





Anne Sağlığı Riskine Yönelik Makine Öğrenmesi Tahmin Modelleri Karşılaştırılması

Öğr. Gör. Çisem YAŞAR^{1*} , Öğr. Gör. Tuğba SARAY ÇETİNKAYA¹ 

¹*İstanbul Gelişim Üniversitesi, İstanbul Gelişim Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, İstanbul*

Özet

Anne sağlığı hamilelik, doğum ve doğum sonrası dönemlerdeki fiziksel, ruhsal ve duygusal düzeyini ifade etmektedir. Annenin sağlığını olumsuz etkileyecek herhangi bir riskin erken tahmin edilmesi, doğumdan önce gerekli önlemlerin alınmasında yardımcı olmaktadır. Makine öğrenmesi yöntemleri ile anne ve bebeğin sağlığını etkileyecek risk düzeyi izlenebilir ve tahmini gerçekleştirilebilir. Bu çalışmada, anne risk sağlığını tahmin edebilmek için yapay zeka algoritmalarından destek vektör makineleri, yapay sinir ağı, XGBoost, AdaBoost ve Gradient Boosting algoritmaları ile analizler gerçekleştirilmiştir. Bu yöntemler ile elde edilen sonuçlar birbiri ile karşılaştırılmış ve anne sağlığını etkileyecek risk düzeyini tahmin etmede en başarılı model %87 oranı ile XGBoost olduğu görülmüştür. Bu sayede anne sağlığı ile ilgili farklı olasılık koşulları değerlendirilmiştir.

Makale Bilgisi

Başvuru:
05/09/2024
Kabul:
05/11/2024

Anahtar Kelimeler: Makine Öğrenmesi, Anne Sağlığı, Sınıflandırma Algoritmaları

A Comparison Of Machine Learning Prediction Models For Maternal Health Risk

Abstract

Maternal health refers to the physical, mental and emotional level during pregnancy, birth and postpartum periods. Early prediction of any risk that will adversely affect the mother's health helps to take the necessary precautions before birth. With machine learning methods, the risk level that will affect the health of mother and baby can be monitored and predicted. In this study, support vector machines, artificial neural network, XGBoost, AdaBoost and Gradient Boosting algorithms from artificial intelligence algorithms were analyzed to predict maternal risk health. The results obtained with these methods were compared with each other and it was seen that XGBoost was the most successful model with 87% in predicting the risk level that would affect maternal health. In this way, different contingency conditions related to maternal health were assessed.

Keywords: Machine Learning, Maternal Health, Classification Algorithms

* İletişim e-posta: cyasar@gelisim.edu.tr

1 Giriş

Bir kadının hayatında önemli bir evre olan gebelik, beraberinde sayısız fizyolojik değişiklikler ve potansiyel sağlık risklerini getirmektedir [1]. Anne sağlığı ise kadının hamilelik, doğum ve doğum sonrası sağlık durumunu ifade etmektedir [2]. Hem annenin hem de bebeğin sağlığını doğrudan etkilediği için halk sağlığında önemlidir. Tıp biliminde yaşanan gelişmelere rağmen anne ölümleri birçok ülkede önemli bir sorun olmaya devam etmektedir [3,4]. Anne ölümü, gebeliğin başlangıcından doğum sonrası 42 gün içerisinde herhangi bir kaza ve tesadüfi nedenlerden kaynaklanmayan gebelik veya gebeliğin yönetimiyle ilgili olan ya da bunların ağırlaştırdığı herhangi bir sebepten kaynaklanan ölüm olarak tanımlanmaktadır [5]. Dünya Sağlık Örgütü'ne göre her gün yaklaşık 810 gebe kadın ve 6700 yenidoğan ölümü gerçekleşmektedir. Ölüm sebeplerinin ise gebelik ve doğum ile ilgili önlenebilir nedenlerden kaynaklandığını ifade edilmektedir[6,7]. Anne ve bebek ölümü tehlikesi dünya çapında önemli bir sorun olarak değerlendirilmektedir. Gebelik ve doğum sırasında gerçekleşen bazı sorunlar anne ölümlerinin başlıca nedenleri arasındadır. Bu sorunlar şiddetli kanama, enfeksiyon, yüksek tansiyon, doğum süresinin uzaması gibi etmenler olabilir. Oluşan bu sorunlara gebelik ve doğum evresi boyunca önleyici tedbirler alınarak anne ölümlerinin sayısı düşürülebilir [8]. Günümüzde teknolojinin hızlı gelişmesiyle birlikte teşhis yöntemleri de gelişmiş olup yapay zeka (YZ) da bu yöntemlerden biri olmuştur. Yapay zeka tabanlı modeller, yüksek risk altında olabilecek hastaları belirlemek için sağlık verilerinin analizini gerçekleştirebilir. Bu bağlamda gebe bir kadının sağlık değerleri ölçülerek elde edilen veriler makine öğrenmesi yöntemleri ile analiz edilebilir. Sonuç olarak anne ölüm oranında azalma sağlanabilir [9]. Bu çalışmada, anne sağlığı riskinin makine öğrenmesi yöntemleri kullanılarak tahmin edilmesi işlemi gerçekleştirilmiştir. Çalışmanın 2. bölümü olan literatür taramasında, benzer algoritmaları taşıyan çalışmalar özetlenmiştir. 3. bölümü olan materyal ve metot kısmında; kullanılan veri seti, makine öğrenmesi algoritmaları ve başarı metriklerinin açıklamasına yer verilmiştir. 4. Bölümü olan bulgular kısmında; çalışma sonucunda ortaya çıkan bulgular değerlendirilmiştir. 5. Bölümü olan sonuç kısmında ise elde edilen sonuçlardan bahsedilmiştir.

