

## Araştırma Makalesi / Research Article

# Servikal Kanserlerin Teşhisinde Kullanılan Makine Öğrenmesi Algoritmalarının Karşılaştırmalı Analizi

Tolga ÖZLEN<sup>1</sup>, Ali GÜNEŞ<sup>2</sup><sup>1</sup> İstanbul Aydın Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul.<sup>2</sup> İstanbul Aydın Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul.Sorumlu Yazar, e-posta: [tolgaozlen@stu.aydin.edu.tr](mailto:tolgaozlen@stu.aydin.edu.tr) ORCID ID: <https://orcid.org/0000-0002-1468-0049>  
[aligunes@aydin.edu.tr](mailto:aligunes@aydin.edu.tr) ORCID ID: <https://orcid.org/0000-0001-6177-3136>

Geliş Tarihi: 15.01.2021

Kabul Tarihi: 12.10.2021

**Öz****Anahtar Kelimeler**Serviks Kanseri;  
Servikal Kanserler;  
Makine Öğrenmesi;  
Yapay Zeka

Serviks (Rahim Ağzı Kanseri) ölüme yol açan ve ölüm oranı en yüksek kanser türlerinden biri olarak görülmektedir. Serviks kanseri kadın kanseri arasında meme kanserinden sonra 2. Sırada yer almaktadır. Günümüzde makine öğrenmesi yöntemlerinin kullanımıyla biyomedikal veri kümelerinin analizi yaygınlaşmıştır. Özellikle kanser gibi habis hastalıkların erken teşhisinde tahminleme sistemleri önemli rol oynamaktadır. Serviks kanseri üzerinde belirlenmiş risk faktörlerine yönelik yapılan tahminler tutarlı olabilmektedir. Bu çalışmada serviks kanserinin teşhisinde kullanılan makine öğrenmesi metotlarının başarıları karşılaştırılmıştır. Çalışmada kullanılan 23 ayrı makine öğrenmesi algoritması, 838 örnek, 32 öznitelik ve 4 hedef değişkenli veri seti üzerinde test edilmiştir. Veri ön işleme, özellik seçimi ve sınıflandırma olmak üzere üç aşamadan oluşan analizde sınıflandırma performansları; sınıflandırma doğruluğu, kesinlik, duyarlılık ve F-ölçütü metrikleri kullanılarak analiz edilmiştir. Analiz sonucunda RepTree algoritmasının en başarılı sonuç veren model olduğu belirlenmiştir.

## Comparative Analysis of Machine Learning Algorithms Used in the Diagnosis of Cervical Cancers

**Abstract**

Cervix (Cervical Cancer) is seen as one of the cancer types that causes death and has the highest mortality rate. Cervical cancer is the second most common female cancer after breast cancer. Today, the analysis of biomedical datasets has become widespread with the use of machine learning methods. Prediction systems play an important role in the early diagnosis of malignant diseases such as cancer. Estimates of risk factors for cervical cancer can be consistent. In this study, the success of machine learning methods used in the diagnosis of cervical cancers was compared. 23 different machine learning algorithms used in the study were tested on a data set with 838 samples, 32 features and 4 target variables. Classification performances in the analysis consisting of three stages: data preprocessing, feature selection and classification; Comparisons were made using classification accuracy, precision, sensitivity, and F-criterion metrics. As a result of the analysis, it was determined that the RepTree algorithm was the model that gave the most successful results.

**Keywords**Cervix Cancer;  
Cervical Cancers;  
Machine Learning;  
Artificial intelligence

### 1. Giriş

Bilgisayarlar insanlara göre daha hızlı işlem yapabilmektedir. Geçmişte karar verme süreci gerektiren durumlarda insan zekasına ihtiyaç duyuluyorken, günümüzde geliştirilen farklı Makine öğrenmesi metotları ile bilgisayarlar doğru kararlar verme yeteneği kazandırılmıştır.

Makine öğrenmesi temel olarak, bilgisayarların mevcut veriler üzerinden çıkarım yapmasına, tahminlerde bulunmasına ve tahminler üzerinde yorumlama yapabilmesine olanak sağlayan algoritmalarla oluşur. Kümeleme, sınıflama yöntemleri, karar ağaçları, yapay sinir ağları gibi pek çok teknik ile veriden anlam çıkarımı ve tahminleme yapılabilmektedir (Kolay ve Erdoğan)

2016). Makine öğrenmesi algoritmaları temel olarak 2 ayrı sınıfta incelenir. Denetimli ve denetimsiz olarak nitelendirebilecek makine öğrenmesi algoritmaları farklı amaçlar doğrultusunda kullanılabilir.

Makine öğrenmesi son yıllarda sağlık sektöründe yaygın olarak kullanılmaya başlanmıştır. Özellikle hastalıkların teşhis ve sınıflandırılmasında sınıflandırma algoritmalarının kullanımı yaygındır. Hastalık teşhisinde kullanılan sınıflandırma algoritmalarına karar destek sistemleri adı verilir. Karar destek sistemlerini oluşturan sınıflandırma algoritmaları konusunda biyomedikal veri kümeleri konusunda günümüze kadar birçok çalışma gerçekleştirilmiştir (Hacıbeyoğlu ve Karakoyun 2014).

