

# İşitme Kaybı Tahmininde Makine Öğrenmesi Yöntemlerinin Uygulanması ve Karşılaştırılması

Yasin TATLI<sup>1</sup>

<sup>1</sup>Avrasya Üniversitesi, Sağlık Hizmetleri Meslek Yüksekokulu, Tıbbi Hizmetler ve Teknikler Bölümü, Odyometri Programı, Trabzon, Türkiye  
Yasin.tatli@avrasya.edu.tr

(İlk Geliş Tarihi 07.11.2024 ve Kabul Tarihi 26.02.2025)

(DOI: 10.35354/tbed.1580891)

**ATIF/REFERENCE:** Tatlı, Y. (2025). İşitme Kaybı Tahmininde Makine Öğrenmesi Yöntemlerinin Uygulanması ve Karşılaştırılması. *Teknik Bilimler Dergisi*, 15 (1), 21-26.

## Öz

İşitme kaybının hızlı ve doğru bir şekilde tespiti, bireylerin yaşam kalitesini artırmak, sosyal ve bilişsel fonksiyonları korumak için kritik öneme sahiptir. Geleneksel işitme testleri uzun ve maliyetli süreçler gerektirirken, makine öğrenmesi tabanlı yaklaşımlar, tanıyı hızlandırma ve doğruluğu artırma potansiyeline sahiptir. Bu çalışmada, Logistic Regression, Decision Tree, ExtraTrees, SVM ve Gradient Boosting algoritmaları test edilmiştir. Gradient Boosting ve SVM modelleri %94 ve %93 doğruluk oranlarına ulaşmış; 0.97 precision ve 0.86 recall değerleriyle en iyi sonuçları sağlamıştır. Çalışma, makine öğrenmesinin sağlık bilişiminde işitme kaybı tanısı için güvenilir bir araç olarak kullanılabileceğini gösterirken, erken teşhise yönelik önemli bir katkı sunmaktadır.

**Anahtar Kelimeler:** İşitme kaybı, makine öğrenmesi, sınıflandırma modelleri, sağlık bilişimi

## Application and Comparison of Machine Learning Methods in Hearing Loss Prediction

### Abstract

The rapid and accurate detection of hearing loss is critical for improving individuals' quality of life and preserving social and cognitive functions. Traditional hearing tests require lengthy and costly procedures, whereas machine learning-based approaches hold the potential to expedite diagnosis and enhance accuracy. In this study, Logistic Regression, Decision Tree, ExtraTrees, SVM, and Gradient Boosting algorithms were tested. The Gradient Boosting and SVM models achieved accuracy rates of 94% and 93%, respectively, with the best performance reflected by precision of 0.97 and recall of 0.86. The findings demonstrate that machine learning can serve as a reliable tool for diagnosing hearing loss in health informatics and contribute significantly to early detection efforts.

**Keywords:** Hearing Loss, Machine Learning, Classification Models, Health Informatics

## 1. Giriş

İşitme kaybı, bireylerin sosyal yaşamdan bilişsel gelişime kadar geniş bir yelpazede olumsuz etkiler yaratan yaygın bir sağlık sorunudur [13,14,15]. Dünya Sağlık Örgütü'ne göre, dünya genelinde yüz milyonlarca insan işitme kaybı yaşamaktadır ve bu durum özellikle yaşlı bireylerde yaygındır. İşitme kaybı, iletişim becerilerini sınırlandırarak sosyal izolasyon, depresyon ve bilişsel gerilemeye yol açabilmektedir. İşitme kaybının doğru teşhisi, bireylerin erken tedavi alabilmesi için kritik bir adımdır (Akmeşe, 2015). Ancak geleneksel işitme testleri uzmanlar tarafından uygulanmakta ve zaman alıcı, maliyetli süreçler içermektedir. Bu testler, özellikle nüfusun geniş bir kısmına erişimi zorlaştırabilir ve teşhis süreçlerini geciktirebilir. Günümüzde makine öğrenmesi ve yapay zeka tekniklerinin sağlık alanında kullanımıyla bu süreçler daha hızlı ve etkili hale getirilebilmektedir [11, 12]. Yapay zeka tabanlı sistemler, bireylerin işitme verilerini analiz ederek teşhisi hızlandırmakta ve doğru sonuçlar sunmaktadır [10]. Bu tür teknolojik gelişmeler, işitme sağlığı hizmetlerine erişimi kolaylaştırmakta ve özellikle risk altındaki bireylerin erken tanı olarak yaşam kalitelerinin korunmasını sağlamaktadır.

