

Xgboost Algoritmasıyla Polikistik Over Sendromu Teşhisi

Diagnosis Of Polycystic Ovary Syndrome With Xgboost Algorithm

Ömer Çağrı YAVUZ¹

ÖZ

Karmaşık bir endokrin bozukluk olan Polikistik Over Sendromu (PKOS), üreme çağındaki kadınları etkilemektedir. Adet düzensizlikleri, hiperandrojenizm ve polikistik overler gibi çeşitli semptomların kombinasyonunu barındırır. Ultrasonda artan sayıda stroma ve folikül varlığı polikistik yumurtalıkları ifade etse de bu durum PKOS tanısı için yeterli görülmemektedir. Metabolik anormallikler, kadın tipi saç dökülmesi, cinsel tatmin ve depresyon PKOS ile ilişkilendirilmektedir. Bu ilişkilerin anlamlandırılması ve analiz edilmesi PKOS teşhisi için önem arz etmektedir. Bu çalışma kapsamında son yıllarda literatürde sıklıkla kullanılan ve diğer algoritmalara göre daha hızlı ve güvenli olduğu belirtilen XGBoost algoritmasıyla PKOS'un teşhis edilmesi amaçlanmıştır. Bu doğrultuda Kaggle veri tabanından alınmış ve toplamda 541 kayıttan oluşan veri setine XGBoost algoritması uygulanmıştır. Çalışmada kullanılan veri seti Kerala (Hindistan)'da yer alan 10 farklı hastaneden elde edilmiştir. Ayrıca kategorik verilerin algoritma performansı üzerindeki etkilerinin incelenmesi amaçlanarak farklı veri setleri oluşturularak performansları değerlendirilmiştir. Son olarak veri setindeki dağılımın performans üzerindeki etkisinin ortaya konulması amaçlanarak veri seti dengeli hale getirilerek performans test edilmiştir. 541 kayıttan oluşan veri setiyle 0,87 doğruluk değeri elde edilmiştir. Çalışmada elde edilen performans metrikleri doğrultusunda sağlık alanında sınıflandırma problemlerinin çözümünde XGBoost algoritmasının katkı sağlayacağı söylenebilir.

Anahtar Kelimeler: Polikistik Over Sendromu, Sağlık Bilişimi, Sınıflandırma

ABSTRACT

Polycystic Ovary Syndrome (PCOS), a complex endocrine disorder, affects women of reproductive age. It involves a combination of symptoms including menstrual irregularities, hyperandrogenism and polycystic ovaries. Although the presence of an increased number of stroma and follicles on ultrasound indicates polycystic ovaries, this is not considered sufficient for the diagnosis of PCOS. Metabolic abnormalities, female pattern hair loss, sexual satisfaction and depression are associated with PCOS. Making sense of and analyzing these relationships is important for the diagnosis of PCOS. This study aims to diagnose PCOS with the XGBoost algorithm, which is frequently used in the literature in recent years and is reported to be faster and safer than other algorithms. In this direction, XGBoost algorithm was applied to the dataset taken from the Kaggle database and consisting of 541 records in total. The dataset used in the study was obtained from 10 different hospitals in Kerala (India). In addition, in order to examine the effects of categorical data on algorithm performance, different data sets were created and their performances were evaluated. Finally, the performance was tested by balancing the data set in order to reveal the effect of the distribution in the data set on the performance. With a dataset of 541 records, an accuracy value of 0,87 was obtained. In line with the performance metrics obtained in the study, it can be said that the XGBoost algorithm will contribute to the solution of classification problems in the field of health.