Makine öğrenmesi tekniklerinin klinik alanda özellikle kanser teşhisine yönelik kullanımı giderek artarken serviks kanserinin tespitini kolaylaştırmaya yönelik olarak yapılan çeşitli çalışmalar bulunmaktadır. Serviks kanseri teşhisinde farklı makine öğrenmesi algoritmaları kullanılmakla birlikte yaygın olarak kümeleme, yapay sinir ağları, destek vektör makineleri, bulanık ve yapay bulanık mantık ve hibrit teknikler kullanılmaktadır (Hacıbeyoğlu ve Karakoyun 2014).

Ölüme yol açan hastalıklardan biri olan kanserler günümüzde mortalite oranı en yüksek hastalıklardan biri olarak karşımıza çıkmaktadır. Serviks kanseri kadınların yaşamında en önemli sağlık sorunlarından biridir. Serviks kanseri genel kanser ölümleri açısından üçüncü sıradadır. Serviks kanseri, 2018 yılında tahmini 570.000 vaka ile kadınlarda dördüncü en sık görülen kanser türüdür ve tüm kadın kanserlerinin %7,5'ini temsil etmektedir. 2018 yılında yaklaşık 311.000 kadın serviks kanseri sebebiyle ölmüştür (World Health Organization, 2019). Servikal kanserlerin erken tanı evresinin olması ve bu evrede teşhis edildiklerinde etkin tedavi olanaklarının varoluşu bu kanser türünü erken teşhis noktasında önemli bir tür haline getirmektedir. Erken teşhis edildiğinde bu kanser türüne ait sağ kalım oranları oldukça yüz güldürücüdür (Gözüyeşil vd. 2019). Ancak Türkiye gibi gelişmekte olan ülkelerde düzenli tarama ve testlerin eksikliği nedeniyle serviks kanseri hala ciddi bir sorun halinde devam etmektedir (World Health Organization 2018).

## 1.1 Serviks Kanseri

Rahim ağzı kanseri ya da tıbbi adıyla serviks kanseri, rahim bölgesinin serviks denilen alt kısmında görülen bir kanser çeşididir. Serviks, rahmin vajinaya bağlanan boyun şeklindeki kısmıdır. Cinsel yolla bulaşan bir enfeksiyon olan HPV (Human Papilloma Virus) ile ilişkili olduğu düşünülmektedir ( Sonay vd. 2013).

Birçok insan virüse maruz kaldığında bağışıklık sistemi HPV'yi baskılar ve hastalık oluşmasını engeller. Ancak küçük bir grup kadında virüs, yıllarca hayatta kalır. Bu virüsler, serviks yüzeyindeki bazı hücrelerin, kanser hücreleri haline gelmesine neden olan süreci başlatır (Güner vd. 2007).

Serviks kanseri, meme kanserinden sonra kadınlarda en sık görülen kanser çeşididir. Her iki dakikada bir kadının serviks kanseri nedeniyle hayatını kaybettiği düşünülmektedir (Aydoğdu vd. 2018). Günümüzde Servikal kanserlerin gelişiminde Human Papilloma Virus'un (HPV) rol oynadığı bilinmektedir. Serviks kanserlerinin %99.7'si HPV 16-18 virüs tipleri ile ilişkilidir (Güner vd. 2013). Cinsel yönden aktif kişilerin %70'inden fazlası, HPV ile enfekte olmakta ve bunların da %70'inden fazlasının 15-24 yaş arasında olduğu bildirilmektedir (Sonay vd. 2013). Bu sebeple serviks kanserlerinin erken teşhisi önemli bir konu olarak görülmelidir.

Birçok kanser çeşidinde olduğu gibi serviks kanserlerinin gelişiminde rol oynayan çeşitli risk faktörleri belirlenmiştir.

Literatürde belirlenmiş risk faktörleri; Kronik HPV enfeksiyonu, Erken yaşta cinsel ilişki, Çok sayıda cinsel partner, İlk doğum yaşının 20 ve altında olması, Doğum sayısının üç ve üzeri olması, Cinsel yolla geçen hastalığa sahip olunması (özellikle Human Papilloma Virüs tip 16-18, Herpes Simpleks tip II ve HIV), Sigara kullanılması, Yaş, Irk (Siyah kadınlar), Tedavi edilmemiş diğer vajinal enfeksiyonların olması, OKS (Doğum Kontrol Yöntemleri) kullanımı olarak belirlenmiştir (Türkmen vd. 2013).

Çoğu serviks kanseri, rahim ağzının yüzeyindeki hücrelere saldıran insan papilloma virüsünden (HPV) kaynaklanır (Uludağ vd. 2020). En erken kanser öncesi aşamalarında, rutin bir muayene sırasında yapılan Pap smear testi, anormal hücrelerin varlığını tespit edebilir (Uludağ vd. 2020).

Hem kanser öncesi hem de kanserli vakalarda, tanı koymak için rahim ağzından biyopsi alınması gerekir.

Bu biyopsi genellikle ayakta tedavi ortamında yapılabilir. Daha ilerlemiş serviks kanseri olan hastaların, tümörün boyutunu daha iyi tanımlamak ve mesane ve rektum gibi diğer organların veya yapıların dahil olup olmadığını incelemek için anestezi altında bir ameliyathanede biyopsi yapılması gerekebilir (Gök vd. 2021).