Makine öğrenmesi, sağlık verileri gibi karmaşık veri setlerinde kalıpları tanımlama ve sınıflandırma süreçlerinde sıklıkla kullanılmaktadır. İşitme kaybı teşhisinde makine öğrenmesi algoritmalarının uygulanması, veri özelliklerinden öğrenerek sınıflandırma yeteneklerinin geliştirilmesine olanak tanımaktadır. Yaş, cinsiyet, işitme testi sonuçları gibi bireylere ait demografik ve klinik verilerin kullanımı, işitme kaybının varlığını belirlemede önemli özellikler sunmaktadır. Bu bağlamda, veri madenciliği ve sınıflandırma tekniklerinin işitme sağlığı alanında tanı sistemlerine entegre edilmesi, daha hızlı ve etkili bir teşhis süreci sağlayabilir. Bu çalışmanın amacı, işitme kaybı teşhisinde farklı makine öğrenmesi algoritmalarının performansını karşılaştırarak, hangi modelin en yüksek doğruluğu sunduğunu tespit etmektir. Bu amaçla, Logistic Regression, Decision Tree, ExtraTrees, Support Vector Machine (SVM) ve Gradient Boosting gibi yaygın kullanılan algoritmalar, işitme kaybını sınıflandırmak için uygulanmıştır. Sınıflandırma performansları precision, recall, F1-Score ve doğruluk gibi metriklerle değerlendirilmiş, en yüksek performansı sunan algoritmalar tespit edilmiştir.

Çalışma, işitme sağlığı alanında makine öğrenmesi uygulamalarına yönelik literatüre katkıda bulunmayı hedeflemektedir. Elde edilen sonuçların, işitme kaybı teşhisinde makine öğrenmesi algoritmalarının klinik kullanımına dair değerli bilgiler sunması beklenmektedir. Ayrıca, sağlık bilişimi ve biyoistatistik alanlarında araştırma yapmak isteyen bilim insanları için bir referans oluşturması amaçlanmıştır.

## 2. Literatür Taraması

Bugüne kadar yapılmış akademik çalışmalar incelendiğinde sağlık alanında makine öğrenmesi yöntemlerinin sıklıkla kullanıldığı görülmektedir. Bu çalışmalar içerisinden odyometri ve işitme kayıpları ile ilgili çalışmalar incelendiğinde önemli bulunan çalışmalar açıklanmıştır. Boven ve ekibi işitme kaybı teşhisini geleneksel klinik ortamdan çıkararak hastaların işitme cihazlarını evde kullanarak kendilerinin ayarlayabileceği bir yöntemi araştırmaktadır. Gaussian Süreç Sınıflandırması kullanılarak, işitme cihazlarıyla yapılan bu testlerin, bir odyolog tarafından yapılan standart testlerden elde edilen sonuçlarla istatistiksel olarak benzer olduğu görülmüştür. Testlerde  $\pm 3$  dB civarında bir fark bulunmuştur; bu, yöntemin güvenilirliğini

desteklemektedir. Yöntem, Bluetooth bağlantılı işitme cihazı ve bir mobil uygulama aracılığıyla çalışmakta, hasta yanıtlarına göre ses seviyesi ve frekansları optimize ederek bireysel eşik eğrileri oluşturmaktadır [6].

Ma ve arkadaşlarının çalışmasında işitme kaybını sınıflandırmak için Auditory Brainstem Response (ABR) test verilerini kullanarak bir derin öğrenme modeli geliştirmiştir. ABR, işitme kaybının tespiti için kullanılan, özellikle iletişim zorluğu yaşayan bebekler, yaşlılar veya engelli bireylerde objektif sonuç veren bir testtir. Araştırmacılar, ABR grafik verilerini derin öğrenme için uygun hale getirmek amacıyla verileri normalize edip tekdüze bir formatta birleştirerek VGG16 modelini eğitmiştir. Modelin hassasiyeti artırılmış, veriler gri tonlamaya çevrilmiş ve gereksiz işaretler kaldırılmıştır. Çalışmada, ABR verileri 10.000 örnekten oluşmuş, 5000'ini normal işitme ve 5000'i işitme kaybı olan bireyler oluşturmuştur. Bu veri, VGG16 modeli ile eğitilmiş ve test edilmiştir; model, 200 epoch ve batch size 8 değerlerinde %84.9 doğruluk ve %85.66 F1 skoru elde etmiştir, bu da modelin işitme kaybını yüksek doğrulukla sınıflandırabileceğini göstermektedir. Sonuçlar, modelin hem klinikte bir ön değerlendirme aracı olarak kullanılabilirliğini hem de ABR verilerine dayalı olarak otolog doktorların hızlıca ikinci bir değerlendirme yapmasına yardımcı olabileceğini göstermektedir (Ma vd., 2023).