2 Literatür Taraması

Rai ve arkadaşlarının yaptıkları çalışmada, gebelikte gerçekleşen komplikasyonlar sonucunda anne-bebek ölüm risk seviyesini değerlendirmek için uzmanlardan anketler aracılığıyla bilgi toplamışlar ve yeni bir model geliştirmişlerdir. 117 gebe kadından veri alınarak geliştirilen modelde 14 özellik seçilmiş, yapay sinir ağı (YSA) ve Naive Bayes (NB) algoritmaları ile analiz gerçekleştirmişlerdir. Analiz sonucunda YSA ile %80, NB ile de %70 doğruluk oranına ulaşmışlardır [10].

Ahmed ve arkadaşlarının yaptıkları çalışmada, gebelikteki risk düzeyini belirlemek için makine öğrenmesi (MÖ) algoritmalarından yararlanmışlardır. Çalışmada Pima-Indian-diyabet veri setini kullanmışlar ve MÖ algoritmaları ile karşılaştırma yapmışlardır. Elde edilen analizler sonucunda gebelik risk seviyesi sınıflandırılmasında ve tahmininde lojistik model ağacı algoritmasının en yüksek doğruluğu verdiğini tespit etmişlerdir [11].

Ramdhani ve arkadaşlarının yaptıkları çalışmada, gebelik sırasında oluşabilecek riskleri erken tespit ederek gebelik risk düzeyini tahmin etmeyi amaçlamışlardır. Gebelik risk faktörü verileri Bangladeş'in Dakka kentindeki çeşitli hastane ve kliniklerden toplanmıştır. Çalışmada karar ağacı (KA), k-en yakın komşu (KNN), rastgele orman (RO) ve NB algoritmaları kullanılarak karşılaştırma yapmışlardır. Sonuç olarak RO algoritması ile %73,37'lik doğruluk oranının en yüksek başarıyı verdiğini tespit etmişlerdir. Aynı zamanda çalışma modelinde genetik algoritmayla optimize edilmesi durumunda ise başarı oranının yükseldiğini de belirtmişlerdir [12].

Umoren ve arkadaşlarının yaptıkları çalışmada, Rivers Eyaleti'nin Etche Yerel Yönetim Bölgesi'ndeki bir hastaneden elde edilen veri setini kullanmışlardır. Gebelik ve doğum sırasında gerçekleşen komplikasyonların çözümünde KA algoritmasına dayalı bir model geliştirmişlerdir. Modelin başarımı, destek vektör makinesi (DVM) ile karşılaştırılmış ve %89,2 ile KA algoritmasının daha yüksek bir başarıya sahip olduğunu tespit etmişlerdir [13].

Edeyath yaptığı çalışmada, ABD'den anonim hasta kayıtlarını içeren NIH All of Us verilerini kullanmıştır. Özyinelemeli özellik seçimi yaparak gebelik döneminde ortaya çıkabilecek risk faktörlerini sınıflandırmak için lojistik regresyon (LR), NB ve RO algoritmalarını kullanmış ve

hepsinin aynı başarımı verdiğini tespit etmiştir [14].

Mutlu ve arkadaşlarının yaptıkları çalışmada, nesnelerin interneti (IoT) tabanlı risk izleme sistemleri aracılığıyla toplanan bir veri seti üzerinde çalışma yapmışlardır. Çalışmada KA, lightGBMClassifier, CatBoost, RO, gradient boosting machines ve KNN algoritmalarını kullanarak karşılaştırma yapmışlardır. Sonuç olarak KA algoritması ile %89,16'lık doğruluk oranının en yüksek başarımı verdiğini tespit etmişlerdir [15].