Bu çalışmalar serviks kanserinin tedavisinde erken teşhisin önemli bir faktör olduğunu göstermektedir. Serviks kanserlerinin risk analizlerine yönelik makine öğrenmesi metotlarının kullanımı mümkündür. Makine öğrenmesi tekniklerinin risk analizinde ve kanser teşhisinde kullanımı erken tanıda büyük avantaj sağlayacağı düşünülmektedir. Bu çalışmada "Pap Smear" test sonuçlarına ait sayısal verileri sınıflandırmak için makine öğrenmesi teknikleri kullanılmıştır.

## **1.2 Makine Öğrenmesi**

Makine öğrenmesi yapay zekanın bir alt dalı olarak karşımıza çıkmaktadır. Veriler arasındaki örüntülerin taranması ve anlamlı çıkarımların oluşturulması için bilgisayar destekli matematiksel modeller kullanılır. Bu matematiksel modeller her an milyonlarca verinin saklandığı yığınlar üzerinde çeşitli analizler yapmak için kullanılmaktadır. Makine öğrenimi, verilere erişebilen ve kendileri için öğrenmeyi kullanabilen bilgisayar programlarının geliştirilmesine odaklanır (Afrin ve Nahar 2015). Makine öğrenmesi algoritmaları denetimli ve denetimsiz olmak üzere iki kısımda incelenmektedir.

### **1.2.1 Denetimli Makine Öğrenmesi Algoritmaları**

Denetimli makine öğrenmesi algoritmaları, gelecekteki olayları tahmin etmek için etiketli örnekleri kullanarak geçmişte öğrenilenleri yeni verilere uygulayabilir. Bilinen bir eğitim veri setinin analizinden başlayarak, öğrenme algoritması, çıktı değerleri hakkında tahminlerde bulunmak için bir işlev üretmektedir. Sistem, yeterli eğitimden sonra herhangi bir yeni girdi için hedefler sağlamaktadır. Denetimli öğrenme algoritmaları aynı zamanda çıktısını doğru, amaçlanan çıktıyla karşılaştırabilir ve modeli buna göre değiştirmek için hataları bulabilmektedir (Afrin ve Nahar 2015). Tahmin etmeye çalışılan çıktı için bilinen verilerin kullanımı söz konusu ise denetimli öğrenme uygun bir tercih olacaktır.

Denetimli makine öğrenmesi algoritmalarına Knn, Linear Regresyon, Lojistik Regresyon, Destek Vektör Makineleri (DVM), Karar ağaçları ve Rastgele Orman

Algoritmaları ve Sinir Ağları örnek olarak gösterilebilir.

### **1.2.2 Denetimsiz Makine Öğrenmesi Algoritmaları**

Eğitmek için kullanılan verilerin sınıflandırılmadığı veya kümelenemediği durumlarda denetimsiz makine öğrenimi algoritmaları kullanılmaktadır. Denetimsiz öğrenme, sistemlerin sınıflandırılmamış verilerden gizli bir sonuca ulaşmak için bir işlevi nasıl çıkarabileceğini inceler. Sistem doğru çıktıyı bulmaz, ancak verileri araştırır ve sınıflandırılmamış verilerden gizli yapıları ortaya çıkarabilmek için veri kümelerinden sonuç tahminleri yapabilir. Denetimsiz öğrenmenin amacı, veriler hakkında daha fazla bilgi edinmek için verilerin temelini oluşturan yapıyı veya dağılımı modellemektir. Eğitim verisi üzerinde etiketlemenin var olmadığı ya da sınıflandırmanın eksik olduğu durumlarda denetimsiz makine öğrenmesi algoritmalarının kullanımı uygun bir tercih olacaktır.

Denetimsiz öğrenmede en sık kullanılan iki teknik Asal Bileşen Analizi (Principal Component Analysis: PCA) ve Kümeleme (Clustering) yöntemidir.

### **1.3 Serviks Kanserine Yönelik Makine Öğrenmesi Çalışmaları**

Karakoyun ve Hacıbeyoğlu (2014), makine öğrenmesi algoritmalarından K-En Yakın Komşu (K-NN), Naive Bayes (NB), CN2, Rastgele Optimizasyon (RO), Yapay Sinir Ağı (YSA) ve Destek Vektör Makineleri (DVM) algoritmalarını kullanarak yaptıkları çalışmada, biyomedikal veri kümeleri üzerinde sınıflandırma yapmışlardır. Yaptıkları çalışmanın sonucunda YSA algoritmasının yüksek başarımda sonuçlar verdiği ve küçük ve orta ölçekli veri kümeleri için K-NN algoritmasının daha hızlı çalıştığı görülmüştür.

Huang ve arkadaşları (2013), Naive Bayes (NB), Karar Ağaçları ve Destek Vektör Makinelerini (DVM) kullanarak çeşitli veri kümeleri üzerinde veri sınıflandırma yapmışlardır. Bu çalışmada DVM algoritmasının, uygulanan veri kümeleri için NB ve C4.5 algoritmalarından daha yüksek başarımlı olduğu ancak yapılan istatistiksel testler sonucunda aradaki farkın kayda değer oranlarda olmadığı bulunmuştur (Huang 2003).