Lenatti ve ekibi işitme kaybını konuşma-gürültü testi yoluyla tespit etmek için makine öğrenmesi algoritmalarını kullanmaktadır. Çalışmada yaş, doğru cevap yüzdesi ve ortalama tepki süresi gibi özellikler kullanılarak işitme kaybını sınıflandırmada karar ağacı, lojistik regresyon, rastgele orman (RF), destek vektör makineleri (SVM), k-en yakın komşu (KNN) gibi modeller karşılaştırılmıştır. Rastgele Orman modeli %85 doğruluk, %86 duyarlılık ve %85 özgüllükle en iyi performansı sergilemiştir. Post-hoc analizler, özellikle yaş, doğru cevap sayısı ve tepki süresinin işitme kaybını belirlemede güçlü öngörücü özellikler olduğunu göstermiştir. Özellikle yaş, doğru sınıflandırmalar için en yüksek ağırlığa sahip özellik olarak öne çıkarken, tepki süresi ve doğru cevap oranı da kaybı tahmin etmede önemli roller oynamaktadır. Çalışma, multivariate (çok değişkenli) bir yaklaşımla, bir konuşma-gürültü testinden elde edilen verilerin işitme kaybını tanımlamada etkili olabileceğini ortaya koymaktadır ve daha geniş veri setleri üzerinde model performansının doğrulanması gerektiğini belirtmektedir [5].

Lenatti gerçekleştirdiği tez çalışmasında, konuşma-gürültü testlerine dayalı olarak makine öğrenmesi kullanarak işitme kaybını otomatik tespit etmeyi amaçlamaktadır. Test, kullanıcılardan farklı sinyal-gürültü oranlarında gelen kelimeleri tanımlamalarını isteyerek işitme duyarlılığını ölçer. Araştırmada Destek Vektör Makineleri (SVM), Rastgele Orman (RF) ve lojistik regresyon gibi algoritmalar test edilmiştir. Yaş, ortalama tepki süresi ve doğru cevap yüzdesi gibi özellikler, işitme kaybını öngörmeye en etkili faktörler olarak öne çıkmıştır. RF ve SVM modelleri %85 doğrulukla en iyi sonuçları sunmuştur. Çalışma, mobil tabanlı, kullanıcı dostu işitme değerlendirme araçları geliştirme potansiyelini ortaya koymakla birlikte, daha büyük ve çeşitli veri setleri ile yapılacak ek çalışmaların, modelin doğrulama sürecini güçlendireceğini belirtmektedir [5].

Park ve çalışma arkadaşları, ani işitsel sinir duysal işitme kaybı (ISSNHL) için işitme iyileşme tahmini yapabilmek amacıyla makine öğrenmesi modellerini incelemektedir. Toplamda 227 ISSNHL hastası üzerinde yapılan araştırmada, destek vektör makineleri (SVM), rastgele orman (RF), AdaBoost,

K-en yakın komşu (KNN) ve çok katmanlı algılayıcı (MLP) gibi beş model değerlendirilmiştir. En yüksek doğruluğu (%75,36) ve F-skorunu (0,74) SVM modeli elde etmiş, ardından %73,91 doğruluk ve 0,74 F-skora sahip RF modeli gelmiştir. Sonuçlar, bu modellerin ISSNHL hastalarının işitme iyileşme tahmininde etkili olabileceğini göstermektedir [4].


Bing ve ekibi ani sensörinöral işitme kaybı (SSHL) için işitme iyileşmesini tahmin etmeyi amaçlayan dört farklı makine öğrenme modelini incelemektedir: Lojistik Regresyon (LR), Destek Vektör Makineleri (SVM), Çok Katmanlı Algılayıcı (MLP) ve Derin İnanç Ağı (DBN). Çalışma kapsamında 1220 SSHL hastasından toplanan, demografik bilgilerden işitme test sonuçlarına kadar uzanan 149 özellik kullanılmıştır. En yüksek doğruluk ve AUC değeri (%77,58 doğruluk, 0.84 AUC) DBN modelinde, tüm değişkenlerin kullanıldığı veri setinde elde edilmiştir. Ancak, LR, SVM ve MLP modelleri yalnızca üç değişkenle—başlangıç işitme seviyesi, odyogram ve semptom başlangıcı ile test arasındaki süre—daha iyi performans göstererek erken tanıda pratik bir alternatif sunmuştur. DBN modeli, katmanlar arası özellik çıkarımı yaparak kompleks ilişkileri daha iyi yakalayabilmiş; bu da onu daha geniş veri setlerinde güçlü bir tahmin aracı yapmıştır. Buna karşın, LR modeli, kolay yorumlanabilir olması ve düşük veri gereksinimiyle klinik kullanım için daha uygun görülmüştür. Çalışma, özellikle çok değişkenli analizlerde derin öğrenmenin getirdiği avantajlara işaret etmekte olup, ilerleyen dönemlerde genomik veriler gibi farklı özelliklerin dahil edilmesiyle tahmin doğruluğunun artırılabilirliğini belirtmektedir [3].

