolojilerinden biridir. Makine öğreniminin başarısı için, iyi belirlenmiş girdi veriler seçilmelidir [3].

Literatürde farklı makine öğrenmesi yöntemleri kullanılarak ses ile cinsiyet tanıma konusuyla ilgili çalışmalara rastlanmaktadır. Örneğin bir çalışmada, meta sezgisel optimizasyon algoritmaları kullanılarak ses verileri ile cinsiyeti tahmin eden bir model önerilmiştir. Önerilen modelde, söz konusu özellik kümesi optimizasyon algoritmalarıyla en uygun ses verileri belirlenmeye çalışılmıştır. Problemin çözmek için meta sezgisel optimizasyon algoritmalarından olan Salp Sürüsü Algoritması (SSA), Parçacık Sürüsü Optimizasyonu (PSO), Karınca Koloni Optimizasyonu (KKO) ve Balina Optimizasyonu Algoritması (BOA)'ndan yararlanılmıştır. Söz konusu algoritmalarla özellik seçimi süreci tamamlandıktan sonra, deneysel çalışma yapılmış olup elde edilen veriler üzerinde NB ve KA algoritmaları uygulanmıştır.

Gerçekleştirilen test ve analizler, KA ve NB algoritmaları ile elde edilen sonuçlar üzerinde optimizasyon algoritmalarının özellik seçimi için başarı oranını artırdığı gözlemlenmiştir [4]. Özkaynak ve diğerleri, Temel Bileşen Analizi (TBA) yöntemini kullanarak cinsiyet tanıma sistemi için bir model önermiş olup genel bir cinsiyet tahmini yapabilen bir yazılım gerçekleştirmiş ve TBA yönteminin performansını değerlendirmişlerdir. Sonuç olarak, TBA algoritmasının tanıma başarısını ortaya koymuşlardır [5]. Tümen, derin öğrenme yöntemlerine dayalı bir model geliştirmiş ve farklı yapıya sahip Ani Sivri Uçlu Sinir Ağları (ASUSA) tekniğinden yararlanmıştır. Çalışmada, insan seslerini veya konuşmalarını kapsayan akustik bilgi tabanlı parametrelerden oluşan veri kümesi kullanılmıştır. Model için hazırlanıp oluşturulan veri seti ile ASUSA modeli eğitilmiş olup cinsiyet tahmini süreci gerçekleştirilmiştir. Sonuç olarak, sınıflandırma sürecinde yüksek bir doğruluk başarısı elde edildiği ve yapılan deneysel testler ve analizler aracılığıyla, ASUSA modelinin başarılı bir şekilde uygulandığı ortaya çıkmıştır [6].

Açıl, çalışmada iris yapısını kullanarak cinsiyet tahmini gerçekleştirmiştir. Bu süreçte, iris görüntülerine öznitelik çıkarmak amacıyla geometrik özellik çıkartma, doku analizi, dalgacık dönüşüm, gabor filtresi ve fourier dönüşümü yöntemleri uygulanmıştır. İleri seçim, bireysel en iyi seçim ve n-al r-bırak seçim algoritmalarından yararlanılarak öznitelik seçimi gerçekleştirilmiş ve elde edilen bulgular karşılaştırılmıştır. Nihai sonuçlar, en yüksek başarı oranıyla (%91 başarı oranı) öznitelik alt kümesi non-lineer dönüşüm olduğunu ortaya koymuştur [7]. Bektaş ise çalışmada, makine öğrenmesi ve derin öğrenme algoritmalarını kullanarak Türkçe haber metinlerinden yazar, tür ve cinsiyete göre sınıflandırma sağlamıştır. Modelleme aşamasında, problemlerin çözümü için derin öğrenme algoritmalarından Evrimsel Sinir Ağları (CNN) ve Uzun Kısa Süreli Bellek (LSTM) ve makine öğrenmesi algoritmalarından olan Çok terimli NB (MNB) ve Rastgele Orman (RF) sınıflandırıcı olarak veri setlerine uygulamıştır. Oluşturulan modellerin sonucunda, her bir veri seti en iyi modeller üzerinde test edilmiş ve her bir model başarı ölçütlerinden olan doğruluk, kesinlik ve duyarlılık ölçütleri ile ölçülerek performansları elde edilmiştir. Bu noktada, özellikle cinsiyet tanıma bakımından en yüksek başarının ve en iyi modelin LSTM sınıflandırıcı algoritması ile mümkün olduğu görülmüştür [8].

Bu çerçevede, konuyla alakalı çalışmalar olduğu gibi makine öğrenmesi yöntemleri kullanılarak farklı alanlarda yapılan çalışmalar da bulunmaktadır. Örneğin, bir çalışmada KA algoritmalarından olan CHAID ve CART kullanılarak 114 tane ülke üzerinde çocuk işçiliğine etki eden faktörlerin önem sırasına göre belirlenmesi amaçlanmıştır. Elde edilen bulgular,

en önemli değişkenin söz konusu CART ve CHAID algoritmaları içerisinde SGP olduğu görülmüştür [9]. Sağlık alanındaki bir diğer çalışmada, akciğer kanserinin erken tanısı için makine öğrenmesi algoritmalarından yararlanılmıştır. Bu algoritmalar NB, Lojistik Regresyon, BayesNet, Multilayer Perceptron, KStar, Bagging, OneR, ZeroR, J48 ve Random Tree'dir. Sonuçlar, en yüksek başarıya sahip algoritmanın NB olduğunu ortaya koymuştur [10]. Makine öğrenmesinin internet bankacılığı kullanıcı profilinin çıkarılması için kullanıldığı çalışmada, Birliktelik Kuralı yöntemi ile müşterilerin banka tercihlerinin neler olduğu, hesaplarında hangi türde işlemler yaptıkları ve bu işlemleri gerçekleştirirken hangi kalite unsurlarının önemli olduğu tespit edilmiştir. Kümeleme analizi ve sepet analizi ile elde edilen sonuçlar, reklam stratejilerinin belirlenmesi, müşteri profillerinin analiz edilerek satış tahminlerinin gerçekleştirilmesi, hedef pazar türünün belirlenmesi, yeni müşterilere erişim sağlamak adına etkin faktörlerin tespit edilmesi, müşterilerin seviyelerinin belirlenmesi, müşterilerin özelliklerine ve tercihlerine göre gruplara ayrılması ve son olarak müşteri ilişkileri yönetimi için kullanılabileceğini ortaya koymuştur [11].

Yine bir çalışmada, zaman serisi yöntemi ve YSA algoritması süpermarket verileri üzerinde kullanarak bir model oluşturulmuştur. Bu model ile gerçekleştirilen tahmin sonuçlarının doğruluk performansları kıyas edilerek analiz edilmiştir. Daha sonra, zaman serisi ve YSA ile oluşturulan modeller içerisinde en yüksek performansa sahip olan model belirlenmiş ve son kez güncel tahmin verileri elde edilmiştir [12]. Bir diğer çalışmada, makine öğrenmesi kapsamında kümeleme algoritmaları yönteminden yararlanılarak daha önceden belirlenen özellikler ışığında ülkelerin aldığı değerler karşılaştırılmıştır. Bu karşılaştırma süreci ile anlamlı kümelerin meydana getirilmesi amaçlanmıştır. Veriler, Dünya Bankası'nın internet web sitesinden temin edilmiştir. Sözkonusu verilerin yer aldığı web siteden 2015 yılına ait veriler MS Excel formatında indirilmiştir. Bu veriler kullanarak kümeleme algoritmalarından olan SOM ve K-Means algoritmaları uygulanmış ve ülkelerin değerlendirilmesi gerçekleştirilmiştir. Elde edilen deneysel sonuçlar ile algoritmaların ürettiği kümeler ve bu kümeler içerisindeki Türkiye'nin yeri analiz edilmiştir [13].

Alabdoo tarafından gerçekleştirilen tez çalışmasında, Deep Recurrent Fingerphotos Network (DRFN) olarak adlandırılan, bir Derin Tekrarlayan Öğrenme (DRL) modeli ile parmak fotoğrafı görüntülerini kullanarak kişi, yaş ve cinsiyet tahmini yapmıştır. Önerilen DRFN modelinin mimarisi; bir giriş katmanı, birkaç gizli katman, bir çıkış katmanı ve bir geri besleme bağlantısından oluşmaktadır. Önerilen modelin doğruluğunu test edebilmek amacıyla, özgün görüntüler içeren bir veri seti kullanılmıştır. Bu veri

seti içerisinde her bir insana ait 10 parmağın farklı açıdan çekilmiş 10 fotoğrafı mevcuttur. Ayrıca, önerilen DRFN modeli ile AlexNet, LeNet, GoogleNet, VGG16 ve ResNet-50 gibi özellik çıkarma için kullanılan deneyler de yer almaktadır. Bu değerlendirmelerde Destek Vektör Makinesi (SVM), Rastgele Orman, Çok Katmanlı Algılayıcı (MLP), Doğrusal Regresyon ve Lojistik Regresyon sınıflandırıcı algoritmaları kullanılmıştır. Analizlerin değerlendirilmesi sürecinde, Precision, Recall ve F1-Score performans değerlendirme ölçütlerinden yararlanılmıştır. Elde edilen sonuçlar, önerilen DRFN modelinin diğerlerine nazaran daha iyi sonuçlar ürettiğini göstermiştir [14]. Görgün ve ark. çalışmada, bir Türkçe Twitter hesabında paylaşılan mesajlar dikkate alınarak Doğal Dil İşleme yöntemiyle hesap sahibinin yaş ve cinsiyetini tahmin etmişlerdir. Çalışmada 1040 adet Twitter kullanıcısına ait yaş ve cinsiyet bilgileri temin edilmiş ve bu verilerle etiketli bir veri kümesi hazırlanmıştır. Daha sonra kelime, karakter, retweet, fastText ve BERT tabanlı beş farklı yöntem geliştirilmiştir. Gerçekleştirilen testlere göre, kullanıcıların paylaştıkları mesajlar insanların yaş ve cinsiyet bilgisine dair önemli ipuçlar sunduğu görülmüştür [15].