Tseng ve arkadaşları (2019) yaptıkları çalışmada tekrarlayan serviks kanseri olgularının teşhisinde destek vektör makinesi, C5.0 ve aşırı öğrenme makinesini içeren üç makine öğrenme yaklaşımı

kullanmış, çalışma sonucunda C5.0 algoritmasının tekrarlayan olguların keşfinde en başarılı model olduğu bulunmuştur.

Sun ve arkadaşları (2014), Naive Bayes, C4.5 ve Lineer Regresyon algoritmaları kullanılarak serviks kanserlerinin tanımlanmasına yönelik yaptıkları karşılaştırmalı çalışmada, RF algoritmasının %94,44 doğruluk oranı ile en iyi sınıflandırma performansını elde ettiği gösterilmiştir.

Sarwar ve arkadaşları (2015), serviks kanserinin teşhisinde kullanılabilir 15 ayrı algoritmayı iki ayrı veri seti üzerinde incelemiş, yaptıkları çalışmanın sonucunda Karar Ağaçları algoritmasının en başarılı sonucu verdiği gözlemlenmiştir. Veri seti üzerinde yapılan çalışmada en başarısız sonuç veren algoritmanın Naive Bayes algoritması olduğu gösterilmiştir.

Erkaymaz ve Palabaş (2018), yılında yapmış oldukları çalışmada serviks kanserlerinin teşhisinde kullanılan makine öğrenmesi algoritmalarını analiz etmiş, Naive Bayes (NB), k-En Yakın Komşu (kNN), Çok Katmanlı Algılayıcı (MLP) ve Karar Ağaçları (KA-C4.5) algoritmaları ve rastgele alt uzaylar algoritması arasından elde edilen performans analizine göre K-NN algoritmasının % 95.51 doğruluk oranıyla daha başarılı performans gösterdiği öne sürülmüştür.

## 2. Materyal ve Metot

Makine öğrenmesi metotları ile yapılacak karşılaştırmalı çalışmada serviks kanseri hastalığının sınıflandırılmasında kullanılacak 838 örnek, 32 öznitelik ve 4 hedef değişkenli veri seti 'UC Irvine Machine Learning Repository' den elde edilmiştir (Sarwar vd., 2015). Çalışmada kullanılacak olan 32 adet veri setinden, "İlk tanıdan bu yana geçen süre" ve "Son tanıdan bu yana geçen süre" özellikleri, hastaların kişisel bilgileri nedeniyle özellikler listesinden kaldırılmıştır. Serviks kanserinin teşhisinde en önemli risk faktörleri olan; Yaş, Cinsel Partner Sayısı, İlk Cinsel İlişki Yaşı, Sigara, Hamilelik Sayısı, Doğum Kontrol İlacı Kullanımı veri tipleri analizde kullanılmıştır. Veri setinde 4 hedef değişken kullanılmıştır. Değişkenlerin isimleri Schiller, Cytology, Biopsy, Hinselmann olarak belirlenmiştir. Hinselmann, serviks kanserinin tespiti için asetik asit kullanılarak yapılan kolposkopi sonucunu ifade etmektedir. Lugol iyot kullanılarak yapılan kolposkopi sonucunda elde edilen veriler, Schillers olarak ifade edilmiştir. Serviks kanserinin teşhisinde kullanılan bir diğer yöntem olan Pap-Smear testi sonucu Cytology olarak belirlenmiştir. Biyopsi hedef

değişkeni hastalıklı olduğu düşünülen alandan alınan doku örneklerinin analizi sonucunda serviks kanserinin var olup olmadığını kontrol etmek için kullanılmaktadır. Verilerin hedef değişkenlerine göre dağılımı çizelgede gösterilmiştir (Çizelge 1).

Çizelge 1. Hedefe göre değişken dağılımları.

Hedef Değişken	Pozitif		Negatif	
	Sayı	Oran	Sayı	Oran
Schiller	63	9.43%	605	90.57%
Cytology	39	5.84%	629	94.16%
Biopsy	45	6.74%	623	93.26%
Hinselmann	30	4.49%	638	95.51%

Bu çalışmada, RepTree, SGD, SMO, OneR, BayesNet, LwL, DecisionStump, DecisionTable, SimpleLogistic, MultilayerPreceptron, NaiveBayes, Naive Bayes Updateable, RandomForest, Logistic, J48, RandomTree, LbK, Kstar, LibSVM, SGDDText, NaiveBayes, Multinomial Text, InputMappedClassifier, ZeroR gibi 23 sınıflandırma modeli ile Weka 3.4.8 sürümünde sınıflandırma uygulanmıştır (Şeker, 2016). Çalışmada her bir hedef değişken ayrı ayrı değerlendirilmiş ve her biri için doğru sınıflandırma başarı oranları farklı çapraz doğrulama yöntemleri kullanılarak karşılaştırılmıştır.