Abd Ghani ve ekibi işitme kaybı semptomlarını tespit etmek için yenilikçi bir yapay zeka modeli sunmaktadır. İşitme eşiği ile semptomlar arasındaki ilişkiyi analiz etmek için FP-Growth algoritması kullanılmıştır ve ardından multivaryant Bernoulli Naive Bayes modeli sınıflandırma amacıyla uygulanmıştır. Veri seti 50 ve 399 hasta örneklerini içerir. Sonuçlar, tinnitus, vertigo ve baş dönmesi gibi semptomların belirli işitme eşikleriyle güçlü bir ilişki gösterdiğini ortaya koymuştur. Model %98.25 doğruluk oranına ve %1.73 hata oranına ulaşarak semptom tespitinde yüksek verimlilik sağlamıştır [2].

Gathman ve ekibi işitme kaybını tahmin etmek için hasta demografisi, klinik faktörler ve öznel işitme durumu gibi temel bilgileri kullanarak bir makine öğrenmesi modeli geliştirmiştir. National Health and Nutrition Examination Survey (NHANES) verilerini temel olarak LightGBM algoritması ile oluşturulan model, işitme kaybını (PTA) %92 doğruluk oranıyla tahmin etmiştir. Özellikle yaş, cinsiyet, BMI, sigara geçmişi ve işitme şikayetleri gibi faktörler en etkili özellikler arasında yer almıştır. Bu sonuçlar, modelin klinik işitme değerlendirmeleri için yararlı olabileceğini göstermektedir [1].

### 3. Veri seti


Bu veri seti [9], bireylerin işitme testine ait verileri içermekte ve işitme kaybı durumu sınıflandırılmaktadır. Veri seti; yaş, cinsiyet, işitme testi sonuçları gibi özellikler barındırarak, işitme kaybının varlığını belirlemeye yönelik sınıflandırma modelleri geliştirilmesi için uygundur. İşitme testlerinin sonuçlarını makine öğrenmesi algoritmalarıyla analiz etmek isteyen araştırmacılar, bu veri setini işitme sağlığı ve tanı sistemleri üzerine çalışmalarında kullanabilir. Veri seti, sağlık bilişimi ve biyoistatistik alanında önemli bir sınıflandırma problemine çözüm sunmaktadır. Veri seti içindeki bağımsız değişkenlerin birbirine ve sonuca etkileri Şekil 1'de gösterilmektedir.



Şekil 1. Veri seti içindeki bağımsız değişkenlerin birbirine ve sonuca etkileri

Grafikte, "test\_result" değişkenine göre yaş ve fiziksel puan dağılımları karşılaştırılmaktadır. Yaş ve fiziksel puan özelliklerinin dağılımı, test sonucuna (0 veya 1) göre farklılık göstermektedir.

Üst sol grafikte yaş dağılımı, test sonucu 1 olan bireylerin yaşlarının ortalamada daha düşük olduğunu göstermektedir. Alt sağ grafikte ise fiziksel puan dağılımı, test sonucu 1 olan bireylerin fiziksel puanlarının daha yüksek olduğunu belirtmektedir. Ayrıca, yaş ile fiziksel puan arasında negatif bir korelasyon bulunmakta ve bu korelasyon test sonuçları arasında belirgin farklılık göstermektedir. Bu durum, yaşın ilerlemesiyle fiziksel puanda bir düşüş olduğunu ve test sonucunun bu ilişkiye göre değiştiğini işaret etmektedir.



Şekil 2. Fiziksel puan ve test sonucu

Şekil2'deki üç boyutlu grafik, yaş, fiziksel puan ve test sonucunu görselleştirmektedir. Kod yapısına göre, yatay eksenle yaş, dikey eksenle fiziksel puan, üçüncü eksenle ise test sonucu bulunur. Grafikteki renk kodlaması ile test sonucu belirtilmiştir: sarı noktalar pozitif sonuçları (1), mor noktalar ise negatif sonuçları (0) temsil eder. Yaş arttıkça fiziksel puanın düştüğü net bir şekilde gözlemlenmektedir; bu, yaş ile fiziksel puan arasında

ters bir ilişkinin olduğunu göstermektedir. Bu korelasyon, fiziksel performansın yaş ilerledikçe azaldığına işaret eder.