Keywords: Polycystic Ovary Syndrome, Health Informatics, Classification

¹ Dr. Öğr. Üyesi, Ömer Çağrı YAVUZ, Makine Öğrenmesi, Trabzon Üniversitesi, Yönetim Bilişim Sistemleri, omercagriyavuz@gmail.com, ORCID: 0000-0002-6655-3754

İletişim / Corresponding Author:
e-posta/e-mail:

Ömer Çağrı YAVUZ
omeragriyavuz@gmail.com

Geliş Tarihi / Received: 26.09.2023
Kabul Tarihi/Accepted: 23.09.2024

GİRİŞ

Yapay Zekâ, temelde akıllı canlılara ait davranış ve düşünce biçimlerinin sistemlere aktarılmasına dayanır. Akıllı davranışlar problem çözme, örüntü tanıma, öğrenme ve bilgiyi kullanma gibi özellikler içerir. Bu doğrultuda yapay zekâ disiplininin amacı akılcı veya insan gibi davranış ve düşünceleri cihaz ve sistemlere aktarmaktır. Davranışlarla birlikte muhakeme sürecinin de dikkate alındığı insan gibi düşünen sistemlerde zihinsel süreçler anlaşılabilir çalışılır.¹ Sorulan sorular doğrultusunda muhabatın insan veya makine olma durumunun araştırıldığı Turing Testi, yapay zekâ çalışmalarının öncülerinden kabul edilmektedir.² Turing testinde insan gibi davranan bir model geliştirilmesi amaçlanmaktadır. Turing testinde ele alınan “Makineler düşünebilir mi?” sorusuyla makinelerin düşünebilme durumu ortaya konulmuştur.³ Bu sorunun cevabı aranırken önceki bilgisayarlardan farklı olarak problem çözümünde veri saklama işleminden faydalanılmıştır. Önceki bilgisayarların fonksiyonlarından farklı olarak veri depolama ve güncelleme işlemleri sonraki süreçte geliştirilen bilgisayarların temelini oluşturmaktadır.

Turing testi yapay zekânın öncüsü olarak kabul edilse de “Yapay Zekâ” kavramı ilk olarak 1956 yılında New Hampshire, Dartmouth College’da bilgisayarların düşünebilme ihtimalinden bahsedilen Yapay Zekâ Üzerine Dartmouth Yaz Araştırma Projesi’nde ortaya atılmıştır.⁴ İlerleyen süreçte bir dönem yapay zekâyı eleştiren raporlar yayımlansa da 1980’li yıllarda İngilizlerin Japonlarla rekabeti için fonladıkları yapay zekâ alanı yeniden gelişmeye başlamıştır.⁵ Sonrasında temel mantığında öğrenme becerisi yatan yapay zekâ kavramı, farklı alanlarda çeşitli çalışmalarla gün geçtikçe gelişim göstermektedir.⁶

Yapay zekâ alanının bir dalı olan makine öğrenmesi, büyük miktardaki verilerin işlenmesi, analiz edilmesi ve örüntülerin tespit edilmesini sağlamaktadır. Makine

öğrenmesi algoritmaları, tıp bilişimi ve sağlık hizmetleri uygulamalarında da sıklıkla kullanılmaktadır. Bu algoritmalar sağlık uygulamalarında etkinlik, verimlilik ve güvenilirlik açısından katkı sağlamaktadır. Sağlık alanında büyük miktardaki verilerin analizinde çeşitli zorluklar yaşanmaktadır. Makine öğrenmesi algoritmaları, karmaşık problemlerin çözülmesi ve karar süreçlerine katkı sağlamak amaçlanarak verilerin işlenmesi ve analiz edilmesi noktasında yardımcı olmaktadır. Derin öğrenme algoritmalarıyla birlikte bu algoritmalar sınıflandırma problemlerinin çözümünde verimlilik ve güvenilirlik açısından etkinlik göstermektedir.⁷ Sağlık alanında hastalıkların tahmin edilmesi ve tedavi planlarının optimizasyonu gibi amaçlarla kullanılan makine öğrenmesi algoritmalarında operasyonel ve metodolojik zorluklar yaşanmaktadır.⁸

Polikistik Over Sendromu (PKOS), adet düzensizlikleri, hiperandrojenizm ve polikistik overlar ile ilişkili karmaşık bir endokrin bozukluktur. Metabolik anormallikler, kadın tipi saç dökülmesi, cinsel tatmin ve depresyon PKOS ile ilişkilendirilmektedir. Bu ilişkilerin anlamlandırılması ve analiz edilmesi PKOS teşhisi için önem arz etmektedir. Ancak PKOS’un teşhis ve tedavisinde daha fazla araştırmaya ihtiyaç duyulduğu söylenebilir.⁹