Yılmaz ve ark. çalışmada, Bilgisayarlı Tomografi (BT) görüntüleri ile Makine öğrenmesi (ML) algoritmalarını kullanarak cinsiyet tahmini amaçlamışlardır. Çalışmada 18-65 yaş arası 214 bireyin BT görüntüleri kullanılmıştır. ML algoritmaları ile 0,84'e varan yüksek doğrulukta cinsiyet tahmin sonuçları elde edilmiştir. Ayrıca çalışma ML algoritması ile Türk popülasyonunda cinsiyet tahmini kullanımının etkin olduğu ortaya koyulmuştur [16]. Kocamış tez çalışmasında, 2D ölçümlerin yerine 3D pelvis verileri kullanarak makine öğrenme algoritmaları ile cinsiyet ve yaş tahmini amaçlanmıştır. Çalışmada, bir devlet hastanesine başvuran 152 kişinin (77 kadın, 75 erkek) pelvis bilgisayarlı tomografi görüntü verileri kullanılmıştır. 256 kesitli çift tüplü BT görüntüleri, 0.625mm kalınlığında ve DICOM formatında kaydedilmiştir. Çalışmada, DVM algoritması kullanarak %87 doğruluk oranında bir başarı elde edilmiştir. 2D morfometrik ölçümlerde %98'lik bir doğruluk elde edilirken, çalışmada makine öğrenme modelleri kullanarak daha yüksek bir başarı elde edilememiştir [17].

Son olarak bir diğer tez çalışmasında ise, Türk popülasyonuna ait Multidedektör Bilgisayarlı Tomografi (MDBT) görüntüleri kullanarak makine öğrenmesi algoritmaları ile cinsiyet tahmini gerçekleştirilmiştir. İzmir Bakırçay Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalı arşivindeki 2018-2022 yılları arasında MDBT çekilmiş, yaşları 20 ile 60 arasında 300 (150 kadın-150 erkek) hastanın görüntüleri taranmıştır. Scapula'ya ait MDBT görüntüleri üzerinden koronal ve sagittal düzlemlerde 13 parametrenin ölçümü yapılmıştır. Çalışmada, ses

içerikli veri seti KA, KNN, NB ve YSA algoritmaları ile sınıflandırarak cinsiyetin tahmin edilmiştir. Sonuçlar, tüm parametrelerin medyan değerinin erkeklerde fazla olduğu, cinsiyet açısından verilerin karşılaştırılması sonucu scapula üzerinde ölçülen tüm parametrelerin anlamlı bir farka sahip olduğunu ortaya koymuştur [18].

2. Materyal ve Yöntem

2.1. Veriseti

Çalışmada yararlanılan veri seti, ele alınan bir ses verisinin Erkek veya Kadın olma durumunu ortaya koymak amacıyla sesin ve konuşmanın akustik özellikleri dikkate alınarak oluşturulmuştur. Söz konusu veri seti, Erkek ve Kadın cinsiyete sahip kişilerden derlenen toplamda 3168 adet ses kayıt örneğinden meydana gelmektedir. Ses örnekleri, seewave ve tuneR paketleri kullanılarak R'de akustik analiz ile önceden işlenmiş ve analiz edilen frekans aralığı 0hz-280hz'dir. Her sesin Tablo 1'de verilen akustik özellikleri ölçülmüş ve CSV'ye dahil edilmiştir.


Tablo 1. Veri setinde bulunan parametreler

Sütunlar	Açıklaması
Meanfreq	Ortalama frekans (kHz cinsinden)
Sd	Frekansın standart sapması
Q25	İlk nicelik (kHz cinsinden)
Q75	Üçüncü kuantil (kHz cinsinden)
IQR	Çeyrekler arası aralık (kHz cinsinden)
Sfm	Spektral düzlük
Centroid	Frekans centroid (spesifikasyona bakınız)


Meanfun	Akustik sinyalde ölçülen temel frekansın ortalaması
Minfun	Akustik sinyalde ölçülen minimum temel frekans
Maxfun	Akustik sinyalde ölçülen maksimum temel frekans
Meandom	Akustik sinyalde ölçülen baskın frekansın ortalaması
Mindom	Akustik sinyalde ölçülen minimum baskın frekans
Maxdom	Akustik sinyalde ölçülen maksimum baskın frekans
Dfrange	Akustik sinyalde ölçülen baskın frekans aralığı
Modindx	Modülasyon indeksi. Temel frekansların bitişik ölçümleri arasındaki birikmiş mutlak farkın frekans aralığına bölünmesiyle hesaplanır.
Label (Çıktı)	Kadın veya Erkek

2.2. Keşifsel veri analizi- violin grafik

Veri setinde bulunan parametrelerin hangi değerler arasında dağılım/yığılım yaptığı bilgisi verilerin keşfi bakımından önemlidir. Şekil 1 'de, sığ olan dağılımlar verinin dengeli dağıldığını gösterirken sığ olmayan dağılımlar bir dengesizlik veya dengesiz dağılım olduğunu gösterir. Sığ olmayan dağılımlar veri seti için olumsuz bir anlam ifade etmez çünkü her parametre kendi içerisinde farklı bir ölçüte göre hesaplanır. Sığ dağılımlarda dalgalanmanın aniden azaldığı yerlerde dengeli dağılımın azaldığı gözlemlenir. Örneğin "Maxfun" parametresinde 2.5 değerinden sonra keskin bir azalış görülmüştür. Bu durum "Maxfun" parametresinin ölçümü sırasında aykırı sonuçlar elde edildiğini göstermektedir.




Şekil 1. Parametrelerin aldıkları değerlerin dağılımı (Violin grafik)




Şekil 1 (devam). Parametrelerin aldıkları değerlerin dağılımı (Violin grafik)


Veri setinde parametrelerin aldıkları değerlerin aykırılık durumları (kutu grafik) ise Şekil 2’de verilmiştir. Örneğin “Meanfun” parametresinin ölçümü yapılırken hiç aykırı değer elde edilmemişken

“Maxfun” parametresi ölçümü yapılırken çok fazla aykırı değer elde edilmiştir. Çalışmada da aykırı veri oranı en düşük olan “Meanfun”, “Q25”, “Sd”, “IQR” giriş değerleri temel alınmıştır.





Şekil 2. Parametrelerin aldıkları değerlerin aykırılık durumları (Kutu grafik)



Şekil 2 (devam). Parametrelerin aldıkları değerlerin aykırılık durumları (Kutu grafik)

2.3. Kullanılan yöntemler

2.3.1. KA

Genel olarak, tahmin ve sınıflandırma amacıyla kullanılan bir makine öğrenmesi yöntemidir [19]. Bu yöntem, yüksek tahmin veya sınıflandırma başarısı göstermektedir. Özellikle basit/temel özelliklere sahip olması nedeniyle de sağlıktan turizme hemen hemen her alanda geniş bir uygulama yelpazesine sahiptir [20, 21].

2.3.2. NB

Bu yöntem, istatistik alanında bilinen Bayes teoremine dayalı olarak geliştirilen, uygulaması ve kullanılması kolay, anlaşılabilir ve uygulanabilir olması

bakımından da oldukça etkin olan makine öğrenme algoritmalarından biridir. Temin edilen verisetinin belirlenen kümelere ait olma olasılığını öngören bir yöntemdir. Genel olarak net olmayan durumlar için sınıflandırma ve tahmin etme amacıyla kullanılır [22].

2.3.3. KNN

K-NN, öğrenme sürecinin güçlü ve kullanışlı olması ve uygulanması bakımından da kolay olmasından dolayı özellikle sınıflandırma problemlerinde etkin ve yaygın biçimde yararlanılmaktadır. Bu tanım dikkate alındığında, K-NN algoritması örnek tabanlı makine öğrenme algoritmaları arasında yer almaktadır [23].

2.3.4. YSA

YSA, insan beyninin temel fonksiyonlarını taklit etmek suretiyle, özellikle beynin öğrenme, geri çağırma, genelleme yapma gibi özellikleriyle topladığı verilerden yeni veri/bilgi üretebilen bilgisayar yazılımıdır. YSA; insan beyninin çalışma prensiplerinden etkilenerek, öğrenme sürecinin matematiksel olarak modellenmesi veya formülize edilmesi ile meydana çıkmıştır [24]. YSA uygulamaları genellikle tahmin, ilişkilendirme, sınıflandırma, yorumlama ve filtreleme gibi amaçlarla kullanılmaktadır [25].

2.4. Modellerin oluşturulması

Modellerin oluşturulması süreci Python kodlarının geliştirilmesiyle gerçekleştirilmiştir. Çalışma kapsamında cinsiyete göre ses tanıma veri setinde 21 adet farklı parametre içerisinden “meanfun, sd, Q25, IQR” olmak üzere 4 parametre girdi değişkenleri ve “label” olmak üzere ise 1 parametre çıktı değişkeni olarak belirlenmiştir. Veri setinin %75’i eğitim, %25’i test kümesi olarak ele alınmıştır. Bu bölümde hem bu kodlara hem de modellerin ayrıntılarına yer verilmiştir.