Şahin ve arkadaşlarının yaptıkları çalışmada, anne sağlığı riski üzerine bir veri seti kullanmışlardır. Çalışmada MÖ algoritmalarından, lineer regresyon,

DVM, KA, RO, çok katmanlı algılayıcı, NB, KNN ve XGBoost kullanmışlardır. Aynı zamanda her bir algoritma için temel bileşenler analizi (PCA) ve lineer diskriminant analizi (LDA) uygulanarak modelin doğruluk oranı için analiz yapmışlardır. Sınıflandırıcıların performansları incelendiğinde, rastgele orman %84 ile en yüksek doğruluk oranına sahip olduğunu ve LDA'nın başarımlarının pozitif yönde olduğunu tespit etmişlerdir [16].

Literatür araştırmasında incelenen kaynakların özeti Tablo 1 ile verilmiştir.

Tablo 1. Literatür araştırması özeti

Sayı	Yayınlayıcı	Veri Seti	Algoritma	Sonuç
1	Rai ve Sowmya (2018)	117 gebe kadından veri alınarak geliştirilen bir model	YSA ve NB algoritmaları	YSA ile %80, NB ile de %70 doğruluk oranına ulaşılmıştır.
2	Ramdhani ve diğerleri (2022)	Dakka kentindeki hastane ve doğum kliniklerinden elde edilen bir veri seti	KA, KNN, RO ve NB algoritmaları	RO algoritmasının %73,37 doğruluk oranı ile en iyi başarı tespit edilmiştir.
3	Umoren ve diğerleri (2022)	Rivers Eyaleti'nin Etche Yerel Yönetim Bölgesi'ndeki bir hastaneden elde edilen veri seti	KA algoritmasına dayalı bir model geliştirmişlerdir. Modelin başarımı, DV ile karşılaştırmışlardır.	KA algoritmasının %89,2 doğruluk oranı ile en iyi başarı tespit edilmiştir.
4	Edayath (2022)	ABD'den anonim hasta kayıtlarını içeren NIH All of Us verileri	LR, NB, RO algoritmaları	Kullanılan algoritmaların benzer sonuç verdiği tespit edilmiştir.
5	Mutlu, ve diğerleri (2023)	Maternal Health Risk veri seti	KA, LightGBMClassifier, CatBoost, RO, Gradient Boosting Machines ve KNN algoritmaları	KA algoritmasının %89,16 doğruluk oranı ile en iyi başarı tespit edilmiştir.
6	Şahin ve diğerleri (2023)	Maternal Health Risk veri seti	LR, DVM, KA, RO, çok katmanlı algılayıcı, NB, KNN ve XGBoost algoritmaları kullanılmış ve her algoritma için PCA ve LDA uygulanmıştır.	Rastgele orman %84 ile en yüksek doğruluk oranına sahip olduğunu ve LDA'nın başarıyı pozitif yönde etkilediği tespit edilmiştir.

3 Materyal ve Metot

Bu bölümde çalışmada kullanılan veri seti, kullanılan algoritmalar ve performans metrikleri açıklanmıştır. Çalışma kapsamında uygulamalar Colab ortamında Python pandas, numpy ve sklearn kütüphaneleri kullanılarak gerçekleştirilmiştir.

3.1 Veri seti

Bu çalışmada, anne sağlığının risk düzeyini tahmin edebilmek amacıyla makine öğrenmesi yöntemleri kullanılmıştır. Risk düzeyinin tahmini için 1014 örnek ve 7 öznitelikten oluşan, açık erişimli UCI (University of California, Irvine) Machine Learning Repository veri tabanında yer alan "Maternal Health Risk

Dataset" başlıklı veri seti kullanılmıştır [17]. Veriler, Bangladeş'in kırsal bölgelerinde bulunan hastane, toplum klinikleri ve anne sağlığı hizmetleri birimlerinde Nesnelerin İnterneti tabanlı risk izleme sistemi aracılığı ile toplanmıştır. Tablo 2'de veri setinde bulunan öznitelikler ve açıklamaları detaylı olarak gösterilmiştir.

Veri setinde üç sınıf bulunmaktadır. Bunlar yüksek risk, düşük risk ve orta risk şeklindedir.

Tablo 2. Veri setinde yer alan öznitelikler ve açıklamaları

Sıra No	Öznitelik	Açıklama	Değer
1	Yaş	Annenin hamilelik yaşı	Nümerik
2	Sistolik Kan Basıncı	Kalbin kasılması sırasında kan basıncının mmHg cinsinden üst değeri	Nümerik
3	Diyastolik Kan Basıncı	Kalbin gevşemesi sırasında kan basıncının mmHg cinsinden alt değeri	Nümerik
4	Kan Şekeri	Kandaki glikoz seviyelerini molar konsantrasyon (mmol/L) cinsinden değeri	Nümerik
5	Vücut Sıcaklığı	Anne vücut sıcaklığının Fahrenheit cinsinden değeri	Nümerik
6	Kalp Atış Hızı	Normal dinlenme anında dakikadaki kalp atış hızı değeri	Nümerik
7	Risk Düzeyi	Gebelik sırasında öngörülen risk düzeyi	Kategorik

3.2 Algoritmalar

Bu çalışmada, anne risk sağlığını tahmin edebilmek için YZ algoritmalarından DVM, YSA, Extreme Gradient Boosting (XGBoost), Adaptive Boosting (AdaBoost) ve Gradyan Artırmalı (Gradient Boosting) algoritmaları kullanılmıştır.