Teşhisinde birçok kriter ele alınsa da PCOS tedavi süreci, sendromun nedeni ve gen regülasyonu açısından bazı belirsizlikleri barındıran bir hastalıktır. Bu doğrultuda toplanan veriler ışığında genlerin birbirleriyle ilişkisinin incelenerek belirsizliklerin giderilmesi, etkin ve ucuz tedavi yöntemlerinin geliştirilebileceği belirtilmektedir.¹⁰

PCOS gibi hastalıkların teşhisinde verilerin analiz edilmesi, karar sürecinin otomatikleştirilmesi ve karmaşık kararlara destek sağlanması amacıyla çeşitli makine öğrenmesi algoritmaları kullanılmaktadır. Bu çalışma kapsamında Hindistan’da 10 farklı

hastaneden elde edilen veri seti kullanılarak Polikistik Over Sendromu'nun teşhis edilmesinde makine öğrenmesi algoritmalarının uygulanabilirliğinin test edilmesi amaçlanmıştır. Bu amaç doğrultusunda sağlık alanında sıklıkla kullanılan ve yüksek başarımlı gösteren XGBoost algoritması kullanılarak performans metrikleri incelenmiştir. Yapılan uygulamada 44 farklı parametreye bağlı olarak PKOS tanısının hızlı ve etkin bir şekilde gerçekleştirilmesi amaçlanmaktadır. Ayrıca bu çalışma kapsamında yapılan uygulamada elde edilen performans metriklerine bağlı olarak karmaşık karar problemlerini içeren hastalık teşhisine yönelik uygulamalarda makine öğrenmesi algoritmalarının kullanımının sürece katkı sağlayacağı öngörülmektedir.

Polikistik Over Sendromu

Karmaşık bir endokrin bozukluk olan PKOS, üreme çağındaki kadınları etkilemektedir. Adet düzensizlikleri, hiperandrojenizm ve polikistik overler gibi çeşitli semptomların kombinasyonunu

barındırır. Ultrasonda artan sayıda stroma ve folikül varlığı polikistik yumurtalıkları ifade etse de bu durum PKOS tanısı için yeterli görülmemektedir.¹¹ Metabolik anormallikler, depresif belirtiler, kadın tipi saç dökülmesi, cinsel tatminin PKOS ile ilişkili olduğu belirtilmektedir.¹² Örnek bir çalışmada depresyon belirtileri olan PCOS'lu kadınların, depresif belirtilen göstermeyen kadınlara göre daha düşük testosteron seviyesine sahip olduğu vurgulanmıştır.¹³ Yine benzer bir çalışmada depresif belirtilerin yüksek testosteron seviyeleri ile ilişkili olduğu belirtilmiştir.¹⁴

Depresif belirtilere ek olarak metabolik anormallikler de PKOS ile ilişkilendirilmektedir. Örnek olarak hiperinsülinemi, insülin direnci, obezitenin PKOS'lu kadınlarda sıklıkla görüldüğü belirtilmektedir.¹⁵ Ayrıca kadın tipi saç dökülmesine sahip kadınların PKOS'a sahip olma olasılıklarının daha yüksek olduğu belirtilmiştir.¹⁶ Son olarak PKOS'un cinsel tatmini etkilediği de yapılan araştırmalarla ortaya konulmuştur.¹⁷

MATERYAL VE METOT

Veri Seti

Çalışma kapsamında kullanılan veri seti toplamda 44 parametreden oluşmakta olup Kaggle veri tabanından alınmıştır. Bu veriler Kerala (Hindistan)'da yer alan 10 farklı hastaneden elde edilmiştir. Veri setinde yer alan öznitelikler PKOS ve kısırlık teşhisinde le alınan fiziksel ve klinik parametreleri içermektedir. Bu parametreler arasında yaş, kilo, kan grubu, evlilik durumu, hamilelik durumu, bel kalça oranı, vitaminler, glikoz testi gibi öznitelikler yer almaktadır. Toplamda 541 kayıttan oluşan veri setinin 1 değeri PKOS tanısı konulan kadınları temsil ederken, 0 değeri PKOS tanısı konulmayan hastaları temsil etmektedir. Hasta numarası ve dosya numarası gibi sonuca etki etmeyen parametreler veri setinden çıkarılmıştır. Elde edilen veri setinde yer alan öznitelikler aşağıda verilmiştir.