Modellerin performanslarını değerlendirmek için Doğru Sınıflandırılmış Örnekler (Correctly Classified Instances), Kappa İstatistiği (Kappa Statistic), Ortalama Mutlak Hata (Mean Absolute Error), Karekök ortalama hata oranı (Root Mean Squared Error), Bağlı Mutlak Hata (Relative Absolute Error), Kök Göreceli Karesel Hata (Root Relative Squared Error), Toplam Örnek Sayısı (Total Number of Instances), Gerçek Pozitif Değerlerin Oranı (True Positive Rate), Yanlış Pozitif Değerlerin Oranı (False Positive Rate), Hassasiyet (Kesinlik), Duyarlılık (Recall), ROC Analizi (ROC Area), F-Ölçüsü (F-Measure), Matthew’s Korelasyon Katsayısı (MCC - Matthews Correlation Coefficient), PRC Alanı (PRC Area) ölçütlerinden yararlanılmıştır.

2.4.1. KA modeli

Veri seti kullanılarak KA modeli oluşturulmuş ve modelin başarısı test edilmiştir. Yaprak başına düşen minimum obje (MinNumObj) sayısı 2 (varsayılan değer) olarak belirlenmiştir. Söz konusu modelin Python kodu Şekil 3’te verilmiştir.

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt

data = pd.read_csv("ses.csv")

data.drop(["meanfreq", "median", "Q75", "skew", "kurt", "sp.ent", "sfm",
           "mode", "centroid", "minfun", "maxfun", "meandom",
           "mindom", "maxdom", "dfrange", "modindx"], axis=1, inplace=True)
data.label=[1 if each=="male" else 0 for each in data.label]

y=data.label.values
x_data=data[["sd", "meanfun", "Q25", "IQR"]]

#normalizasyon
x=(x_data-np.min(x_data))/(np.max(x_data)-np.min(x_data))

#train test split
from sklearn.model_selection import train_test_split
x_train,x_test,y_train,y_test=train_test_split(x,y,test_size=0.6,random_state=1)

#knn
from sklearn.tree import DecisionTreeClassifier
dtc=DecisionTreeClassifier()
dtc.fit(x_train,y_train)

print(dtc.score(x_test,y_test))
prediction=dtc.predict(x_test)

from sklearn import tree
fn=["sd", "meanfun", "Q25", "IQR"]
cn=['Male', 'Female']
fig, axes = plt.subplots(nrows = 1,ncols = 1,figsize = (4,4), dpi=500)
tree.plot_tree(dtc,feature_names = fn, class_names=cn, filled = True);


from sklearn import metrics
cnf_matrix = metrics.confusion_matrix(y_test,prediction)

import seaborn as sns
plt.figure(figsize=(9,9))
sns.heatmap(cnf_matrix, annot=True, fmt=".0f", linewidths=.5, square = True, cmap = 'Blues_r');
plt.ylabel('Gerçek');
plt.xlabel('Tahmin');
all_sample_title = 'Accuracy Score: {}'.format(metrics.accuracy_score(y_test, prediction))
plt.title(all_sample_title, size = 15);

print("Dogruluk-Accuracy:",metrics.accuracy_score(y_test, prediction))
print("Hassasiyet-Precision:",metrics.precision_score(y_test, prediction))
print("Dogru tanimlama oranı-Recall:",metrics.recall_score(y_test, prediction))
```

Şekil 3. KA Sınıflandırma Yönteminin Python Kodu

KA incelendiğinde (Şekil 4), dallanmanın ilk olarak “Meafun” parametresinden başladığı görülmektedir. İlk koşulun “Meafun” parametresi olma sebebi Entropi değerinin yüksek olmasıdır. Her bir ana ve alt yapraklar entropi değerleri dikkate alınarak belirlenmiştir. Modellenen KA 17 yaprak, 33 daldan oluşmaktadır.



Şekil 4. KA modeli

Modelin performansına ait sonuçlar Tablo 2’de verilmiştir.

Tablo 2. KA performans sonuçları

Ölçüt	Değer
Başarı Oranı	97.000 %
Kappa İstatistiği	0.94
Ortalama Mutlak Hata (MAE)	0.045
Kök Ortalama Kare Hatası (RMSE)	0.163
Görelî Mutlak Hata (RAE)	8.92 %
Kök Görelî Kare Hatası (RRSE)	32.92 %
Modeli Oluşturmak İçin Geçen Süre	3 sn

Modelde Doğru Sınıflandırılmış Örnekler (Correctly Classified Instances) bakımından, 3168 satır veriden 792’si üzerinde tahmin yapılmıştır. Bunun sonucunda 2376 adet eğitim verisi ile %97.000 oranında başarı elde edilmiştir. Kadın ve Erkek değerlerinin arasındaki karşılaştırmalı uyuşmanın (Kappa İstatistiği) güvenilirlik oranı 0.94’dür. Elde edilen değer 0.81-1.00 aralığında olduğu için Kadın ve Erkek değerleri arasında neredeyse mükemmel bir uyuma olduğu görülmektedir. Tahmin sonucunda elde edilen ortalama mutlak hata oranı (MAE) 0.045’dır. Tahmin sonucunda elde edilen karekök ortalama hata oranı (RMSE) 0.163’dır. Tahmin sonucunda gerçek değer ile hesaplanan değer arasındaki farkın gerçek değere oranlanması (RAE) sonucunda 0.892 değeri elde edilmiştir. MAE, RMSE ve RAE değerleri 0’a yakın olduğu için tahmin edilen modelin başarılı olduğu söylenebilir. Tahmin sonucunda kök göreceli hata oranı (RRSE) 0.325’dir. Bu değer 0’a çok yakın olmasa da diğer metriklerin 0’a yakın olmasından dolayı modelin başarı oranını çok etkilememiştir. Karışıklık matrisi ve diğer formülasyon sonuçları Tablo 3’te verilmiştir.

Tablo 3. KA Karışıklık Matrisi Bulguları

TP Oranı	FP Oranı	Kesinlik	Duyarlılık	F-Ölçüm	MCC	ROC	PRC	Sınıf
0.96	0.02	0.97	0.96	0.97	0.94	0.97	0.97	Erkek
0.97	0.03	0.96	0.97	0.97	0.94	0.97	0.97	Kadın

Tablo 3’te verilen her bir sonuca ait yorumlar şöyledir:

TP Oranı: Tahmin sonucunda sınıfı Erkek olan verilerden Erkek sesini Erkek sesi olarak tahmin etme oranı 0,964’dür. Sınıfı Kadın olan verilerden Kadın sesini Kadın sesi olarak tahmin etme oranı 0,976’dır. Bu değerler 1’e yakın olduğu için iyi bir başarı oranı elde edildiği görülmektedir. Yapılan KA sınıflandırma yöntemi sonucunda verilerin tamamına yakın bir kısmını doğru tahmin ettiği görülmektedir. Aynı zamanda Kadın ve Erkek sınıflarında en çok doğru tahmin yapılan sınıfın Kadın olduğu görülmüştür.

FP Oranı: Tahmin sonucunda sınıfı Erkek olan verilerden Erkek sesini Kadın sesi olarak tahmin etme oranı 0,024’dür. Sınıfı Kadın olan verilerden Kadın

sesini Erkek sesi olarak tahmin etme oranı 0,036’dır. Bu değerler 0’a yakın olduğu için yapılan hatalı tahminin düşük olduğu görülmektedir. Aynı zamanda Erkek ve Kadın sınıfları arasında en çok hata yapılan sınıfın Kadın olduğu görülmüştür.

Kesinlik: Tahmin sonucunda Erkek sınıfı hassasiyet oranı 0,976 iken Kadın sınıfı hassasiyet oranı 0,964’dür. Hassasiyet oranları 1’e yakın olduğu için sınıflandırma modelinin yüksek oranda tahmin başarısı gösterdiği söylenebilir. Sınıfı Erkek olan verilerin hassasiyet oranı daha yüksektir.

Duyarlılık: Tahmin sonucunda Erkek sınıfı geri çağırma oranı 0,964 iken Kadın sınıfı geri çağırma oranı 0,976’dır. Yani bu durum, gerçekte sesin Kadın olduğu durumda tahminin Erkek sesi olarak yapılmasıdır. Bu hata oranı 0’a yaklaştıkça artar, 1’e yaklaştıkça azalır. Bu durumda sınıflandırma modelinin yüksek oranda tahmin başarısı gösterdiği söylenebilir. Kadın sınıfına ait veriler daha doğru tahmin edilmiştir.

F-Ölçüm: Tahmin sonucunda Erkek ve Kadın sınıfı F-Ölçüm oranı 0,970 çıkmıştır. Bu değer 1’e yakın olması, tahmin modelinin başarılı olduğunu göstermektedir.

Matthew’s Korelasyon Katsayısı: Tahmin sonucunda Erkek ve Kadın sınıfı MCC oranı 0,940 çıkmıştır. Bu değer 1’e yakın olması, tahmin modelinin başarılı olduğunu göstermektedir.

ROC Alanı: Tahmin sonucunda Erkek ve Kadın sınıfı ROC Alanı oranı 0,978 çıkmıştır. Bu değer 1’e yakın olması, tahmin modelinin başarılı olduğunu göstermektedir.

PRC Alanı: Tahmin sonucunda Erkek sınıfı PRC Alanı oranı 0,977 iken Kadın sınıfı oranı 0,970 çıkmıştır. Bu değer 1’e yakın olması, tahmin modelinin başarılı olduğunu göstermektedir. Aynı zamanda Erkek sınıfının PRC Alanı oranı Kadın sınıfından daha başarılıdır.

Karışıklık Matrisi: Karışıklık Matrisi kısmında oluşturulan test ve eğitim kümeleri sonucunda label parametresinde bulunan Erkek ve Kadın tahminlerindeki başarı görülmektedir. Erkek olan 639 verinin 616 tanesi Erkek olarak doğru tahmin edilirken 23 tanesi Kadın olarak yanlış tahmin edilmiştir. Kadın olan 628 verinin 613 tanesi Kadın olarak doğru tahmin edilirken 15 tanesi Erkek olarak yanlış tahmin edilmiştir. Tüm veri setine bakıldığında zaman, 1267 veriden 1229 veri doğru tahmin edilirken 38 veri yanlış tahmin edilmiştir.

Şekil 5’te, model tarafından yapılan yanlış ve doğru tahminlerin kesişimi gösterilmiştir. Sınıflandırıcı hata grafiğinde “Kadın” sınıfı kırmızı, “Erkek” sınıfı mavi

renktir. Grafikte ise “x” ile verilenler doğru sınıflandırılmış verileri “kare” şeklinde gösterilen yerler ise yanlış sınıflandırılmış verileri temsil etmektedir.

Örneğin **Kadın** kısmında bulunan **mavi** bir kare bu değer Erkek sınıfına ait olduğunu ama yanlış şekilde sınıflandırılarak Kadın sınıfına dâhil edildiğini göstermektedir. Tahmin modelinin sınıflandırıcı hata grafiğine bakıldığında, 23 Erkek, 15 Kadın olmak üzere 38 hata yapıldığı görülmektedir. 23 Erkek çıktının Kadın olarak tahmin edildiği ve 15 Kadın çıktının ise Erkek olarak tahmin edildiği görülmektedir.



Şekil 5. KA modeli yanlış ve doğru tahminlerin dağılımı

2.4.2. NB modeli

Veri seti kullanılarak model oluşturulmuş (Şekil 6) ve NB algoritması ile modelin tahmin etmesi sağlanmıştır.