Veri önileme, özellik seçimi ve sınıflandırma olmak üzere üç aşamadan oluşan analizde algoritmaların sınıflandırma performansları; sınıflandırma performansı (SP), Kappa İstatistiği (KI), Ortalama Mutlak Hata (OMH), Ortalama Hata Karekökü (OHK) metrikleri kullanılarak analiz edilmiştir. SP, KI, OMH,OHK ölçütlerine göre en başarılı sonucu veren üç algoritma farklı katlarda çapraz doğrulama yöntemleri ve yüzdeler ayırma yöntemleri kullanılarak tekrar analiz edilmiştir.

Yapılan analizlere göre en yüksek performansa sahip olan yöntem kesinlik ve duyarlılık ölçütlerine göre değerlendirilmiştir. Doğru Pozitif Oran (TPR), Yanlış Pozitif Oran (FPR), Hassasiyet (PRE), Duyarlılık (Recall), F-Measure (FM), Matthews Correlation Coefficients (MCC), ROC Analizi (ROC), Precision-recall Curve (PRC) ve Sınıf metrikleri analizin sonuçlarını değerlendirmek için kullanılmıştır. Hedef değişkenlere göre yapılan sınıflandırma işleminin sonucunda tahmin edilen veriler için; kanserli doku(P), sağlıklı doku(N) olarak belirlenmiştir. Çıkan sonuçların ağırlıklı ortalaması (W.Avg) değerlendirilmiştir.

### 3. Bulgular

Serviks kanserine neden olan risk faktörleri detaylı bir şekilde analiz edilmiş, veri seti üzerindeki değerler hedef değişkenlere göre tahmin edilmiştir. Ortalama mutlak hata değerleri, ortalama karesel hatanın karekökü ile korelasyon katsayısı değerleri karşılaştırılmıştır. Aşağıdaki çizelgede her bir öğrenme yöntemi ve sonuçları gösterilmiştir (Çizelge 2).

**Çizelge 2.** Makine Öğrenmesi Yöntemleri ve Sonuçları

Algoritma	SP	KI	OMH	OHK
RepTree	96,42%	0.7391	0.0533	0.1659
SGD	96,18%	0.7258	0.0382	0.1954
SMO	96,18%	0.7258	0.0382	0.1954
OneR	96,18%	0.7151	0.0478	0.1979
BayesNet	96,18%	0.666	0.0446	0.1737
LwL	96,18%	0.7258	0.0559	0.1687
DecisionStump	96,18%	0.7258	0.0559	0.1681
DecisionTable	96,18%	0.7258	0.0572	0.1681
SimpleLogistic	96,18%	0.7258	0.1486	0.1967
MultilayerPreceptron	95,82%	0.6506	0.049	0.1833
NaiveBayes	95,58%	0.643	0.0471	0.1799
Naive Bayes Updateable	95,58%	0.643	0.0471	0.1799
RandomForest	95,58%	0.6369	0.0561	0.1781
Logistic	95,35%	0.6475	0.0571	0.1749
J48	95,23%	0.6173	0.0596	0.1989
RandomTree	94,99%	0.5843	0.0501	0.2239
LbK	94,99%	0.5843	0.0512	0.2236
Kstar	94,51%	0.4132	0.0601	0.206
LibSVM	93,91%	0.0992	0.0609	0.2467
SGDText	92,56%	0	0.0944	0.2538
NaiveBayes Multinomial Text.	90,56%	0	0.1578	0.2145
InputMappedClassifier	88,56%	0	0.1585	0.2845
ZeroR	82,56%	0	0.1986	0.3956

Çizelge 2 incelendiğinde en düşük ortalama mutlak hata değerine sahip modelin 0.0385 değeri ile olasılıksal dereceli azaltma algoritması olan SGD ve SMO yöntemleri olduğu görülmektedir. DVM'e benzer bir şekilde çalışan algoritmaların basit ve özellik ölçmeye duyarlı olduğu düşünülmektedir. SGD ve SMO algoritması ile oluşturulan modelin sınıflandırma performansı %96,18 olup, işlem süresi 0.86 saniye olarak ölçülmüştür. SGD ve SMO yöntemlerinin birbirleri üzerinde sonuç açısından farklılığı bulunmamakla birlikte 838 adet özniteliğin, 806 adedini doğru sınıflandırdığı görülmektedir. Çalışmada en kısa sürede sonuç veren yöntem LbK yöntemi olarak belirlenmiştir. Çalışmada ReppTree algoritması en yüksek sınıflandırma performansına sahip olarak ölçülmüştür (%96,42). RepTree algoritmasının sonuçları incelendiğinde 838 örneğin 808 tanesinin doğru sınıflandırıldığı görülmüştür. RepTree, SGD, SMO algoritmaları arasında sınıflandırma performansı ve hata oranları açısından değerlendirildiğinde belirgin bir üstünlük görülmemiştir. SGDDText, NaiveBayes, MultinomialText, InputClassifier ve ZeroR algoritmalarının korelasyonel olarak diğerlerine göre daha zayıf performans gösterdiği belirlenmiştir. ZeroR modelinin en yüksek ortalama hata değerine sahip olduğu söylenebilir. Yöntemin geçerliliği açısından sınıflandırma performansına dikkat etmek gereklidir. RepTree modeline yakın sınıflandırma performansına sahip olan SGD ve SMO yöntemlerinin ortalama mutlak hata değeri daha düşük hesaplanmıştır. Bu da tahmin edilen değer ile gerçek değerlerin birbirine yakınlaştığını ve modellerin daha başarılı sonuçlar verdiğini göstermektedir. ReppTree modelinin sınıflara göre ayrıntılı kesinlik ve duyarlılık oranları Çizelge 3'te gösterilmiştir.