- PCOS (1/0)

- Yaş
- Ağırlık (Kg)
- Vücut Kitle Endeksi
- Kan Grubu
- Nabız (bpm)
- Risk Oranı
- Hemogloblin seviyesi (g/dl)
- Siklus (R/I)
- Siklus Süresi (gün)
- Evlilik Durumu
- Hamilelik
- Kürtaj Sayısı
- I beta-HCG hormonu (mIU/mL)
- II beta-HCG hormonu (mIU/mL)
- Folikül Uyarıcı Hormon (FSH-mIU/mL)

- Lüteinizan Hormonu (LH-mIU/mL)
- FSH/LH
- Kalça (inch)
- Bel (inch)
- Bel – Kalça Oranı
- Tiroid Uyarıcı Hormon (mIU/L)
- Antimülleryen Hormon (ng/mL)
- Prolokatin (ng/mL)
- D3 Vitamini (ng/mL)
- Progesteron Hormonu
- Alyuvar Sayısı (mg/dl)
- Kilo artışı
- Kılınma (1/0)
- Cilt Kararması (1/0)
- Saç Dökülmesi (1/0)
- Sivilce (1/0)
- Fast food tüketimi (1/0)
- Reg. Egzersizi (1/0)
- Sistolik Kan Basıncı (mmHg)
- Diastolik Sistolik Değer (mmHg)
- Folikül No. (L)
- Folikül No. (R)
- Ortalama F Büyüklüğü (L) (mm)
- Ortalama F Büyüklüğü (R) (mm)
- Endometrium (mm)

İki farklı veri seti ile yapılan uygulamada pozitif kayıtların sayısı 177 iken negatif kayıtların sayısı 364'tür.

XGBoost (Extreme Gradient Boosting) Algoritması

Sınıflandırma problemlerinin çözümünde sıklıkla kullanılan XGBoost algoritması veri kümelerinin işlenmesi ve analizinde fayda sağlamaktadır. XGBoost, sınıflandırma performansını arttırarak tahminlerin doğruluğunu yükseltmek için çoklu zayıf öğreniciler ve özellikle karar ağaçlarının

tahminlerini birleştiren bir makine öğrenmesi algoritmasıdır.¹⁸

Yinelemeli karar ağaçlarını bünyesinde barındıran XGBoost algoritması, karar ağaçları üreterek çalışır ve oluşturulan her yeni ağaç hataları optimize etmeyi amaçlar. Gerçek değerler ve tahmin edilen değerler arasındaki farklılıklar eğitim sürecinde kayıp fonksiyonunu iyileştirir. Yeni oluşturulan ağacın öncesinde oluşturulan ağaçlarda yer alan hataları indirgeyecek şekilde eğitimini ifade eden gradyan güçlendirmeyi kullanır. Yinelemeli bir yapıya sahip olmasına rağmen XGBoost algoritmasının diğer algoritmalara göre 10 kat daha hızlı çalıştığı vurgulanmaktadır.¹⁹

XGBoost'un en önemli avantajlarından biri, eksik verileri ve aykırı değerleri etkili bir şekilde işleme yeteneğidir. Ağaç oluşturma işlemi sırasında varsayılan yönler atayarak eksik değerleri işlemek için yerleşik mekanizmalara sahiptir. Ek olarak, XGBoost, modelin karmaşıklığını kontrol etmeye ve genelleştirme yeteneğini geliştirmeye yardımcı olan teknikler kullanır. XGBoost algoritmasının bu yönleriyle literatürde sıklıkla kullanılan diğer algoritmalarda yer alan sorunların ortadan kaldırılmasında katkı sağladığı belirtilmektedir. Ayrıca XGBoost algoritmasının Kaggle ve KDDCup gibi organizasyonların makine öğrenmesi yarışmalarında kazanan uygulamalarda öne çıktığı belirtilmektedir.²⁰