DVM, sınıflandırma veya regresyon analizi yapmak için kullanılan güçlü bir denetimli MÖ algoritmalarından biridir. Verileri sınıf etiketlerine göre ayırarak en iyi hiperdüzlemi bulmaya amaçlamaktadır. Bu sayede sınıflandırma problemlerinde optimum ayrımı sağlamaya yardımcı olmaktadır [18,19]. Bu çalışma kapsamında uygulanan modelde C hiper parametresi 5 olarak belirlenmiştir. Çekirdek fonksiyonu olarak Doğrusal Çekirdek Fonksiyonu, Polinom (Polynomial) Çekirdek Fonksiyonu, Sigmoid (Hiperbolik Tanjant) Çekirdek Fonksiyonu, Gaussian RBF (Radial Basis Function) Çekirdek

Fonksiyonu uygulanmış ve en başarılı sonuç RBF Çekirdek Fonksiyonu ile elde edilmiştir.

YSA, insan beynindeki nöronların yapısının matematiksel olarak modellenmesi ile tasarlanmış yöntemdir. YSA girdi, çıktı ve ağırlık değerleri üzerinden kendi kendine öğrenebilmekte, çıkarımlarda bulunabilmekte ve kararlar alabilmektedir [20]. Karmaşık problemlere pratik ve hızlı çözüm bulabilme, eksik veri ile çalışabilme, belirsizlik durumunda karar verme ve hata toleransı bulunmaktadır. YSA sınıflandırma, tahminleme, kümeleme, veri sıkıştırma ve optimizasyon konularında da güçlü sonuçlar üreten teknikler arasındadır [21,22]. Bu çalışma kapsamında uygulanan modelde üç katmanlı bir yapı oluşturulmuştur. Çıkış katmanında softmax aktivasyon fonksiyonu ile kullanılmış, optimizasyon yöntemi olarak adam kullanılmıştır.

XGBoost, artırımlı ve ağaç tabanlı bir öğrenme yöntemi sunmaktadır. Hızlı işleme yeteneği ve yüksek performans gerektiren durumlarda sıkça

kullanılmaktadır. Büyük veri setleri üzerinde hızlı ve etkili öğrenme sağlayan Gradient Boosting algoritmasının geliştirilmiş bir versiyonudur. Bu özelliği ile de yüksek başarımda sonuçlar veren bir MÖ yöntemidir [23,24].

AdaBoost, artırma zayıf bir sınıflandırıcıyı güçlü hale getirme işlemidir. İkili sınıflandırma ve regresyon analizleri için geliştirilmiş güçlü bir artırma algoritmasıdır [25,26].

Gradient Boosting, artırma algoritmalarının temel yaklaşımı, zayıf öğrencileri tekrarlayarak artırılmış güçlü öğrenci elde etmektir. Gradient Boosting yöntemi kayıp fonksiyonu en aza indirerek toplam modeli bulmayı amaçlayan bir MÖ algoritmasıdır. Zayıf öğrencileri güçlü öğrenciye dönüştürme üzerine çalışmaktadır [27,28]. Bu çalışma kapsamında uygulanan tüm modellerde veri setinin yüzde seksenlik bölümü kullanılarak eğitim gerçekleştirilmiştir.

3.3 Performans Metrikleri

Karışıklık matrisi, uygulanan modelde yer alan her bir sınıf için doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) tahminleri göstererek sınıflandırma sonuçlarının ayrıntılı bir şekilde değerlendirilmesini sağlamaktadır [29].

Doğruluk (Accuracy), doğru sınıflandırılmış veri sayısı ile toplam veri sayısının oranı hesaplanarak değerlendirilmektedir. Doğruluk metriğinin formülü denklem (1) ile verilmiştir [30].

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Kesinlik (Precision), uygulama sonucunda doğru pozitif örnek sayısı ile tüm pozitif örnek sayılarının oranı ile hesaplanmaktadır. Kesinlik metriğinin formülü denklem (2) ile verilmiştir [30].

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (2)$$

Duyarlılık (Recall), doğru tahmin edilen pozitif örneklerin sayısı ile toplam doğru örnek sayısının

oranı ile hesaplanmaktadır. Duyarlılık metriğinin formülü denklem (3) ile verilmiştir [31].