```
import pandas as pd
import numpy as np

data = pd.read_csv("ses.csv")

data.drop(["meanfreq", "median", "Q75", "skew", "kurt", "sp.ent", "sfm",
           "mode", "centroid", "minfun", "maxfun", "meandom",
           "mindom", "maxdom", "dfrange", "modindx"], axis=1, inplace=True)
data.label = [1 if each == "male" else 0 for each in data.label]

y = data.label.values
x_data = data[["sd", "meanfun", "Q25", "IQR"]]

#normalizasyon
x = (x_data - np.min(x_data)) / (np.max(x_data) - np.min(x_data))

#train test split
from sklearn.model_selection import train_test_split
x_train, x_test, y_train, y_test = train_test_split(x, y, test_size=0.6, random_state=1)

#knn
from sklearn.naive_bayes import GaussianNB
nb = GaussianNB()
nb.fit(x_train, y_train)

prediction = nb.predict(x_test)

print(nb.score(x_test, y_test))

from sklearn import metrics
cnf_matrix = metrics.confusion_matrix(y_test, prediction)
```

```
import seaborn as sns
import matplotlib.pyplot as plt
plt.figure(figsize=(9,9))
sns.heatmap(cnf_matrix, annot=True, fmt=".0f", linewidths=.5, square = True, cmap = 'Blues_r');
plt.ylabel('Gerçek');
plt.xlabel('Tahmin');
all_sample_title = 'Accuracy Score: {}'.format(metrics.accuracy_score(y_test, prediction))
plt.title(all_sample_title, size = 15);

print("Doğruluk-Accuracy:", metrics.accuracy_score(y_test, prediction))
print("Hassasiyet-Precision:", metrics.precision_score(y_test, prediction))
print("Doğru tanımlama oranı-Recall:", metrics.recall_score(y_test, prediction))
```

Şekil 6. NB yöntemi Python kodu

Tablo 4. NB performans sonuçları

Ölçüt	Değer
Başarı Oranı	96.37 %
Doğru Sınıflandırılmış Örnekler	1221
Kappa İstatistiği	0.927
Ortalama Mutlak Hata (MAE)	0.043
Kök Ortalama Kare Hatası (RMSE)	0.170
Görelî Mutlak Hata (RAE)	8.711%
Kök Görelî Kare Hatası (RRSE)	34.013%
Toplam Örnek Sayısı	1267
Modeli oluşturmak için geçen süre	3,5 sn

Model ile yapılan tahminde %96.37 oranında bir başarı elde edilmiştir. Kadın ve Erkek değerlerinin arasındaki karşılaştırmalı uyuşmanın güvenilirlik oranı 0.927'dir. Elde edilen değer 0.81-1.00 aralığında olduğu için Kadın ve Erkek değerleri arasında neredeyse önemli derecede bir uyuşma olduğu görülmektedir. Tahmin sonucunda elde edilen ortalama mutlak hata oranı (MAE) 0.043'dır. Tahmin sonucunda elde edilen karekök ortalama hata oranı (RMSE) 0.170'dür. Tahmin sonucunda gerçek değer ile hesaplanan değer arasındaki farkın gerçek değere oranlanması (RAE) sonucunda 0.871 değeri elde edilmiştir. MAE, RMSE ve RAE değerleri 0'a yakın olduğu için tahmin edilen modelin başarılı olduğu söylenebilir. Tahmin sonucunda kök göreceli hata oranı (RRSE) 34.013'dir. Bu değer 0'a çok yakın olmasa da diğer metriklerin 0'a yakın olmasından dolayı modelin başarı oranını çok etkilememiştir.

Karışıklık matrisi ve diğer formülasyon sonuçları Tablo 5'te verilmiştir.

Tablo 5. NB karışıklık matrisi bulguları

TP Oranı	FP Oranı	Kesnilik	Duyarlılık	F-Ölçüm	MCC	ROC	PRC	Sınıf
0.97	0.04	0.95	0.97	0.96	0.92	0.99	0.99	Erkek
0.95	0.02	0.97	0.95	0.96	0.92	0.99	0.99	Kadın

TP Oranı: Tahmin sonucunda sınıfı Erkek olan verilerden Erkek sesini Erkek sesi olarak tahmin etme oranı 0,973'tür. Sınıfı Kadın olan verilerden Kadın sesini Kadın sesi olarak tahmin etme oranı 0,954'tür. Bu değerler 1'e yakın olduğu için iyi bir başarı oranı elde edildiği görülmektedir. Navie Bayes sınıflandırma modelinin verilerin tamamına yakın bir kısmını doğru

tahmin ettiği görülmektedir. Aynı zamanda Kadın ve Erkek sınıflarında en çok doğru tahmin edilen sınıfın Erkek olduğu görülmüştür.

FP Oranı: Tahmin sonucunda sınıfı Erkek olan verilerden Erkek sesini Kadın sesi olarak tahmin etme oranı 0,046'dır. Sınıfı Kadın olan verilerden Kadın sesini Erkek sesi olarak tahmin etme oranı 0,027'dir. Bu değerler 0'a yakın olduğu için yapılan hatalı tahminin düşük olduğu görülmektedir. Aynı zamanda Erkek ve Kadın sınıfları arasında en çok hata Erkek sınıfında olmuştur.

Kesinlik: Tahmin sonucunda Erkek sınıfı hassasiyet oranı 0,955 iken Kadın sınıfı hassasiyet oranı 0,972'dir. Hassasiyet oranları 1'e yakın olduğu için sınıflandırma modelinin doğru tahmin yaptığı görülmektedir. Sınıfı Erkek olan verilerin hassasiyet oranı daha yüksektir.

Duyarlılık: Tahmin sonucunda Erkek sınıfı geri çağırma oranı 0,973 iken Kadın sınıfı geri çağırma oranı 0,954'tür. Yani bu sonuç gerçekte sesin Kadın olduğu durumda tahminin Erkek sesi olarak yapılmasıdır. Burada hata oranı 0'a yaklaştıkça artar, 1'e yaklaştıkça azalır. Bu durumda sınıflandırma modelinin doğru tahmin yaptığı görülmektedir. Erkek sınıfına ait veriler daha doğru tahmin edilmiştir.

F-Ölçüm: Tahmin sonucunda Erkek sınıfı F-Measure oranı 0,964 iken Kadın sınıfı oranı 0.963 çıkmıştır. Bu değer 1'e yakın olması, tahmin modelinin başarılı olduğunu göstermektedir. Erkek sınıfına ait verilerde daha fazla başarı elde edilmiştir.

Matthew's Korelasyon Katsayısı: Tahmin sonucunda Erkek ve Kadın sınıfı MCC oranı 0,928 çıkmıştır. Bu değer 1'e yakın olması, tahmin modelinin başarılı olduğunu göstermektedir.


ROC Alanı: Tahmin sonucunda Erkek ve Kadın sınıfı ROC Area oranı 0,993 çıkmıştır. Bu değer 1'e yakın olması, tahmin modelinin başarılı olduğunu göstermektedir.

PRC Alanı: Tahmin sonucunda Erkek ve Kadın sınıfı PRC Area oranı 0,993 çıkmıştır. Bu değer 1'e yakın olması yapılan tahmin modelinin başarılı olduğunu göstermektedir. Kadın sınıfına ait verilerde daha fazla başarı elde edilmiştir.

Karışıklık Matrisi: Karışıklık Matrisi kısmında oluşturulan test ve eğitim kümeleri sonucunda label parametresinde bulunan Erkek ve Kadın tahminlerindeki başarı görülmektedir. Erkek olan 639 verinin 622 tanesi Erkek olarak doğru tahmin edilirken 17 tanesi Kadın olarak yanlış tahmin edilmiştir. Kadın olan 628 verinin 599 tanesi Kadın olarak doğru tahmin edilirken 29 tanesi Erkek olarak yanlış tahmin edilmiştir. Tüm veri setine bakıldığı

zaman, 1267 veriden 1221 veri doğru tahmin edilirken 46 veri yanlış tahmin edilmiştir.

Şekil 7'de, NB modeline ait doğru ve yanlış tahmin edilen verilerin grafik olarak gösterimi verilmiştir. Tahmin modelinin sınıflandırıcı hata grafiğine bakıldığında, 17 Erkek 29 Kadın olmak üzere 46 hata yapıldığı görülmektedir. 17 Erkek çıktının Kadın olarak tahmin edildiği ve 29 Kadın çıktının ise Erkek olarak tahmin edildiği görülmektedir.



Şekil 7. NB modeli yanlış ve doğru tahminlerin dağılımı

2.4.3. KNN modeli

KNN modeli oluşturmak için Şekil 8'de verilen kodlar geliştirilmiştir. Aynı zamanda, test ve eğitim verisine göre hangi küme sayılarının en yüksek veya en düşük başarı oranı vereceğini gösteren grafikleri çizdirmek için de kullanılmıştır. Bu süreçte modelin başarı oranı da analiz edilmiştir. En yakın küme sayısı 2 olarak ele alınmıştır.

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt

data = pd.read_csv("ses.csv")

data.drop(["meanfreq", "median", "Q75", "skew", "kurt", "sp.ent", "sfm",
           "mode", "centroid", "minfun", "maxfun", "meandom",
           "mindom", "maxdom", "dfrange", "modindx"], axis=1, inplace=True)
data.label = [1 if each == "male" else 0 for each in data.label]

y = data.label.values
x_data = data.drop(["label"], axis=1)

x = (x_data - np.min(x_data)) / (np.max(x_data) - np.min(x_data))

from sklearn.model_selection import train_test_split
x_train, x_test, y_train, y_test = train_test_split(x, y, test_size=0.6, random_state=1)

from sklearn.neighbors import KNeighborsClassifier
knn = KNeighborsClassifier(n_neighbors=2)
knn.fit(x_train, y_train)

prediction = knn.predict(x_test)

print("{} n-neighbors score: {}".format(3, knn.score(x_test, y_test)))

score_listesi = []
for each in range(1, 20):
    knn2 = KNeighborsClassifier(n_neighbors=each)
    knn2.fit(x_train, y_train)
    score_listesi.append(knn2.score(x_test, y_test))

from sklearn import metrics
cmf_matrix = metrics.confusion_matrix(y_test, prediction)

import seaborn as sns
import matplotlib.pyplot as plt

plt.figure(figsize=(9, 9))
sns.heatmap(cmf_matrix, annot=True, fmt=".0f", linewidths=.5, square=True, cmap="Blues_r");
plt.ylabel('Gerçek');
plt.xlabel('Tahmin');
plt.title('Accuracy Score: {}'.format(metrics.accuracy_score(y_test, prediction)));
plt.title('all sample title, size = 15');

print("Dogruluk-Accuracy: ", metrics.accuracy_score(y_test, prediction))
print("Hassasiyet-Precision: ", metrics.precision_score(y_test, prediction))
print("Dogru tanımlama oranı-Recall: ", metrics.recall_score(y_test, prediction))
```