#### 4. Bulgular ve Tartışma

Tablo 1. Kullanılan algoritmalar ve değerlendirme metrikleri

Algoritma ve Metrikler	Precision	Recall	F1-Score	Doğruluk
Logistic Regression	0.92	0.86	0.89	0.92
Karar Ağaçları	0.86	0.86	0.86	0.89
ExtraTrees	0.90	0.86	0.88	0.91
SVM	0.97	0.86	0.91	0.93
GradientBoosting	0.97	0.86	0.91	0.94

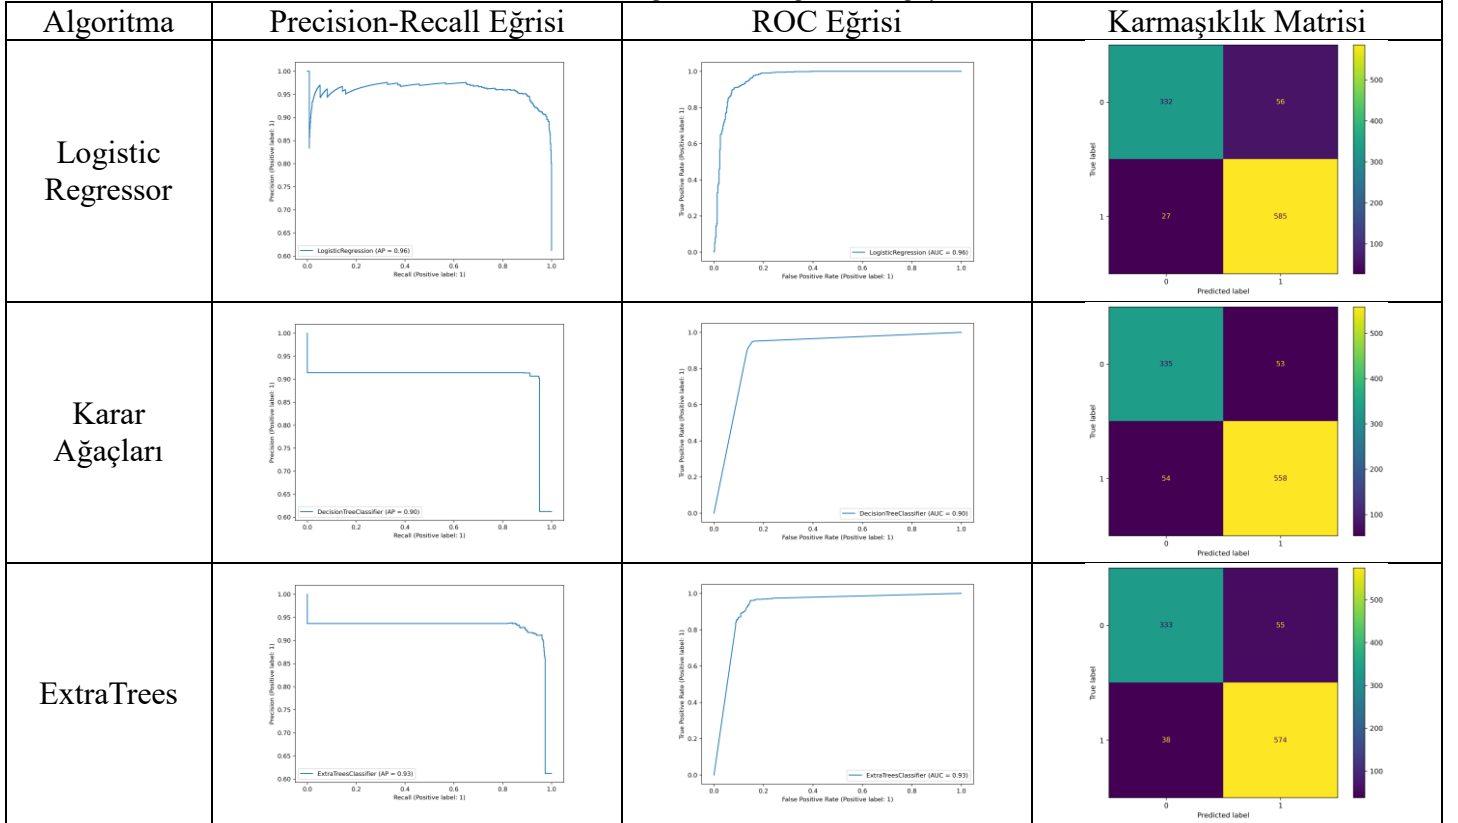
Tablo 1'deki veriler, çeşitli sınıflandırma algoritmalarının Precision (Doğruluk), Recall (Duyarlılık), F1-Score ve Accuracy (Doğruluk) metriklerine göre performanslarını kapsamlı bir şekilde karşılaştırmaktadır. Bu metrikler, modelin sınıflandırma başarısını farklı açılardan değerlendirir:

- **Gradient Boosting ve SVM (Support Vector Machine) algoritmaları**, en yüksek performansı göstermektedir. Her iki model de 0.97 precision ve 0.86 recall değerleriyle pozitif sınıfı başarılı bir şekilde tanımlarken, yüksek doğruluk (SVM için %93, Gradient Boosting için %94) ve F1-Score (0.91) değerleri ile ön plana çıkmaktadır. Bu durum, bu modellerin hem doğru pozitifleri hem de yanlış pozitifleri dengeli bir şekilde optimize edebildiğini göstermektedir.

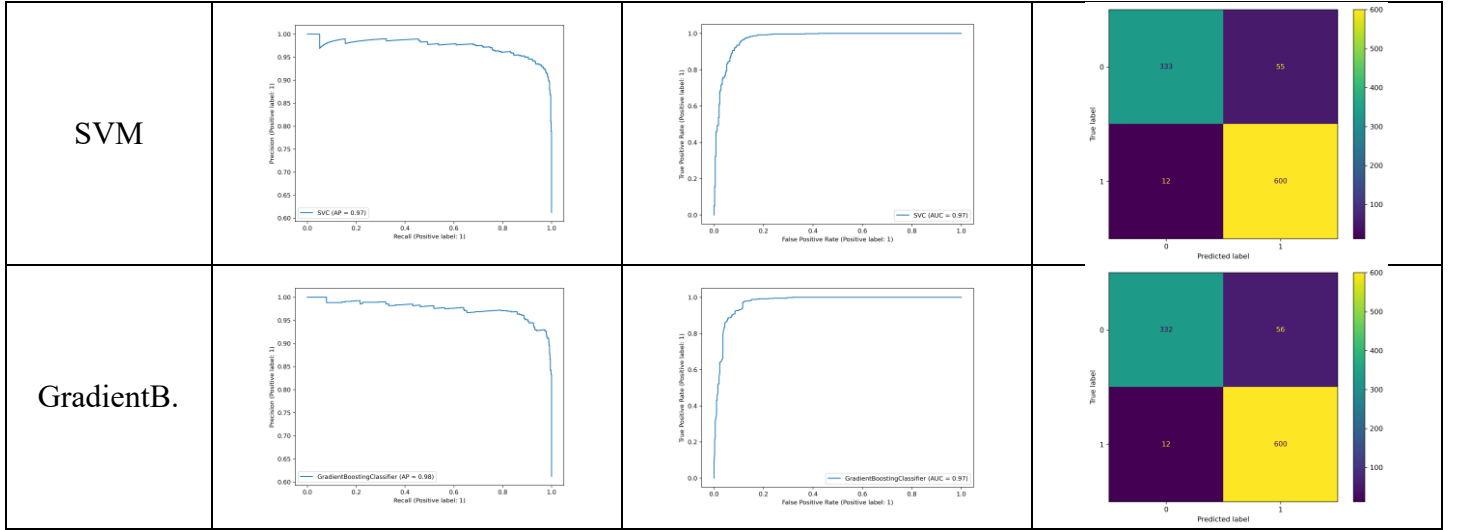
- **Logistic Regression**, %92 doğruluk ve 0.89 F1-Score ile tatmin edici bir performans sergilemektedir. 0.92 precision ve 0.86 recall değerleriyle model, doğru pozitif oranını artırırken hatırlama açısından biraz düşük kalmaktadır. Bu durum, modelin pozitif sınıfı tanımlamada dikkatli ancak bazı durumlarda yanlış negatifleri göz ardı edebileceğini göstermektedir.
- **Karar Ağaçları algoritması**, tüm metriklerde 0.86'lık dengeli değerlere sahip olup, %89 doğruluk oranı ile diğer modellere göre daha düşük bir performans sergilemektedir. Bu sonuç, karar ağacının basit yapısı nedeniyle veri ayırt etme yeteneğinin sınırlı kalabileceğini göstermektedir.
- **ExtraTrees modeli**, %91 doğruluk ve 0.88 F1-Score ile Logistic Regression modeline yakın bir performans sergilemektedir. Bu modelin 0.90 precision ve 0.86 recall değerleri, sınıfları iyi bir doğrulukla tahmin ettiğini ancak bazı yanlış negatifler ve yanlış pozitifler içerebileceğini işaret eder.