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (3)$$

F1-skor, kesinlik ve duyarlılık metriklerinin sonuçlarının harmonik ortalaması alınarak hesaplanmaktadır. F-skor formülü denklem (4) ile verilmiştir [31].

$$\text{F1 - skor} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

AUC (Eğri Altında Kalan Alan), olasılık eğrisi olarak ifade edilen ve ROC eğrisi sınıflandırmadaki performansı gösteren bir metriktir. ROC eğrisinin altında kalan alan AUC olarak ifade edilmektedir. Bu metriğin değeri 1'e ne kadar yakın ise modelin performansının da o kadar yüksek olduğu şeklinde yorumlanır [30].

4 Bulgular

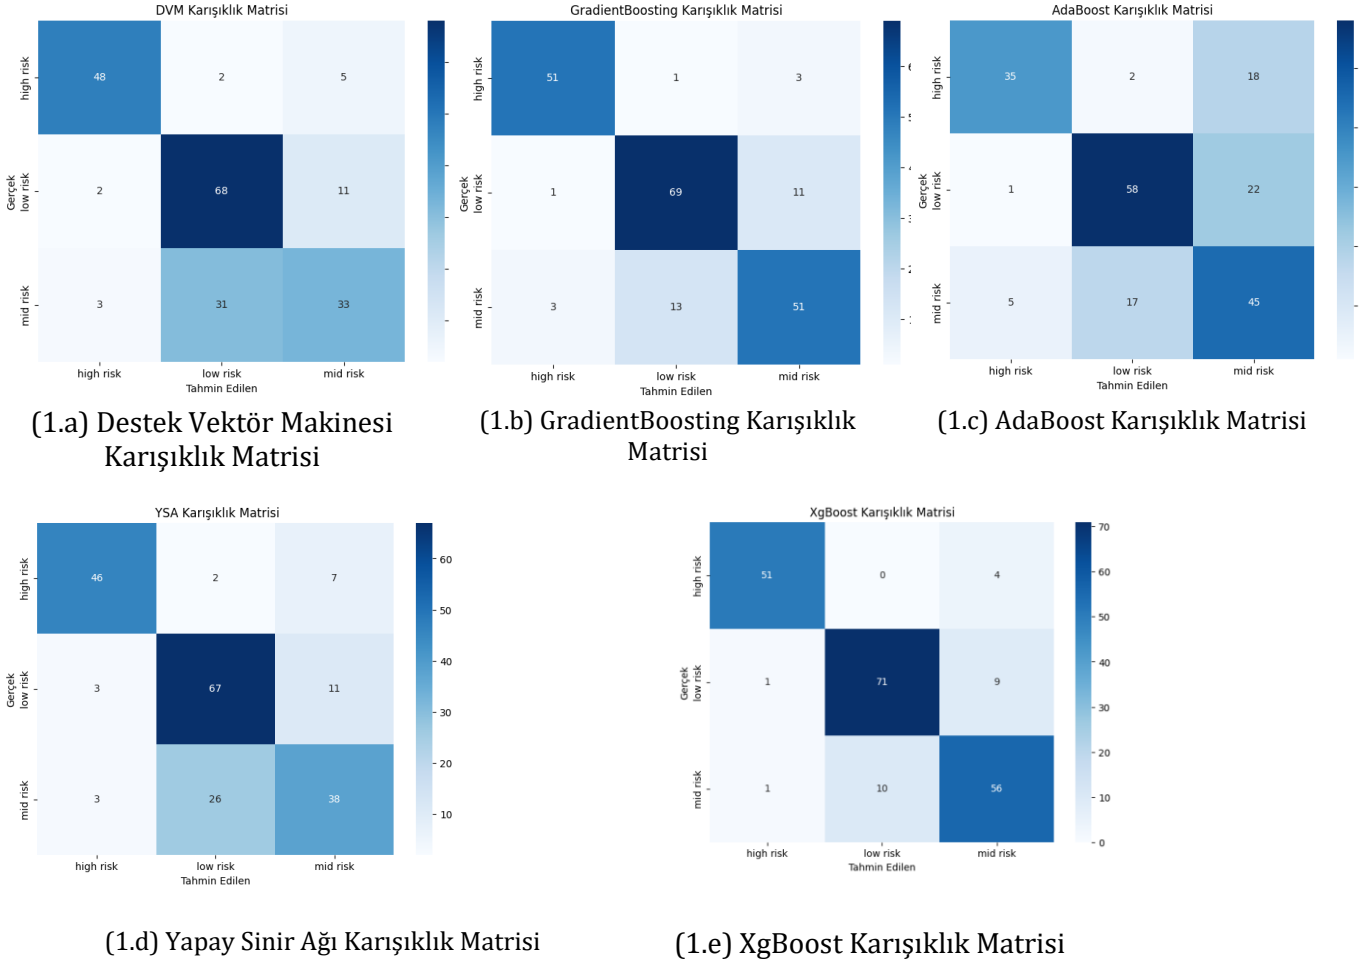
Anne sağlığının risk düzeyini tahmin edebilmek amacıyla DVM, Gradient Boosting, AdaBoost, YSA ve XGBoost makine öğrenmesi modelleri kullanılarak çalışma gerçekleştirilmiştir. Belirlenen makine öğrenmesi modelleri veri setine uygulanarak doğruluk, kesinlik, duyarlılık ve f1-skor performans metrikleri ile değerlendirilmiş ve karışıklık matrisi oluşturulmuştur. Tablo 3 ile makine öğrenmesi modellerinin uygulanması ile elde edilen performans metriklerine ait sonuçlar verilmiştir. Elde edilen sonuçların doğruluk oranı incelendiğinde 0.87 ile XGBoost algoritmasının en iyi sonuca, 0,67 ile AdaBoost algoritmasının en düşük sonuca sahip olduğu görülmektedir.