Şekil 8. KNN yöntemi Python kodu

KNN sınıflandırma yönteminde dağılım (scatter) grafiği, dendrogram ve kol grafiği Şekil 9'daki kodlar ile çizdirilmiştir.

```
from sklearn import datasets
import pandas as pd
import matplotlib.pyplot as plt

ses=pd.read_csv("ses.csv",sep=",")
data=ses.loc[:,["sd","meanfun","IQR","Q25"]]

def yeni(x):
    if (x=="Male"):
        return 1
    else:
        return 0

ses["gercek_deger"]=ses["label"].apply(yeni)
###

plt.scatter(data.sd,data.meanfun,data.Q25,data.IQR)
plt.show()

# %% KMEANS

from sklearn.cluster import KMeans
wcss = []

for k in range(1,10):
    kmeans = KMeans(n_clusters=k)
    kmeans.fit(data)
    wcss.append(kmeans.inertia_)

plt.plot(range(1,10),wcss)
plt.xlabel("k degerleri yani kümeler (cluster)")
plt.ylabel("wcss")
plt.show()

### k = 2 için modelim


kmeans2 = KMeans(n_clusters=2)
clusters = kmeans2.fit_predict(data)

###dendrogram

from scipy.cluster.hierarchy import linkage,dendrogram
merg=linkage(data,method="ward")
dendrogram(merg,leaf_rotation=90)
plt.xlabel("data points")
plt.ylabel("uzaklık öklit uzaklığı")
plt.show()
```

Şekil 9. KNN dağılım, dendrogram ve kol grafiği Python kodları


Şekil 10'da, Meanfun (turkuaz), Q25 (mor), IQR (sarı) ve Sd(açık yeşil) verilerinin dağılımı görülmektedir. Meanfun ve Q25 verilerinin daha sık olduğu ve birbirine yakın olduğu görülmektedir.



Şekil 10. Meanfun, Q25, IQR ve Sd verilerinin dağılımı


Şekil 11'de, Meanfun, Q25, IQR ve Sd giriş değerleri temel alınarak çizdirilen kol grafiği incelendiğinde doğru 2 üzerinde kırılarak gittikçe düzleşmiştir. Bir

diğer kırılma 3 kümede gerçekleşmiştir. Bu kırılmaların amacı veri setinin 2 kümeden ya da 3 kümeden oluştuğunu göstermektir. Kol grafiğinde ilk keskin kırılma değeri ele alındığı için ilk kırılma 2 de gerçekleşmiştir. Bu bağlamda küme değeri 2 seçilirse modelin başarılı bir sonuç vereceğini göstermektedir.




Şekil 11. Kol grafiği

Şekil 12'de, dendrogram grafiğinden küme sayısının kaç olması gerektiği görülebilmektedir. İlk olarak en uzun kenara bir doğru çizilir. Çizilen doğrunun kesişme noktaları ele alınır. Kesişme noktalarının sayısı KNN sınıflandırma yönteminde en yüksek başarı oranının hangi küme sayısında elde edileceğini göstermektedir. Çizilen doğruyu kesen 2 nokta bulunduğu için küme değeri 2 seçilmiştir.



Şekil 12. Dendrogram grafiği

Şekil 13'te, k değerlerinin çıkacak başarı değerleri gösterilmektedir. Grafik kodlanırken k değer aralığı 1-20 olarak belirlenmiştir. Küme sayısı 2 seçilirse elde edilecek en yüksek başarı oranı %96 civarında olacağı, 17 seçilirse en düşük başarı oranı %93 civarında olacağı görülmektedir. Bu grafik elde edildikten sonra oluşturulan modelin kümesi 2 olarak belirlenmiştir.



Şekil 13. k değerlerine göre başarı

Tablo 6. KNN performans sonuçları

Ölçüt	Değer
Başarı Oranı	96.764 %
Doğru Sınıflandırılmış Örnekler	1226
Kappa İstatistiği	0.935
Ortalama Mutlak Hata (MAE)	0.03
Kök Ortalama Kare Hatası (RMSE)	0.151
Görelili Mutlak Hata (RAE)	5.89%
Kök Görelili Kare Hatası (RRSE)	30.250%
Toplam Örnek Sayısı	1267
Küme Sayısı	2
Modeli oluşturmak için geçen süre	4,4 sn

Bu modelde %96.764 oranında bir doğru tahmin başarısı elde edilmiştir. Kadın ve Erkek değerlerinin arasındaki karşılaştırmalı uyuşmanın güvenilirlik oranı 0.935'dür. Elde edilen değer 0.81-1. 00 aralığında olduğu için Kadın ve Erkek değerleri arasında neredeyse mükemmel bir uyuşma olduğu görülmektedir.

Tahmin sonucunda elde edilen ortalama mutlak hata oranı (MAE) 0.03'dir. Tahmin sonucunda elde edilen karekök ortalama hata oranı (RMSE) 0.151'dür. Tahmin sonucunda gerçek değer ile hesaplanan değer arasındaki farkın gerçek değere oranlanması (RAE) sonucunda 0,589 değeri elde edilmiştir. MAE, RMSE ve RAE değerleri 0'a yakın olduğu için tahmin edilen modelin başarılı olduğu söylenebilir. Tahmin sonucunda kök göreceli hata oranı (RRSE) 30.250 dür. Bu değer 0'a çok yakın olmasa da diğer metriklerin 0'a yakın olmasından dolayı modelin başarı oranını çok etkilememiştir.

Karışıklık matrisi ve diğer formülasyon sonuçları Tablo 7'de verilmiştir.

Tablo 7. KNN karışıklık matrisi bulguları

TP Oranı	FP Oranı	Kesinlik	Duyarlılık	F-Ölçüm	MCC	ROC	PRC	Sınıf
0.98	0.04	0.95	0.98	0.96	0.93	0.98	0.97	Erkek
0.95	0.02	0.97	0.95	0.96	0.93	0.98	0.97	Kadın

TP Oranı: Tahmin sonucunda sınıfı Erkek olan verilerden Erkek sesini Erkek sesi olarak tahmin etme oranı 0,980'dir. Sınıfı Kadın olan verilerden Kadın sesini Kadın sesi olarak tahmin etme oranı 0,955'dir. Bu değerler 1'e yakın olduğu için iyi bir başarı oranı elde edildiği görülmektedir. K-Nearest Neighbor (KNN) sınıflandırma yöntemi sonucunda, verilerin tamamına yakın bir kısmını doğru tahmin ettiği görülmektedir. Aynı zamanda Kadın ve Erkek sınıflarında en çok doğru tahmin yapılan sınıfın Erkek olduğu görülmüştür.

FP Oranı: Tahmin sonucunda sınıfı Erkek olan verilerden Erkek sesini Kadın sesi olarak tahmin etme oranı 0,045'dir. Sınıfı Kadın olan verilerden Kadın sesini Erkek sesi olarak tahmin etme oranı 0,020'dir. Bu değerler 0'a yakın olduğu için yapılan hatalı tahminin oldukça düşük olduğu görülmektedir. Aynı zamanda Erkek ve Kadın sınıfları arasında en çok hata yapılan sınıfın Erkek olduğu görülmüştür.

Kesinlik: Tahmin sonucunda Erkek sınıfı hassasiyet oranı 0,957 iken Kadın sınıfı hassasiyet oranı 0,979'dur. Hassasiyet oranları 1'e yakın olduğu için sınıflandırma modelinin yüksek oranda tahmin başarısı gösterdiği söylenebilir. Sınıfı Kadın olan verilerin hassasiyet oranı daha yüksektir.