Sağlık alanında yer alan sınıflandırma problemlerinde de sıklıkla kullanılan XGBoost algoritmasıyla yüksek başarımlar elde edilmektedir.²¹⁻²⁴ Özetle, XGBoost algoritması, makine öğrenmesi uygulamalarında popüler bir seçim haline gelmektedir. Bu çalışma kapsamında regularizasyon, seyreklik uyumu, ağırlıklı çeyrek çizim ve çapraz doğrulama imkânı sunan ve 2016 yılında geliştirilen XGBoost algoritmasıyla PCOS sendromunun teşhis edilmesi amaçlanmıştır.

Performans Metrikleri

Makine öğrenmesi algoritmalarıyla yapılan uygulamalarda elde edilen performans karışıklık matrisi ile ifade

edilebilmektedir. Bahsedilen karışıklık matrisi Tablo 1’de verilmiştir.

Tablo 1. Karışıklık Matrisi

		Gerçek Değer	
		Pozitif (1)	Negatif (0)
Tahmin Edilen Değer	Pozitif (1)	TP [1,1]	FN [1,0]
	Negatif (0)	FP [0,1]	TN [0,0]

Yukarıdaki tabloda;

TP (True Positive), doğru tahmin edilen 1 değerlerinin sayısını,

TN (True Negative), doğru tahmin edilen 0 değerlerinin sayısını,

FN (False Negative), yanlış tahmin edilen 1 değerlerinin sayısını,

FP (False Positive), yanlış tahmin edilen 0 değerlerinin sayısını ifade eder.

Yukarıda karışıklık matrisinde yer alan değerler doğrultusunda çalışma kapsamında XGBoost algoritmasının performansının ortaya konulması amacıyla kullanılan doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve f1 skorunun formülleri aşağıda verilmiştir.

$$\text{Doğruluk: } \frac{(TP + TF)}{(TP + TF + FP + FN)} \quad \text{Duyarlılık: } \frac{TP}{(TP + FN)}$$

$$\text{Kesinlik: } \frac{TP}{(TP + FP)} \quad \text{F1 Skoru: } 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$$

BULGULAR VE TARTIŞMA

Çalışma kapsamında Kaggle veri tabanından elde edilen ve toplamda 541 kayıttan oluşan veri setine XGBoost algoritması uygulanmıştır. Yapılan uygulamada 0,87 doğruluk değeri elde edilmiş olup kesinlik değeri, duyarlılık değeri ve f1 skoru Tablo 2’de verilmiştir.

Tablo 2. Performans Metrikleri

	Kesinlik	Duyarlılık	F1 Skoru
0	0,89	0,94	0,91
1	0,84	0,74	0,79

Yapılan uygulama sonrasında öznitelikler içerisinde hamilelik durumu, kılınma, kilo alma durumu, cilt koyulaşması, saç dökülmesi, sivilce oluşma durumu, fast food tüketimi, egzersiz yapma durumu ve kan grubu gibi kategorik parametreler çıkarılmıştır. Kategorik değerler çıkarıldıktan sonra yapılan uygulamada elde edilen performans metrikleri Tablo 3’te verilmiştir.

Tablo 3. Performans Metrikleri (Kategorik Değerler Çıkarılan Veri Seti)

	Kesinlik	Duyarlılık	F1 Skoru
0	0,86	0,98	0,92
1	0,94	0,64	0,76

Sonrasında sadece kategorik özniteliklerden oluşan bir veri seti oluşturularak XGBoost algoritması uygulanmıştır. Yapılan uygulamada doğruluk değerinin 0,82’ye düştüğü görülürken elde edilen diğer performans metrikleri Tablo 4’te verilmiştir.