Tablo 3. Makine öğrenmesi modellerinin sonuçları

Tahmin Modeli	Doğruluk	Kesinlik	Duyarlılık	F1-skor	AUC
Destek Vektör Makinesi	0.73	0.74	0.73	0.73	0.87
GradientBoosting	0.84	0.84	0.84	0.84	0.94
AdaBoost	0.67	0.70	0.67	0.68	0.75
Yapay Sinir Ağı	0.74	0.74	0.74	0.74	0.89
XGBoost	0.87	0.88	0.88	0.88	0.96

Makine öğrenmesi modellerinden elde edilen sonuçlar üzerinden karışıklık matrisi oluşturularak sınıflandırma sonuçlarının ayrıntılı dökümü sağlanmıştır.

Şekil 1 ile bu çalışmada uygulanan makine öğrenmesi modellerine ait karışıklık matrisleri verilmiştir.

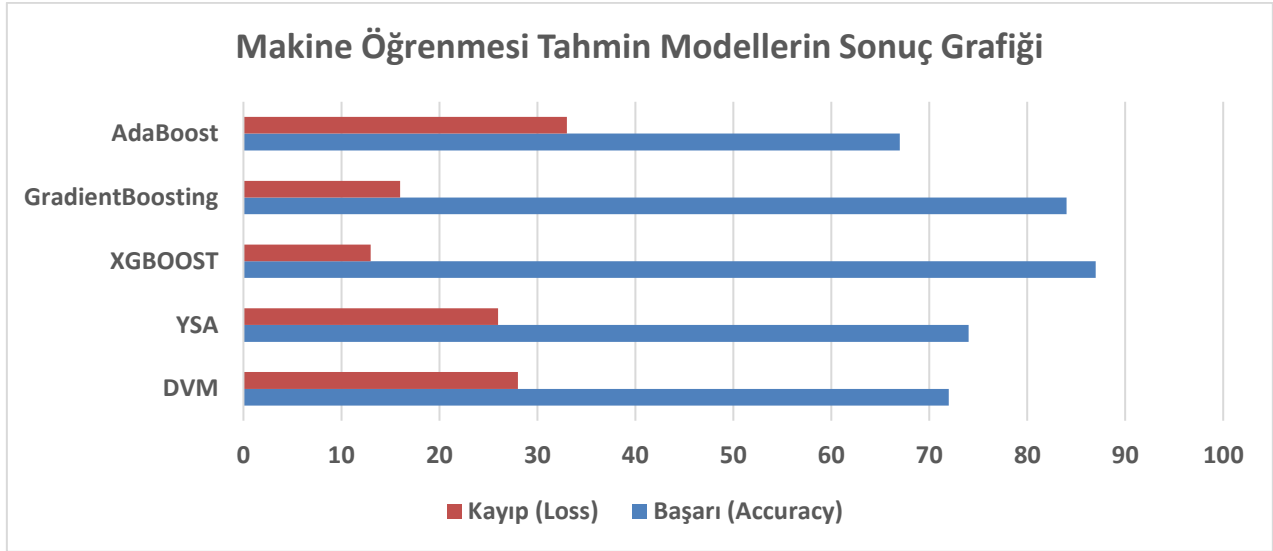


Şekil 1. Uygulanan makine öğrenmesi modellerinin karışıklık matrisleri

Anne sağlığı ile ilgili risklerin ele alındığı bu çalışmada yapılan deneyler sonucunda DVM ile %73, GradientBoosting ile %84, AdaBoost ile %67, YSA ile %74 ve XgBoost ile %87 başarı oranları elde edilmiştir.