Duyarlılık: Tahmin sonucunda Erkek sınıfı geri çağırma oranı 0,980 iken Kadın sınıfı geri çağırma oranı 0,955'dir. Yani bu durum, gerçekte sesin Erkek olduğu durumda tahminin Kadın sesi olarak yapılmasıdır. Burada hata oranı 0'a yaklaştıkça artar, 1'e yaklaştıkça azalır. Bu durumda sınıflandırma modelinin doğru tahmin yaptığı görülmektedir. Erkek sınıfına ait veriler daha doğru tahmin edilmiştir.

F-Ölçüm: Tahmin sonucunda Erkek sınıfı F-Measure oranı 0,968, Kadın sınıfı oranı 0,967 çıkmıştır. Bu değerlerin 1'e yakın olması tahmin modelinin başarılı olduğunu göstermektedir.

Matthew's Korelasyon Katsayısı: Tahmin sonucunda Erkek ve Kadın sınıfı MCC oranı 0,936 çıkmıştır. Bu değerlerin 1'e yakın olması tahmin modelinin başarılı olduğunu göstermektedir.


ROC Alanı: Tahmin sonucunda Erkek ve Kadın sınıfı ROC Area oranı 0,983 çıkmıştır. Bu değerlerin 1'e yakın olması tahmin modelinin başarılı olduğunu göstermektedir.

PRC Alanı: Tahmin sonucunda Erkek sınıfının PRC Area oranı 0,977 ve Kadın sınıfı PRC Area oranı 0,972 çıkmıştır. Bu değerlerin 1'e yakın olması yapılan tahmin modelinin başarılı olduğunu göstermektedir.

Karışıklık Matrisi: Karışıklık Matrisi kısmında oluşturulan test ve eğitim kümeleri sonucunda label parametresinde bulunan Erkek ve Kadın

tahminlerindeki başarı görülmektedir. Erkek olan 639 verinin 626 tanesi Erkek olarak doğru tahmin edilirken 13 tanesi Kadın olarak yanlış tahmin edilmiştir. Kadın olan 628 verinin 600 tanesi Kadın olarak doğru tahmin edilirken 28 tanesi Erkek olarak yanlış tahmin edilmiştir. Tüm veri setine bakıldığı zaman, 1267 veriden 1226 veri doğru tahmin edilirken 41 veri yanlış tahmin edilmiştir.


Şekil 14'te yanlış tahmin edilen verilerin grafik olarak gösterimi verilmiştir. Tahmin modelinin sınıflandırıcı hata grafiğine göre, 28 Erkek 13 Kadın olmak üzere 41 hata yapıldığı, 28 Erkek çıktı Kadın olarak tahmin edildiği ve 13 Kadın çıktı ise Erkek olarak tahmin edildiği görülmektedir.



Şekil 14. KNN modeli yanlış ve doğru tahminlerin dağılımı

2.4.4. YSA-çok katmanlı algılayıcı modeli

YSA Çok Katmanlı Algılayıcı algoritmasından makineye veri setinin sonucu bilinen değerlerin %75'ini eğitim kümesi vererek %25'ini tahmin etmesi istenmiştir. Label parametresi üzerinden de sınıflandırması yapılmıştır. Örnekte momentum değeri 0.5, learningRate değeri 0.4, hiddenLayers değeri 1,2,3, trainingTime değeri 100 alınmıştır. Şekil 15'te, oluşturulan ve önerilen YSA modeli verilmiştir.



Şekil 15. YSA modeli

Tablo 8. YSA performans sonuçları

Ölçüt	Değer
Başarı Oranı	98.962%
Doğru Sınıflandırılmış Örnekler	1237
Kappa İstatistiği	0.853
Ortalama Mutlak Hata	0.028
Kök Ortalama Kare Hatası	0.04
Görelî Mutlak Hata	5.508%
Kök Görelî Kare Hatası	17.963%
Toplam Örnek Sayısı	1267

Momentum	0.5
LearningRate	0.4
HiddenLayers	1,2,3
TrainingTime	100
Modeli oluşturmak için geçen süre	3.7 sn

Bu modelde, %98.96'lık yüksek bir başarı oranı elde edilmiştir. Kadın ve Erkek değerlerinin arasındaki karşılaştırmalı uyuşmanın güvenilirlik oranı (Kappa Statistic) 0.853'dir. Elde edilen değer 0.81-1.00 aralığında olduğu için Kadın ve Erkek değerleri arasında önemli derecede bir uyuşma olduğu görülmektedir. Tahmin sonucunda elde edilen ortalama mutlak hata oranı (MAE) 0.028'dir. Tahmin sonucunda elde edilen karekök ortalama hata oranı (RMSE) 0.04'dir. Tahmin sonucunda gerçek değer ile hesaplanan değer arasındaki farkın gerçek değere oranlanması (RAE) sonucunda 0.551 değeri elde edilmiştir. MAE, RMSE ve RAE değerleri 0'a yakın olduğu için tahmin edilen modelin başarılı olduğu söylenebilir. Tahmin sonucunda kök göreceli hata oranı (RRSE) 17.963'dir. Bu değer 0'a çok yakın olmasa da diğer metriklerin 0'a yakın olmasından dolayı modelin başarı oranını çok etkilememiştir.

Karışıklık matrisi ve diğer formülasyon sonuçları Tablo 9'da verilmiştir.

Tablo 9. YSA karışıklık matrisi bulguları

TP Oranı	FP Oranı	Kesinlik	Duyarlılık	F-Ölçüm	MCC	ROC	PRC	Sınıf
0.99	0.01	0.99	0.98	0.99	0.97	0.99	0.99	Erkek
0.99	0.02	0.98	0.99	0.98	0.97	0.99	0.99	Kadın

TP Oranı: Tahmin sonucunda sınıfı Erkek olan verilerden Erkek sesini Erkek sesi olarak tahmin etme oranı 0,989'dir. Sınıfı Kadın olan verilerden Kadın sesini Kadın sesi olarak tahmin etme oranı 0,987'dir. Bu değerler 1'e yakın olduğu için iyi bir isabet oranı elde edildiği görülmektedir. Yapılan YSA Çok Katmanlı Algılayıcı yöntemi sonucunda verilerin tamamına yakın bir kısmını doğru tahmin ettiği görülmektedir. Aynı zamanda Kadın ve Erkek sınıflarında en çok doğru tahmin yapılan sınıfın Erkek olduğu görülmüştür.

FP Oranı: Tahmin sonucunda sınıfı Erkek olan verilerden Erkek sesini Kadın sesi olarak tahmin etme oranı 0,012'dir. Sınıfı Kadın olan verilerden Kadın sesini Erkek sesi olarak tahmin etme oranı 0,018'dir. Bu değerler 0'a yakın olduğu için yapılan hatalı tahminin oldukça düşük olduğu görülmektedir. Aynı zamanda Erkek ve Kadın sınıfları arasında en çok hata yapılan sınıfın Erkek olduğu görülmüştür.

Kesinlik: Tahmin sonucunda Erkek sınıfı hassasiyet oranı 0,986 iken Kadın sınıfı hassasiyet oranı 0,984'dir. Hassasiyet oranları 1'e yakın olduğu için sınıflandırma modelinin yüksek oranda tahmin

başarısı gösterdiği söylenebilir. Sınıfı Erkek olan verilerin hassasiyet oranı daha yüksektir.

Duyarlılık: Tahmin sonucunda Erkek sınıfı geri çağırma oranı 0,982 iken Kadın sınıfı geri çağırma oranı 0,989'dur. Yani bu durum, gerçekte sesin Kadın olduğu durumda tahminin Erkek sesi olarak yapılmasıdır. Bu hata 0'a yaklaştıkça artar 1'e yaklaştıkça azalır. Bu durumda sınıflandırma modelinin doğru tahmin yaptığı görülmektedir. Erkek sınıfına ait veriler daha doğru tahmin edilmiştir.

F-Ölçüm: Tahmin sonucunda Erkek sınıfı için F-Measure oranı 0,986, Kadın sınıfı için ise 0,985 çıkmıştır. Bu değer 1'e yakın olması yapılan tahmin modelinin başarılı olduğunu göstermektedir. Erkek sınıfına ait verilerde daha fazla başarı elde edilmiştir.


Matthew's Korelasyon Katsayısı: Tahmin sonucunda Erkek sınıfı için MCC oranı 0,975 ve Kadın sınıfı için ise 0,973 çıkmıştır. Bu değer 1'e yakın olması tahmin modelinin başarılı olduğunu göstermektedir.

ROC Alanı: Tahmin sonucunda Erkek sınıfı için ROC Area oranı 0,993 ve Kadın sınıfı için 0,991 çıkmıştır. Bu değer 1'e yakın olması tahmin modelinin başarılı olduğunu göstermektedir.

PRC Alanı: Tahmin sonucunda Erkek sınıfı PRC Area oranı 0,994 iken Kadın sınıfı PRC Area oranı 0,989 çıkmıştır. Bu değer 1'e yakın olması tahmin modelinin başarılı olduğunu göstermektedir. Kadın sınıfına ait verilerde daha fazla başarı elde edilmiştir.

Karışıklık Matrisi: Karışıklık Matrisi kısmında oluşturulan test ve eğitim kümeleri sonucunda label parametresinde bulunan Erkek ve Kadın tahminlerindeki başarı görülmektedir. Erkek olan 639 verinin 631 tanesi Erkek olarak doğru tahmin edilirken 8 tanesi Kadın olarak yanlış tahmin edilmiştir. Kadın olan 628 verinin 616 tanesi Kadın olarak doğru tahmin edilirken 12 tanesi Erkek olarak yanlış tahmin edilmiştir. Tüm veri setine bakıldığı zaman, 1267 veriden 1247 veri doğru tahmin edilirken 20 veri yanlış tahmin edilmiştir.