Tablo 4. Performans Metrikleri (Kategorik Değerler)

	Kesinlik	Duyarlılık	F1 Skoru
0	0,85	0,90	0,88
1	0,74	0,64	0,69

Tablo 4’te görüldüğü üzere kategorik değerlerin çıkarılmasıyla elde edilen veri seti ile yapılan uygulamada performans metriklerinde düşüş görülmüştür. Bu doğrultuda doğrudan kategorik verilerin

çıkarılmasından ziyade fazla sayıda öznelik barındıran veri setlerinde özellik çıkarımı algoritmaları kullanılarak boyut azaltma işlemi sürecin basitleştirilmesi adına katkı sağlayabilir.

Hastalık teşhisine yönelik uygulamalarda veri setinde yer alan dağılımlara bağlı olarak çeşitli performans kayıpları yaşanabilmektedir. Bu bağlamda özellikle nadir görülen hastalıkların teşhisinde frekansa dayalı tahmin yapan algoritmalar yanıltıcı sonuçlar verebilmektedir. Bu tür performans kayıplarının önüne geçmek amacıyla çeşitli yeniden örnekleme yöntemleri uygulanmaktadır. Bu durum doğrultusunda çalışma kapsamında veri dağılımındaki dengesizliklerin sonuca etkisinin incelenmesi amaçlanarak WEKA'da bulunan ve alt veri kümesini oluşturmaya yarayan Resample filtresi uygulanmıştır. Uygulanan filtre ile pozitif ve negatif kayıtların sayısı 177'ye eşit olup toplamda 354 kayıt bulunmaktadır. Dengeli veri setiyle yapılan uygulamada 0,74 doğruluk değeri elde edilmiştir. Diğer performans metrikleri Tablo 5'te verilmiştir.

Tablo 5. Performans Metrikleri (Resample Uygulanan Veri Seti)

	Kesinlik	Duyarlılık	F1 Skoru
0	0,80	0,70	0,75
1	0,70	0,80	0,75

Makine öğrenmesi algoritmaları sağlık bilişimi alanında tedavi planlaması, görüntü işleme, hasta takibi ve hastalık teşhisi gibi birçok amaçla kullanılmaktadır. Bu uygulamalarda kullanılan algoritmaların büyük miktarda verilerin işlenmesi ve analiz edilmesi için önem arz ettiği söylenebilir. Son yıllarda popüleritesi artan ve makine öğrenmesi yarışmalarında başarı gösteren XGBoost algoritması da bu uygulamalarda sıklıkla kullanılmaktadır. Örnek olarak Zamanında tedavi uygulanmadığı takdirde ölüme neden olma ihtimali yüksek olan akut lenfoblastik lösemi hastalığının teşhisi için oluşturulan XGBoost modeliyle 0,98 f1 skoru elde edilmiştir.²⁶ Başka bir çalışmada dünyada kadınları etkileyen hastalıkların

başında gösterilen göğüs kanserinin kanserinin teşhis edilmesi amaçlanarak XGBoost algoritması uygulanmıştır. Çalışma sonucunda 0,97 başarımla elde edilmiştir.²⁷ Bu çalışma kapsamında PKOS sendromunun teşhisi amaçlanarak elde edilen veri setine XGBoost algoritması uygulanarak 0,87 başarımla elde edilmiştir. Bu tür çalışmalardan hareketle hastalık teşhisine yönelik çalışmalarda XGBoost algoritmasının yüksek başarımla gösterdiği söylenebilir. Buna ek olarak XGBoost algoritmasının hızlı hesaplama süresi ve büyük veri setlerinde etkisi, bu çalışma kapsamında XGBoost algoritmasının seçilme nedeni olarak ortaya konulabilir.

Yukarıda bahsedilen çalışmalara ek olarak bu çalışmada elde edilen performans metrikleri doğrultusunda XGBoost algoritmasının sınıflandırma problemlerinde yüksek başarımla gösterdiği ve benzer çalışmalarda katkı sağlayacağı söylenebilir. Ancak bu yüksek başarımların klinik uygulamalarla doğrulanması gerekmektedir. Ayrıca XGBoost algoritmasıyla yapılan uygulamadan elde edilen genel performans veri setinin büyüklüğü ve çeşitliliğiyle sınırlı olabilir.