Uygulanan her makine öğrenmesi modeli için elde edilen başarı ve kayıp oranları Şekil 2 ile verilmiştir. Tablo 3 ile verilmiş olan kesinlik, duyarlılık, F1 skor

ve AUC performans metriklerinin başarı oranları ile uyumlu olduğu görülmektedir. Bu değerler uygulanan modellerin performansını ifade eden doğruluk parametresinin ne kadar başarılı şekilde hesaplandığını göstermektedir. Örneğin; F1 skor değeri incelendiğinde DVM ile 0.73, GradientBoosting ile 0.84, AdaBoost ile 0.68, YSA ile 0.74 ve XgBoost ile 0.88 sonucunun elde edildiği görülmektedir.



Şekil 2. Makine Öğrenmesi Tahmin Modellerine Ait Sonuçlar

5 Sonuçlar

Hamile bir kadının sağlık verilerinin makine öğrenmesi yöntemleri kullanılarak analiz edilmesi ile risk düzeyinin tahmini için farklı modeller uygulanmıştır. Çalışmanın sonuçları değerlendirildiğinde Anne Sağlığı Risk Veri Setinde (Maternal Health Risk Dataset) bulunan, yaş, büyük tansiyon, küçük tansiyon, kan şekeri, kalp atımı, vücut sıcaklığı ve risk düzeyi özellikleri üzerinden en başarılı sonuç XGBoost algoritması ile elde edilmiştir. Sonuç olarak bu çalışmada kullanılan makine öğrenmesi modelleri sayesinde anne sağlığı ile ilgili farklı olasılık koşulları değerlendirilmiştir. Çalışma kapsamında DVM, GradientBoosting, AdaBoost, YSA ve XgBoost makine öğrenmesi modelleri kullanılarak deneyler yapılmıştır. Sonuç olarak DVM modeli ile %73, GradientBoosting modeli ile %84, AdaBoost modeli ile %67, YSA modeli ile %74 ve XgBoost modeli ile %87 başarı oranları elde edilmiştir. Anne Sağlığı Risk Veri Setinde en iyi performansa %87 başarı oranı ile XgBoost modelinin sahip olduğu görülmüştür. Yapay zeka teknikleri ile düşük riskini değerlendirmek amacıyla farklı makine öğrenmesi modelleri kullanılarak hibrit deneyler gerçekleştirilebilir.

6 Kaynaklar

- [1] Thakkar, Dhruvi, Vaibhav C. Gandhi, Dhriti Trivedi. "Forecasting Maternal Women's Health Risks using Random Forest Classifier." *International Conference on Inventive Computation Technologies (ICICT)*. IEEE, 2024.
- [2] Maheswari, B. Uma, Aniket Dixit, Alok Kumar Karn. "Machine Learning Algorithm for Maternal Health Risk Classification with SMOTE and Explainable AI." *9th International Conference for Convergence in Technology (I2CT)*. IEEE, 2024.
- [3] Olonade, O., Olawande, T. L., Alabi, O. J. & Imhonopi, D. "Maternal Mortality and Maternal Health Care in Nigeria: Implications for Socio-Economic Development." *Open access Macedonian journal of medical sciences vol. 7,5* 849-855. 2019.
- [4] Musarandega, R., Nyakura, M., Machekano, R., Pattinson, R. & Munjanja, S. P. "Causes of maternal mortality in Sub-Saharan Africa: a systematic review of studies published from 2015 to 2020." *Journal of Global Health*. 2021.
- [5] World Health Organization. "Global health observatory (GHO) data." 2015.
- [6] Li, S., Wang, Z., Vieira, L. A., Zheutlin, A. B., Ru, B., Schadt, E., & Li, L., "Improving preeclampsia risk prediction by modeling pregnancy trajectories from routinely collected electronic medical record data." *npj Digital Medicine* 5.1. 2022
- [7] Gunawardane, D. A. "Sri Lankan Newborns; Improving Survival and Well-Being." *Sri Lanka Journal of Medicine*. 2024.
- [8] Grieger, J. A., Hutchesson, M. J., Cooray, S. D., Bahri Khomami, M., Zaman, S., Segan, L., & Moran, L. J. "A review of maternal overweight and obesity and its impact on cardiometabolic outcomes during pregnancy and postpartum." *Therapeutic advances in reproductive health* 15, 2021: 2633494120986544.
- [9] Ramakrishnan, Rema, Shishir Rao, and Jian-Rong He. "Perinatal health predictors using artificial