**Çizelge 3.** RepTree Algoritması Ayrıntılı sınıflandırma performansı.

	TPR	FPR	PRE	Recall	F-M	MCC	ROC	PRC	Sınıf
N	0,97	0,13	0,99	0,97	0,98	0,75	0,88	0,98	0
P	0,87	0,03	0,67	0,87	0,76	0,75	0,88	0,57	1
W. Avg	0,96	0,12	0,97	0,96	0,97	0,75	0,88	0,96	

Bu çalışmada kullanılan tüm yöntemlerde 10 katlı çapraz doğrulama yöntemi kullanılmış olup, değerlerin değişmesi durumunda sonuçların nasıl olacağı gözlemlenmiştir. Bu sebeple ReppTree, SGD ve SMO yöntemleri üzerinde 5-40 aralığında farklı çapraz doğrulama katsayıları ve %66'ya %33 ayırımı yöntemleri kullanılarak analizler yapılmıştır. Çıkan sonuçlar Çizelge 4, Çizelge 5 ve Çizelge 6'da görüntülenmektedir.

**Çizelge 4.** RepTree yöntemi için farklı çapraz doğrulama sayıları ve sonuçları.

Yöntem	SP	KI	OMH
5 Katlı Çapraz Doğrulama	96,18%	0.0541	0.172
10 Katlı Çapraz Doğrulama	96,42%	0.0533	0.1659
15 Katlı Çapraz Doğrulama	95,94%	0.0575	0.7614
20 Katlı Çapraz Doğrulama	96,18%	0.0541	0.172
25 Katlı Çapraz Doğrulama	95,82%	0.0578	0.1795
30 Katlı Çapraz Doğrulama	96.06 %	0.0558	0.1734
35 Katlı Çapraz Doğrulama	95,94%	0.0575	0.7614
40 Katlı Çapraz Doğrulama	96.06 %	0.0558	0.1734
%66'ya %33 Ayırma	95.43%	0.0568	0.1849

**Çizelge 5.** SGD yöntemi için farklı çapraz doğrulama sayıları ve sonuçları.

Yöntem	SP	KI	OMH
5 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
10 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
15 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
20 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
25 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
30 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
35 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
40 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
%66'ya %33 Ayırma	95.78%	0.6779	0.0421


**Çizelge 6.** SMO yöntemi için farklı çapraz doğrulama sayıları ve sonuçları.

Yöntem	SP	KI	OMH
5 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
10 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
15 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
20 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
25 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
30 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
35 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
40 Katlı Çapraz Doğrulama	96,18%	0.0382	0.1954
%66'ya %33 Ayırma	95.78%	0.6779	0.0421


Yukarıdaki çizelgelerde yer alan sonuçlara bakıldığında en başarılı RepTree algoritmasının sonucun 10 katlı çapraz doğrulama yöntemi ile oluşturulduğu görülmektedir. Sınıflandırma performansı bakımından 10 katlı çapraz doğrulama yöntemine en yakın sonuçlar veren 5 katlı çapraz doğrulama yöntemidir fakat korelasyonel olarak incelendiğinde 10 katlı çapraz doğrulama metodunun bu makine öğrenmesi yönteminde daha iyi sonuçlar verdiği görülmektedir. SGD ve SMO algoritmalarının farklı katlardaki çapraz doğrulama

oranları incelendiğinde sonucun değişmediği görülmektedir. Ayrıca çapraz doğrulama katsayısının azaltılması ya da artırılması gibi yöntemlerin çalışmanın sonucunda etki göstermediği görülmektedir. Bu sebeple çalışma sonucu 10 katlı çapraz doğrulama ile hesaplanmıştır. Genel kanı bu tip çalışmalar için 10 katlı çapraz doğrulama yönteminin iyi sonuçlar verdiğidir.

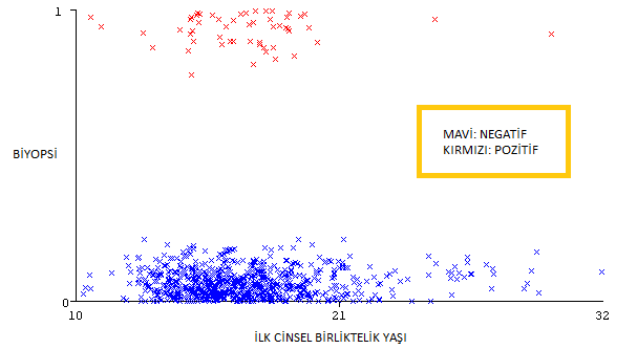
Bu çalışmanın sonucunda serviks kanserlerinin teşhisinde kullanılan risk faktörlerinin analizinde en iyi tahmin modeli olarak Random Tree yöntemi bulunmuştur. Elde edilen tahmin değerleri ve gerçek değerlerin durumunu göstermek adına her bir değişkenin hedef değişkene göre sınıflandırma performansı gösterilmiştir (Şekil 1, Şekil 2, Şekil 3, Şekil 4, Şekil 5, Şekil 6).