Genel olarak, Gradient Boosting ve SVM modelleri en yüksek performansı sunmakta ve özellikle dengeli bir doğruluk ve duyarlılık sağladıkları için sınıflandırma görevlerinde tercih edilmesi önerilen modeller olarak öne çıkmaktadır. Logistic Regression ve ExtraTrees modelleri de iyi performans gösterirken, Decision Tree daha düşük doğruluk oranı ile daha basit bir sınıflandırma modeli olarak kalmaktadır. Bu sonuçlar, veri seti ve sınıflandırma görevine bağlı olarak model seçimini etkileyebilecek değerli bilgiler sunmaktadır. Tablo 2'de kullanılan algoritmalar ve değerlendirme grafikleri gösterilmiştir.

Tablo 2. Kullanılan algoritmalar ve değerlendirme grafikleri







Gradient Boosting sınıflandırıcısının Precision-Recall (Doğruluk-Hatırlama) Eğrisinde X eksenini, pozitif sınıfı doğru bir şekilde tanımlama oranını ifade eden recall (hatırlama) değerini, Y eksenini ise doğru pozitif tahminlerin tüm pozitif tahminlere oranını gösteren precision (doğruluk) değerini göstermektedir.

Eğrinin altında kalan alan (AP - Average Precision) değeri 0.98 olarak belirtilmiştir; bu, modelin pozitif sınıfı yüksek bir doğruluk ve hatırlama ile ayırt edebildiğini ifade eder. Eğri, yüksek doğruluk ve hatırlama değerleri elde edildiğini göstermekte olup, Gradient Boosting sınıflandırıcısının veri seti üzerindeki performansının güçlü olduğunu yansıtmaktadır. Bu sonuç, modelin yanlış pozitif ve yanlış negatif oranlarını en aza indirmede başarılı olduğunu ortaya koyar, bu da onu sınıflandırma görevlerinde etkili bir seçenek haline getirir.

Gradient Boosting sınıflandırıcısının ROC (Receiver Operating Characteristic) Eğrisi modelin pozitif sınıfı doğru şekilde ayırt etme başarısını ifade eder. X eksenini False Positive Rate'i (Yanlış Pozitif Oranı) gösterirken, Y eksenini True Positive Rate'i (Doğru Pozitif Oranı) göstermektedir. Eğri altında kalan alan (AUC - Area Under Curve) değeri 0.97 olarak verilmiştir. Bu yüksek AUC değeri, modelin sınıflandırma görevinde güçlü bir ayırt edici performansa sahip olduğunu ve pozitif sınıfı doğru tanımlama kapasitesinin yüksek olduğunu gösterir.

GradientBoosting'e ait karmaşıklık matrisi, modelin tahmin performansını göstermektedir.

- Sol üst köşede (332), gerçek etiketi 0 olan ve doğru tahmin edilen örnekler bulunur (True Negatives).
- Sağ üst köşede (56), gerçek etiketi 0 olup yanlışlıkla 1 olarak tahmin edilen örnekler (False Positives) yer alır.
- Sol alt köşede (12), gerçek etiketi 1 olan fakat 0 olarak tahmin edilen örnekler (False Negatives) vardır.
- Sağ alt köşede (600), gerçek etiketi 1 olup doğru tahmin edilen örnekler (True Positives) gösterilmektedir.

Model, yüksek doğrulukla sınıflandırma yapmaktadır, ancak bazı yanlış pozitif ve negatif tahminler mevcuttur.

## 5. Sonuçlar

Bu çalışmada, işitme kaybı durumunu sınıflandırmaya yönelik çeşitli makine öğrenmesi algoritmalarının performansları karşılaştırılmıştır. Kullanılan veri seti, bireylerin yaş, cinsiyet ve

işitme testi sonuçları gibi özelliklerini içermekte olup, işitme kaybını belirlemeye yönelik sınıflandırma modellerinin geliştirilmesi için kapsamlı bir temel sunmaktadır. Sonuçlar, Gradient Boosting ve SVM algoritmalarının, özellikle yüksek doğruluk ve dengeli duyarlılık sunarak en başarılı modeller olarak öne çıktığını göstermektedir. Bu modeller, 0.97 precision, 0.86 recall ve 0.91 F1-Score değerleri ile doğru pozitif tahmin oranlarını optimize ederek işitme kaybı sınıflandırma görevinde etkili sonuçlar elde etmişlerdir. Diğer algoritmalarından Logistic Regression ve ExtraTrees ise tatmin edici performans sergilerken, Decision Tree nispeten daha düşük doğruluk oranı ile sınıflandırma kabiliyetinin sınırlı kaldığını ortaya koymaktadır.