Şekil 16'da, yanlış tahmin edilen verilerin grafik olarak gösterimi verilmiştir. Tahmin modelinin sınıflandırıcı hata grafiğine göre, 12 Erkek 8 Kadın olmak üzere 20 hata yapıldığı. 13 Erkek çıktı Kadın olarak tahmin edildiği ve 7 Kadın çıktı ise Erkek olarak tahmin edildiği görülmektedir.



Şekil 16. YSA modeli yanlış ve doğru tahminlerin dağılımı

3. Bulgular ve Tartışma

Bu bölümde, KA, NB, KNN ve YSA modelleri üzerinde gerçek ve farklı veriler kullanılarak gerçekleştirilen deneysel testlerden elde edilen bulguların tüm ayrıntılarına yer verilmiştir. Test sonuçlarından önce her bir model için kullanılan özellikler Tablo 10'da bulunmaktadır.

Tablo 10. Her bir model için kullanılan özellikler

	Test 1	Test 2
KA		
Yaprak ve Dal Sayısı	12-23	6-11
Yaprak Başına Düşen Minimum Obje Sayısı	10	45
NB		
-	-	-
KNN		
Küme Sayısı	3	6
YSA		
Momentum	1	0.7
Learningrate	0.5	0.4
Hiddenlayers	2,3	5,4,3
Trainingtime	50	35

Test sonuçları incelendiğinde (Tablo 11), eğitim seti oranı daha fazla olan testin başarı oranı daha fazla olduğu görülmektedir. Burada, tahmin modelinin eğitim verisi oranını arttırdıkça elde edilen başarı oranının arttığı, azalttıkça da hata oranının arttığı görülmüştür.

Ayrıca, yaprak başına düşen minimum obje sayısı arttırıldıkça karışık veri setlerinde başarı oranı artarken karışık olmayan veri setlerinde bu oran düşmüştür. Gerçek pozitif oran, hassasiyet oranı, geri bildirme oranı, f-ölçüsü oranı, MCC oranı, ROC alan oranı ve RPC alan oranı 1'e yaklaşması modelin başarılı olduğunu ortaya koymaktadır. Yanlış pozitif oran 0'a yaklaştıkça da modelin başarı oranı artarken 1'e yaklaştığında bu oran düşer. Dolayısıyla, tüm bu ölçütler çerçevesinden, KA1 ve NB2 modellerinde diğerlerine nazaran daha başarılı sonuçlar elde edilmiştir.

Tablo 11. Tüm modellerden elde edilen test sonuçları

	KA 1	KA 2	NB 1	NB 2	KNN 1	KNN 2	YSA 1	YSA 2
Model Oluşturmak için Harcanan Zaman	0.01 sn	0.01 sn	0.0 sn	0.01 sn	0.1 sn	0.01 sn	5.7 sn	2.57 sn
Başarı Oranı	%96.68	%94.11	%95.92	%96.06	%82.38	%62.55	%50	%88.76
Kappa İstatistik	0.934	0.793	0.919	0.921	0.65	0.251	0	0.775
Ortalama Mutlak Hata	0.048	0.095	0.049	0.048	0.20	0.420	0.5	0.366
Kök Ortalama Kare Hatası	0.17	0.233	0.182	0.18	0.362	0.491	0.707	0.38
Görelî Mutlak Hata	%9.55	%19.05	%9.69	%9.59	%39.94	%84.01	%99.99	%73.20
Kök Görelî Kare Hatası	%33.85	%46.66	%36.52	%35.90	%72.44	%98.16	%141.42	%75.96
Ortalama Gerçek Pozitif Oran	0.967	0.941	0.959	0.961	0.824	0.626	0.500	0.888
Ortalama Yanlış Pozitif Oran	0.033	0.060	0.041	0.039	0.176	0.374	0.500	0.112
Ortalama Hassasiyet Oranı	0.967	0.944	0.960	0.961	0.825	0.636	0.500	0.888
Ortalama Geri Bildirme	0.967	0.941	0.970	0.961	0.824	0.626	0.500	0.888
Ortalama F-Ölçüsü	0.967	0.941	0.959	0.961	0.824	0.618	0.467	0.888
Ortalama MCC	0.934	0.885	0.919	0.922	0.649	0.261	0.000	0.775
Ortalama ROC Area	0.987	0.941	0.991	0.991	0.887	0.670	0.500	0.942
Ortalama RPC Area	0.983	0.916	0.991	0.991	0.852	0.634	0.500	0.933

Tablo 12’de, konuyla ilgili literatürde yer alan bazı çalışmalar ve son satırda önerilen çalışma hakkında özet bilgilere yer verilmiştir. Bu tabloda yer alan çalışmalarda, veriler genelde Kaggle açık kaynak web sitesinden elde edilmiş olup farklı kaynaklardan da yararlanılmıştır. Söz konusu verilerin eksiksiz ve temiz olması nedeniyle ön işleme süreci gerçekleştirilmemiştir. Bu noktada çalışmada da Kaggle açık kaynak platformundan elde edilen veriler kullanılmış olup ekstra bir ön işleme işlemi yapılmamıştır. Tablo 12’de yer alan tüm çalışmalar birbirine yakın sonuçlar elde etmekle birlikte, özellikle [6], [29] ve [30] referans numaralı çalışmalar önerilen çalışmaya oldukça yakın performans göstermiştir. Bununla birlikte [30] referans numaralı çalışmada diğerlerine nazaran en düşük performans

elde ettiği görülmektedir. Aslında, tüm çalışmalarda aynı veri kullanılması halinde yapılan bu çalışmaların karşılaştırmaları daha anlamlı olacaktır. Yine de çalışmayla aynı başlık ve içerikte yapılmış çalışmaların ortaya konulması bakımından Tablo 12 önemli görülmektedir. Gerçekleştirilen çalışmalar içerisinde, [4],[6],[27] ve önerilen çalışmada veri sayısı bakımından aynı sayıda veri kullanılmış olup yine en yüksek başarı oranı önerilen çalışmadan elde edildiği görülmektedir. Son olarak makine öğrenmesi çalışmalarında veri seti oldukça önemlidir. Veri sayısı arttıkça modelin başarısı da artacaktır. Bu çerçevede, özellikle [28] referans numaralı çalışma bu duruma kanıt niteliği taşımaktadır.

Tablo 12. Önerilen modelin literatürdeki modellerle karşılaştırılması

No	Yazar(lar)\Yıl	Yöntem (Kullanılan Algoritmalar)	En Başarılı Algoritma	Doğruluk (%)	Veri Sayısı
1	Özbay ve Özbay (2023) [4]	Parçacık Sürüsü Optimizasyonu (PSO), Karınca Koloni Optimizasyonu (KKO), Salp Sürüsü Algoritması (SSA) ve Balina Optimizasyonu Algoritması (BOA)	Balina Optimizasyonu Algoritması (BOA)	97,6	3168
2	Tümen (2022) [6]	Ani Sivri Uçlu Sinir Ağları ile Önerilen Yaklaşım	Ani Sivri Uçlu Sinir Ağları ile Önerilen Yaklaşım	98,84	3168
3	Kuncan ve diğ. (2019) [26]	Destek Vektör Makinesi (SVM), Rastgele Orman (RF), YSA (YSA), KNN (KNN)	KNN (KNN)	97,28	9120
4	Babalola ve diğ. (2022) [27]	Lojistik Regresyon, Uzun Kısa-Süreli Hafıza (LSTM), Çok Katmanlı Algılayıcı (MLP)	Lojistik Regresyon	97,1	3168
5	Hızlısoy ve diğ. (2022) [28]	Destek Vektör Makinesi (SVM), YSA (YSA), Lojistik Regresyon, Doğrusal Regresyon, Rastgele Orman (RF), AdaBoost, Karar Mantiğı, CNN, KNN, Genetik Algoritma ve DNN	Lojistik Regresyon	89,0	894

6	Nabiyev ve Yüesoy (2009) [29]	Vektör Kuantizasyonu (VQ) ve Gauss Karışım Modeli (GMM)	Vektör Kuantizasyonu	98,80	1680
7	Bakır (2016) [30]	Saklı Markov Modelleri (Hidden Markov Models-HMM), Dinamik Zaman Bükmesi (Dynamic Time Warping-DTW) ve Gauss Mixture Models (Gauss Karışım Modeli-GMM)	Saklı Markov Modelleri (Hidden Markov Models-HMM)	98,34	2658
8	Calp (2024) Önerilen Model	KNN (K-NN), KA (KA), NB (NB) ve YSA (YSA)	YSA (YSA)	98.96	3168