Şekil 1. Yaş/Biyopsi Sınıflandırma Grafiği




Şekil 2. Cinsel Partner Sayısı/Biyopsi Sınıflandırma Grafiği




Şekil 3. İlk Cinsel Birliktelik Yaşı/Biyopsi Sınıflandırma Grafiği



Şekil 4. Hamilelik Sayısı/Biyopsi Sınıflandırma Grafiği



Şekil 5. Sigara/Biyopsi Sınıflandırma Grafiği



Şekil 6. Doğum Kontrol Yöntemi Kullanımı/Biyopsi Sınıflandırma Grafiği

#### 4. Tartışma ve Sonuç

Bulgular dikkatlice incelendiğinde Cinsel Partner Sayısı, İlk Cinsel Birliktelik Yaşı, Hamilelik Sayısı, Sigara Kullanımı, Doğum Kontrol Yöntemlerinin kullanımı gibi risk faktörlerinin biyopsi sonucunun kanser çıkması ile doğrudan ilişkisinin olduğu görülmektedir. Gerçek değerler için risk faktörleri analiz edildiğinde tahminlerin ortalama %0,05'lik ortalama mutlak hata değeri ile yaklaşık %96,42 doğruluk oranında yapıldığı gösterilmektedir. Bu çalışma için karar ağacı algoritmalarının ve destek vektör makinesi yöntemlerinin genel olarak diğer makine öğrenmesi algoritmalarına göre daha doğru ve hızlı sonuçlar verdiği söylenebilir. Çalışmada kullanılan OneR, BayesNet, Lwl, DecisionStump, DecisionTable, SimpleLogistic yöntemlerinin de oldukça yüksek doğruluk oranları ile çalıştığı (%96,18) ve bu tip veri kümelerindeki çalışmalar için güvenle kullanılabilmesi düşünülmektedir. Genel olarak destek vektör makineleri tabanlı algoritmaların en yakın komşu ve karar ağaçları tabanlı yöntemlere göre daha başarılı olduğu görülmüştür.

Araştırma sonucunda daha geniş örneklem gruplarından toplanacak verilerin makine öğrenmesi yöntemlerinin başarılarını arttıracığı düşünülmektedir. Araştırma bulguları servikal kanserlerin erken teşhisinde risk faktörlerinin makine öğrenmesi yöntemleri ile analiz edilebileceğini göstermiştir. Bu yönüyle tıp hekimlerinin makine öğrenmesi yöntemlerinden faydalanarak serviks kanseri gibi hastalıkların erken teşhisinde önemli bir ipucu yakalamaları mümkündür. Özellikle yüksek katımlı hastalık taramalarında faydalı bir yöntem olduğu düşünülmektedir.

#### 5. Kaynaklar

Afrin, F., & Nahar, I., 2015. Incremental Learning Based Intelligent Job Search System (*Doctoral dissertation, BRAC University*).

Sarwar A., Ali M., Suri J. And Sharma V., 2015. Performance Evaluation Of Machine Learning Techniques For Screening Of Cervical Cancer, *2nd International Conference On Computing For*

*Sustainable Global Development (Indiacom)*, **2**, 880-886.

Allawi M., Jaafar O., Ehteram M., Mohamad F., El-Shafie A., 2018. Synchronizing Artificial Intelligence Models For Operating The Dam And Reservoir System. *Water Resour Manage* **32**, 3373– 3389.

Alpaydın E., 2004. Introduction To Machine Learning. *The Mit Press*, 1-15.

Aydoğdu S., Özsoy Ü., 2018. Serviks kanseri ve HPV, *Kadın Cinsel Sağlığı*, **20**, 25–29.

Durmaz, S , Ozvurmaz, S , Adana, F , Kurt, F . ,2021. Kadınlarda Serviks Kanserinin Tanısına İlişkin Tutum ve Düzenli Jinekolojik Muayene İlişkisinin Kesitsel Olarak Değerlendirilmesi. *Adnan Menderes Üniversitesi Sağlık Bilimleri Fakültesi Dergisi* , **5 (1)** , 26-36.

Erkaymaz E., Palabaş T., 2018. Classification Of Cervical Cancer Data And The Effect Of Random Subspace Algorithms On Classification Performance, *Signal Processing And Communications Applications Conference*, **26**, 1-4.

Good, I. J., 1965. The Estimation Of Probabilities: An Essay On Modern Bayesian Methods. *M.I.T. Press 1965* , **30**, 182-199.

Gök, S. , Gök, B. , Ceylan D. A. , 2021. HPV-16/18 pozitif kadınların takibinde kolposkopi eşliğinde alınan servikal biyopsinin önemi. *Pamukkale Tıp Dergisi* , **14(1)**, 253-261.

Gözüyeşil, E. , Arıöz, D. , Ünal, K. , 2019. Kadınların Serviks Kanserinden Korunma Ve Erken Tanıya Yönelik Tutumlarının Değerlendirilmesi. *Sted / Sürekli Tıp Eğitimi Dergisi* , **28 (4)** , 229-238.