Genel olarak, elde edilen bulgular, veri setine ve sınıflandırma görevine göre model seçiminin önemini vurgulamaktadır. Gradient Boosting ve SVM gibi daha güçlü algoritmalar, işitme sağlığı ve tanı sistemleri üzerine yapılan çalışmalarda kullanılabilir güvenilir sınıflandırıcılar olarak değerlendirilmektedir. Bu bağlamda, makine öğrenmesi temelli analizlerin sağlık bilimsel alanında tanı süreçlerini destekleme potansiyeli taşıdığı sonucuna ulaşılmaktadır. Gelecekte, farklı veri setleri ve daha karmaşık modelleme yaklaşımları ile sınıflandırma doğruluğunu daha da artırmak amacıyla çalışmalar yapılması hedeflenmektedir.

## Kaynakça

- [1]Gathman, T. J., Choi, J. S., Vasdev, R. M., Schoepfoerster, J. A., & Adams, M. E. (2023). Machine learning prediction of objective hearing loss with demographics, clinical factors, and subjective hearing status. *Otolaryngology–Head and Neck Surgery*, 169(3), 504-513.
- [2]Abd Ghani, M. K., Noma, N. G., Mohammed, M. A., Abdulkareem, K. H., Garcia-Zapirain, B., Maashi, M. S., & Mostafa, S. A. (2021). Innovative artificial intelligence approach for hearing-loss symptoms identification model using machine learning techniques. *Sustainability*, 13(10), 5406.
- [3]Bing, D., Ying, J., Miao, J., Lan, L., Wang, D., Zhao, L., ... & Wang, Q. (2018). Predicting the hearing outcome in sudden sensorineural hearing loss via machine learning models. *Clinical Otolaryngology*, 43(3), 868-874.

- [4]Park, K. V., Oh, K. H., Jeong, Y. J., Rhee, J., Han, M. S., Han, S. W., & Choi, J. (2020). Machine learning models for predicting hearing prognosis in unilateral idiopathic sudden sensorineural hearing loss. *Clinical and experimental otorhinolaryngology*, 13(2), 148-156.
- [5]Lenatti, M. (2019). Automated detection of hearing loss by machine learning approaches applied to speech-in-noise testing for adult hearing screening.
- [6]Boven, C., Roberts, R., Biggus, J., Patel, M., Matsuoka, A. J., & Richter, C. P. (2023). In-situ hearing threshold estimation using Gaussian process classification. *Scientific reports*, 13(1), 14667.
- [7]Ma, J., Seo, J. H., Moon, I. J., Park, M. K., Lee, J. B., Kim, H., ... & Hong, M. (2023). Auditory brainstem response data preprocessing method for the automatic classification of hearing loss patients. *Diagnostics*, 13(23), 3538.
- [8]Lenatti, M., Moreno-Sánchez, P. A., Polo, E. M., Mollura, M., Barbieri, R., & Paglialonga, A. (2022). Evaluation of machine learning algorithms and explainability techniques to detect hearing loss from a speech-in-noise screening test. *American Journal of Audiology*, 31(3S), 961-979.
- [9]Kaggle, Hearing Test Classification Problem, Erişim Bağlantısı: <https://www.kaggle.com/datasets/prasenjitsharma/hearing-test-classification-problem/data>. Erişim Tarihi: 30.10.2024
- [10]Çınaroğlu, S. (2017). Sağlık Harcamasının Tahmininde Makine Öğrenmesi Regresyon Yöntemlerinin Karşılaştırılması. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 22(2), 179-200.
- [11]Emre, İ. E., Taş, C., & Erol, Ç. (2021). Psikiyatride makine öğrenmesi yöntemlerinin kullanımı. *Psikiyatride Güncel Yaklaşımlar*, 13(2), 332-353.
- [12]Kaya, U., Yılmaz, A., & Dikmen, Y. (2019). Sağlık alanında kullanılan derin öğrenme yöntemleri. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 792-808.
- [13]Mustul, E. E., & Doğan, M. (2022). İşitme kaybı olan çocuklarda yürütücü işlevler araştırmaları üzerine bir sistematik derleme. *Ankara Üniversitesi Eğitim Bilimleri Fakültesi Özel Eğitim Dergisi*, 23(1), 165-189.
- [14]Akmeşe, P. P. (2015). Doğuştan İleri/Çok İleri Derecede İşitme Kayıplı Çocukların. *Ege Eğitim Dergisi*, 16(2), 392-407.
- [15]İşıl, O. R. A. N., Kemaloğlu, Y., Gökdoğan, Ç., Gündüz, B., & Bilgin, C. (2015). İşitme kayıplı çocukların gelişimsel alanlardaki performans düzeylerinin Gazi Erken Çocukluk Değerlendirme Aracı ile incelenmesi. *Gazi Üniversitesi Gazi Eğitim Fakültesi Dergisi*, 34(3), 563-582.