4. Sonuç ve Öneriler

Bu çalışmada, makine öğrenmesi modelleri içerisinde yer alan tahmin ve sınıflandırma tekniklerinden KA, KNN, NB ve YSA-Çok Katmanlı Algılayıcı kullanılarak ses ve konuşma analizi ile kişilerin cinsiyetleri tahmin edilmiştir. Oluşturulan her model için kendi içerisinde farklı şekillerde analizler yapılarak sonuçlar üretilmiştir. Böylece hem makine öğrenmesi hem de ses tanıma konularında bir altyapı oluşturabileceği ve ses tanıma gibi problemlerin makine öğrenmesi yöntemleriyle çözülebileceği gösterilmiştir. Bununla birlikte, konuyla ilgili örnek bir model sunarak yeni bir bakış açısı kazandırılmıştır. Makine öğrenmesinin ses tanıma uygulama alanlarında kullanımını bu örnekler ile sınırlamak mümkün değildir. Kaggle üzerinden temin edilen veri setine Python kodlarıyla modeller oluşturulmuş ve makine öğrenmesi algoritmaları uygulanmıştır. Bütün önileme ve veri hazırlama süreçlerinin tamamlanmasının ardından sonra veri seti üzerinde çeşitli algoritmalar uygulanarak oluşturulan modellere göre en başarılı algoritmanın YSA-Çok Katmanlı Algılayıcı algoritması olduğu görülmüştür. Kullanılan algoritmaların eğitim-test ve başarı oranları göz önüne alındığında, en yüksek tahmin ve sınıflandırma başarısının, %97.6322'lik yüksek bir başarı oranı ile %75 eğitim-%25 test verisi alınarak oluşturulan YSA-Çok Katmanlı Algılayıcı modelinden elde edildiği görülmüştür. İkinci sırada en iyi başarı, %97.0008'lik bir oranla KA algoritması kullanılarak elde edilmiştir. YSA Çok Katmanlı Algılayıcı algoritmasında başarı değerlerinin oranları sadece test-eğitim setinin farklı olmasından değil, aynı zamanda katman sayısı, momentum katsayısı, öğrenme katsayısı ve adım sayısının farklı olmasından değişiklik göstermiştir. YSA Çok Katmanlı Algılayıcı algoritması gibi kullanılan diğer algoritmalarda kendi içerisinde birçok özelliğe göre sınıflandırılmıştır. Model oluşturma sürecinde, kullanılan algoritmaların karşılaştırılması sonucunda en başarılı algoritmanın YSA olması, bu veri seti kullanılarak ilerleyen çalışmalarda cinsiyete göre ses tanıma çalışma alanlarına yönelik bir uygulama geliştirilmesi ve cinsiyet tespit sürelerinin kısalması araştırmacılara fikir vermesi bakımından oldukça önemli görülmektedir.

Yapılacak diğer çalışmalarda, oluşturulan modelde farklı parametreler girdi değişkeni olarak kullanılabilir. Çalışmada kullanılacak girdi değerleri uç veriler barındırmamalıdır. Sınıflandırma algoritmaları kullanılmadan önce veri seti iyi analiz edilmeli ve aykırı veriler belirlenmelidir. Belirlenen aykırı veriler temizlenmeli veya kullanılacak girdi değerlerinde aykırı veri oranı düşük olmalıdır. Verilerin düzenli dağılım göstermesi başarı oranını arttıracaktır. Özellikle hazır veri seti kullanıldığında, veri setinin güncel olmasına dikkat edilmelidir.

Yapılacak diğer çalışmalarda diğer sınıflandırma teknikleri (Regresyon, Zaman Serisi Analizleri, Genetik Algoritmalar, Kestirim) hibrit olarak kullanılarak çıktı tahmin edilmeye çalışılabilir. Kullanılacak sınıflandırma teknikleri veri setinin büyüklüğü, karmaşıklığı, girdi sayısı, çıktı sayısı ve konusu gibi birçok özelliğe göre değişiklik göstereceği için veri setinin iyi analiz edilmesi ve doğru sınıflandırma yöntemlerinin seçilmesi gerekir. Sonuç olarak, çalışmanın söz konusu alana katkı sunması beklenmektedir.

Kaynakça

- [1] Pacheco, P. 2011. An Introduction to Parallel Programming. Burlington: Morgan Kaufmann Publishers is an imprint of Elsevier.
- [2] Alpaydın, E. 2013. Yapay Öğrenme. İstanbul: MIT, BÜTEK.
- [3] Erdoğan, İ., Güllü, M., & Polat, H. 2022. Makine Öğrenmesi Algoritmaları ile Uçtan Uca Yazar Tanıma Uygulaması Geliştirme. *El-Cezeri*, 9(4), 1303-1314.
- [4] Özbay, F. A., & Özbay, E. 2023. Ses verilerinden cinsiyet tespiti için yeni bir yaklaşım: Optimizasyon yöntemleri ile özellik seçimi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 38(2), 1179-1192.
- [5] Özkaynak, E., Sulak, E. E., & Yılmaz, H., 2018. Temel Bileşenler Analizi Kullanılarak Ses Tanıma ile Cinsiyet Tespiti, *20. Akademik Bilişim 2018 Konferansı Bildirileri* – Karabük Üniversitesi.

- [6] Tümen, V. 2022. Sinaptik Etkinlik Fonksiyon Tabanlı Sızdıran Entegre ve Ateşleme Nöron Modelini Kullanarak İnsan Ses Sinyallerinde Cinsiyet Tespiti. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 11(2), 469-477.
- [7] Açı, T. 2019. Güncel makine öğrenmesi teknikleri ile iris görüntülerinden cinsiyet analizi, *Yüksek Lisans Tezi*, İskenderun Teknik Üniversitesi/Mühendislik ve Fen Bilimleri Enstitüsü/Elektrik-Elektronik Mühendisliği Anabilim Dalı.
- [8] Bektaş, M. 2020. *Derin öğrenme algoritmaları kullanarak yazar, tür ve cinsiyet tanıma (Master's thesis, Tekirdağ Namık Kemal Üniversitesi)*.
- [9] Demirel, Ş., Y. Giray, S. 2019. KA Algoritmaları ve Çocuk İşçiliği Üzerine Bir Uygulama. *Social Sciences Research Journal*, 8 (4), 52-65.
- [10] Sebik, N. B., & Bülbül, H. İ. 2018. Veri Madenciliği Modellerinin Akciğer Kanseri Veri Seti Üzerinde Başarılarının İncelenmesi. *Tünav Bilim Dergisi*, 11(3), 1-7.
- [11] Gürsoy, U. T., & Bilgin, Ş. 2016. Banka Müşterilerinin İnternet Bankacılığına İlişkin Yaklaşımlarının Veri Madenciliği Teknikleri ile İncelenmesi. *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7(14), 421-442.
- [12] Aydın, M. R. 2019. YSA ile Talep Tahmini: Perakende Sektöründe Bir Uygulama. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 18(35), 43-55.
- [13] Akkuş, B., & Zontul, M. 2019. Veri madenciliği yöntemleri ile ülkeleri gelişmişlik ölçütlerine göre kümeleme üzerine bir uygulama. *AURUM Journal of Engineering Systems and Architecture*, 3(1), 51-64.
- [14] Alabdoo, I. N. F. (2024). Parmak Görüntüleri Üzerinden Kişi Yaş ve Cinsiyet Tahmini Yapılması (Master's thesis, Kırşehir Ahi Evran Üniversitesi-Fen Bilimleri Enstitüsü).
- [15] Görgün, M. K., Demirok, G. B., & Kutlu, M. (2023). Türkçe sosyal medya mesajlarından kullanıcıların yaş ve cinsiyetini tahmin etme. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 12(2), 325-333.
- [16] Yılmaz, N., Seçgin, Y., Demirci, R., & Keskin, N. K. (2024). Gender Prediction From Foramen Magnum Using Machine Learning Algorithms. *Celal Bayar Üniversitesi Sağlık Bilimleri Enstitüsü Dergisi*, 11(3), 447-451.
- [17] Kocamış, O. G. (2024). Sakroiliak eklem morfometrisi ve varyasyon tipleri ile makine öğrenme teknikleri kullanılarak cinsiyet ve yaş tayini.
- [18] Temelci, H. (2024). Türk Popülasyonunda Makine Öğrenme Algoritmaları Kullanılarak MDBT Görüntüleri Üzerinde Scapula'nın Antropometrik Ölçümleri ile Cinsiyet Tahmini (Doctoral dissertation, Necmettin Erbakan University (Turkey)).
- [19] Wu, D. 2009. Supplier selection: A hybrid model using DEA, decision tree and neural network. *Expert systems with Applications*, 36(5), 9105-9112.
- [20] Zhao-han, S., & Bing Xiang, L. 2005. Research method of customer churn crisis based on decision tree. *Journal of Management Sciences in China*, 8(2), 20-25.
- [21] Akpınar, H. 2000. Veri tabanlarında bilgi keşfi ve veri madenciliği. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 29(1), 1-22.
- [22] Wang, J. 2006. Encyclopedia of Data Warehousing and Mining. Information Science Reference, Volume: 49, ss: 140.
- [23] Mitchell, T. 1997. "Machine Learning", McGraw Hill, New York.
- [24] Kabalcı, E. 2014. YSA. Ders Notları <https://ekblc.files.wordpress.com/2013/09/ysa.pdf>
- [25] Ağyar, Z. 2015. YSA'nın kullanım alanları ve bir uygulama. *Mühendis ve Makine*, 56(662), 22-23.
- [26] Kuncan, F., Kaya, Y., & Kuncan, M. 2019. Sensör işaretlerinden cinsiyet tanıma için yerel ikili örüntüler tabanlı yeni yaklaşımlar. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 34(4), 2173-2186.
- [27] Babalola, Katende, Bitirim ve Toygar. 2022. Cinsiyet Tanımı için Ses Biyometrisinin Kullanımı, The 14th International Scientific Research Congress - Science and Engineering, 14. Uluslararası Bilimsel Araştırmalar Kongresi Fen ve Mühendislik Bilimleri, UBAK 20-21 Aug. 2022, Proceeding Book Bildiri Tam Metin Kitabı, Editor: Prof. Dr. Bahri Bayram, ASOS Yayınları, Ankara
- [28] Hızlısoy, S., Çolakoğlu, E., & Arslan, R. S. 2022. Speech-to-Gender Recognition Based on Machine Learning Algorithms. *International Journal Of Applied Mathematics Electronics And Computers*, 10(4), 84-92.
- [29] Nabyev, V., & Yücesoy, E. 2009. VQ Yöntemiyle Konuşmacı Cinsiyetinin Belirlenmesi. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 1(1).
- [30] Bakır, Ç. 2016. Alman dili üzerinde konuşmacı cinsiyetinin otomatik olarak belirlenmesi. *Academic Platform-Journal of Engineering and Science*, 4(2).