Sun, G., Li S., Cao Y., Lang F., 2017. Cervical Cancer Diagnosis Based On Random Forest. *Int J Performability Eng*, **13(4)**, 446-457.

Güner, H., Taşkiran, Ç., 2007. Serviks Kanseri Epidemiyolojisi Ve Human Papilloma Virüs. *Türk Jinekoloji Ve Obstetri Derneği Dergisi* **4(1)**,11-19.

Hacıbeyoğlu, M., Karakoyun, M., 2014. Biyomedikal Veri Kümeleri İle Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması. *Deü Mühendislik Fakültesi Mühendislik Bilimleri*, **16**, 30-41

Huang, J., Lu, J., Ling, C.X, 2003. Comparing Naive Bayes, Decision Trees, And Svm With Auc And Accuracy, *Third Ieee International Conference On Data Mining*, 553–556.



- Kanbur, A., Çapık, C., 2011. Servikal Kanserden Korunma, Erken Tanı-Tarama Yöntemleri Ve Ebe/Hemşirenin Rolü. *Hacettepe Üniversitesi Sağlık Bilimleri Fakültesi Hemşirelik Dergisi*, **18 (1)** 61-72.
- Karkalos, N., Efkolidis, N., Kyratsis, P., Markopoulos, A. , 2019. A Comparative Study Between Regression And Neural Networks For Modeling Al6082-T6 Alloy Drilling. *Machines* **7(1)**,13.
- Kolay, N., Erdoğan, P., 2016. The Classification Of Breast Cancer With Machine Learning Techniques. *In Electric Electronics, Computer Science, Biomedical Engineerings' Meeting*, **1**, 1-4.
- Kretschmann, E., Fleischmann, W. , Apweiler R., 2001. Automatic rule generation for protein annotation with the C4.5 data mining algorithm applied on SWISS-PROT. *Bioinformatics*, **17**, 920–926.
- Li, J., Liu, H., Ng, S.K. and Wong, L. , 2003. Discovery of significant rules for classifying cancer diagnosis data. *Bioinformatics*, **19**, 93–102.
- Lu, L. , Zhu, Z., 2014. Prediction Model For Eating Property Of Indica Rice. *Journal Of Food Quality*, **37**, 274-280.
- Lu, W., Wang, W., Leung, A., Lo, S., Yuen, R., Xu, Z. And Fan., H., 2002. Air Pollutant Parameter Forecasting Using Support Vector Machines. *In Proceedings Of The 2002 International Joint Conference On Neural Networks*. **1**, 630-635.
- Malhotra, M., Sharma, S. and Nair, S. S. , 1999. Decision Making Using Multiple Models. *European Journal Of Operational Research*, **114**, 1-14.
- Quinlan, J. R., 1993. C4.5: Programs For Machine Learning. Morgan Kaufmann Publishers, 110-116.
- Sevli, O., 2019. Göğüs Kanseri Teşhisinde Farklı Makine Öğrenmesi Tekniklerinin Performans Karşılaştırması. *Avrupa Bilim Ve Teknoloji Dergisi*, **16**, 176-185.
- Sonay Kurt A, Canbulat N, Savaşer S., 2013. Adölesan Dönem Cinselliğiyle Öne Çıkan Serviks Kanseri Ve Risk Faktörleri. *Bakırköy Tıp Dergisi*, **9**, 59–63.
- Şeker, S. E., 2016. Weka ve veri madenciliği, Draft2Digital Yayıncılık, **1**, 18-27.
- Tobler, J.B., Molla, M.N., Nuwaysir, E.F., Green, R.D. and Shavlik, J.W., 2002. Evaluating machine learning approaches for aiding probe selection for gene-expression arrays. *Bioinformatics*, **18**, 164–171.
- Tseng, C., Lu, C., Chang, C. Et Al. , 2014. Application Of Machine Learning To Predict The Recurrence-Proneness For Cervical Cancer. *Neural Comput & Applic*, **24**, 1311–1316.
- Türkmen, A. S. , Canbulat Şahiner, N., Savaşer, S. , 2013. Adölesan Dönem Cinselliğiyle Öne Çıkan Serviks Kanseri Ve Risk Faktörleri. *Bakırköy Tıp Dergisi*, **2**, 59-63.
- Uludağ, G. , Gamsızkan, Z. and Sungur, M. A. , 2020. Kadınların Serviks Kanseri ve Taraması İle İlgili Sağlık İnançlarının Değerlendirilmesi . *Düzce Üniversitesi Sağlık Bilimleri Enstitüsü Dergisi* , **10 (3)** , 357-362.
- Vapnik, V., 1995. The Nature Of Statistical Learning Theory. *Springer*, 57-75.
- World Health Organization, 2019. Human papillomavirus (HPV) and cervical cancer. Retrieved from [https://www.who.int/en/newsroom/factsheets/detail/human-papillomavirus-\(hpv\)-and-cervical-cancer](https://www.who.int/en/newsroom/factsheets/detail/human-papillomavirus-(hpv)-and-cervical-cancer) (18.07.2021)
- World Health Organization, 2018. *Global Cancer Observatory*. Retrieved from: <http://gco.iarc.fr/> (18.07.2021)