- intelligence: A review." *Women's Health* 17, 2021: 17455065211046132.
- [10] Rai, S. K., and Sowmya, K. "A review on use of machine learning techniques in diagnostic health-care." *Artificial Intelligent Systems and Machine Learning* 10.4. 2018: 102-107.
- [11] Ahmed, M., Kashem, M. A., Rahman, M., & Khatun, S. "Review and analysis of risk factor of maternal health in remote area using the Internet of Things (IoT)." In *InECCE2019: Proceedings of the 5th International Conference on Electrical, Control & Computer Engineering, Kuantan, Pahang, Malaysia, 29th July 2019* (pp. 357-365). Springer Singapore. 2020.
- [12] Ramdhani, Y., Maulidia, D., Setiadi, A., & Alamsyah, D. P. "Feature Weighting Optimization: Genetic Algorithms and Random Forest for Classification of Pregnant Potential Risk." In *2022 International Conference on Information Technology Research and Innovation (ICITRI)* (pp. 95-100). IEEE. 2022.
- [13] Umoren, Imeh, A. Silas, & B. Ekong. "Modeling and prediction of pregnancy risk for efficient birth outcomes using decision tree classification and regression model." *Artificial intelligence and soft computing 21st international conference, ICAISC. 2022.*
- [14] Edayath, Prajina. *Analysis Of Factors Affecting Maternal Health Using Data Mining Techniques*. MS thesis. The University of Texas at El Paso, 2022.
- [15] Mutlu, H.B., Durmaz, F., Yücel, N., Cengil, E., ve Yıldırım, M. "Prediction of maternal health risk with traditional machine learning methods." *Naturengs* 4.1. 2023: 16-23.
- [16] Şahin, F., Tulum, G. and Karaca, Ş. "Anne Sağlığı Riski İçin Makine Öğrenmesi Modellerinin Performans Karşılaştırması." *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi* 14.4. 2023: 547-553.
- [17] Ahmed, M., Kashem, M.A., Rahman, M., & Khatun, S. "Review and Analysis of Risk Factor of Maternal Health in Remote Area Using the Internet of Things (IoT)." *Lecture Notes in Electrical Engineering*. 2020.
- [18] Üzen, H., Fırat, H. "Göğüs Röntgeni Görüntülerinden Akciğer Hastalıklarının Sınıflandırılması için Farklı Derin Öznitelikler ile Beslenen Destek Vektör Makinesi." *Bilişim Teknolojileri Dergisi* 17.1. 2024: 11-21.
- [19] Elen, A., Baş, S. & Közkurt, C. "An adaptive Gaussian kernel for support vector machine." *Arabian Journal for Science and Engineering* 47.8. 2022: 10579-10588.
- [20] Yusufoglu, H., Aydın, H. & Çetinkaya, A. "Twitter Üzerindeki Finansal Tweetlerin LSTM Sinir Ağı Algoritması ile Duygu Analizi." *Veri Bilimi* 4.3. 2021: 28-43.
- [21] Keskenler, M. F., Keskenler, E. F. "Geçmişten günümüze yapay sinir ağları ve tarihçesi." *Takvim-i Vekayi* 5.2. 2017: 8-18.
- [22] Eğrioğlu, E., U. Yolcu, & E. Baş. "Yapay sinir ağları öngörü ve tahmin uygulamaları." Nobel Yayıncılık. 2019.
- [23] Fangoh, A. M., Selim, S. "Using CNN-XGBoost deep networks for COVID-19 detection in chest X-ray images." *2020 15th international conference on computer engineering and systems (ICCES)*. IEEE, 2020.
- [24] Azizoğlu F. "Makine Öğrenmesi Yöntemleriyle Kalp Hastalıklarının Sağlık Tahmini", Yüksek Lisans Tezi, Bilgisayar Mühendisliği Ana Bilim Dalı, Sivas Cumhuriyet Üniversitesi. 2023.
- [25] Freund, Y., Schapire, R. E. "A decision-theoretic generalization of on-line learning and an application to boosting." *Journal of computer and system sciences* 55.1. 1997: 119-139.
- [26] Thomas, T., Vijayaraghavan, A. P., & Emmanuel, S. "Machine learning approaches in cyber security analytics." Singapore: Springer, 2020.
- [27] Friedman, J., Hastie, T., & Tibshirani, R. "Additive logistic regression: a statistical view of boosting (with discussion and a rejoinder by the authors)." *The annals of statistics* 28.2. 2000: 337-407.
- [28] Yeşilyurt, S., Dalkılıç, H. "Xgboost ve gradient boost machine ile günlük nehir akımı tahmini." *3rd International Symposium of III Engineering Applications on Civil Engineering and Earth Sciences*. 2021.
- [29] Kayaalp, K., Varol, A. "LeNet ve ResNet Derin Öğrenme Modelleri ile Asma Yapraklarının Sınıflandırması". *Veri Bilimi*, 7(1), 16-25. 2024.
- [30] Kılıçer, S., Şamlı, R. "E-Ticaret Sitelerindeki Türkçe Ürün Yorumları Üzerine Makine Öğrenmesi Algoritmaları ile Duygu Analizi." *Veri Bilimi* 6.2: 15-23.
- [31] Özcan, I., Aydın, H., & Çetinkaya, A. "Comparison of classification success rates of different machine learning algorithms in the diagnosis of breast cancer." *Asian Pacific journal of cancer prevention: APJCP* 23.10. 2022: 3287.