Bu çalışmanın sınırlamalarından biri de, kullanılan veri setinin sınırlı sayıda hasta verileri içermesi ve bu kayıtlarda yer alan eksiklerdir. Bu tür uygulamalarda eksik verilerin temizlenmesi veya tamamlanması amacıyla kullanılan yöntemlerin sonuçları etkileyebileceği göz ardı edilmemelidir. Ek olarak yapılan uygulamalarda PCOS'un farklı alt tiplerinin teşhisine yönelik bir ayırım yapılmadığı için bu alt tiplerin teşhisinde modelin performansını değerlendirmek de gelecekteki çalışmalar için önemlidir.

Çalışmada kullanılan veri seti, Kerala'da yer alan ve coğrafi olarak belirli bir bölgeden 10 farklı hastaneden elde edilmiş olup, farklı bölgelerde yer alan hasta kayıtlarından oluşan veri setleri üzerinde de test edilmesi gerekmektedir.

Bu çalışmadan farklı olarak PKOS sendromunun teşhis edilmesinin amaçlandığı bir çalışmada birden fazla makine öğrenmesi algoritması kullanılarak performansları

karşılaştırılmıştır. Çalışmada en yüksek doğruluk değerinin rastgele ormanlar algoritmasıyla yapılan uygulamada elde edildiği belirtilmiştir. ²⁸Bu tür çalışmalarda birden fazla algoritmanın kullanılmasının sonuca katkı sağlayacağı belirtilebilir. Ancak birden fazla algoritmanın kullanıldığı çalışmalarda performansların karşılaştırılmasıyla beraber algoritmaların birlikte kullanımı önerilmektedir. Her bir algoritmadan elde edilen sonuç değerinin nihai sonuca katkı sağlaması amaçlanarak oylama yöntemleriyle birleştirilmesi performans açısından katkı sağlayacaktır.

Bu çalışma kapsamında Kaggle veri tabanından elde edilen veri seti kullanılarak PCOS teşhisinde XGBoost algoritmasının uygulanabilirliğinin incelenmesi amaçlanmaktadır. Bu çalışmada her ne kadar somut veriler kullanılsa da PKOS teşhisine yönelik daha kapsamlı veri setlerine ihtiyacın hâsıl olduğu söylenebilir. Ayrıca doküman

temelli araştırma ve uzman görüşüne bağlı olarak PCOS teşhisine yönelik kriterlerin indirgenmesi ve özellik çıkarım algoritmalarının kullanımı sürecin hızlı bir şekilde yürütülmesi adına katkı sağlayacaktır. Ek olarak daha kapsamlı veri setleriyle birlikte gerçek hastalara ait verilerle test grupları oluşturularak yapılan tahminlerle hastalık teşhisine yönelik uygulamaların güvenilirliğine katkı sağlanacağı söylenebilir.

Sonuç olarak, XGBoost'un PCOS teşhisinde etkin bir araç olabileceği sonucuna varılmakla birlikte, daha geniş ve çeşitli veri setleriyle yapılan çalışmaların, klinik doğrulamalarla desteklenmesinin ve oluşturulan modelin farklı alt tipleri ayırt edebilme kapasitesinin incelenmesinin gerekli olduğu vurgulanmalıdır. Bu tür gelişmiş yaklaşımlar, PCOS teşhisinde daha hızlı ve doğru sonuçlar elde edilmesine katkı sağlayabilir.

SONUÇ VE ÖNERİLER

Bu çalışma kapsamında birçok değişkenden etkilenen ve teşhisi için daha fazla araştırmaya ihtiyaç duyulduğu belirtilen PKOS'un teşhis edilmesi amaçlanarak Kerala (Hindistan)'da yer alan 10 farklı hastaneden elde edilen ve 544 kayıttan oluşan veri setine XGBoost algoritması uygulanmış ve 0,97 doğruluk değeri elde edilmiştir. Sonrasında veri seti üzerinde çeşitli revizyonlar yapılarak farklı setleri üzerinde performans metrikleri karşılaştırılmıştır. XGBoost gibi makine öğrenmesi algoritmalarının sağlık alanında bu tür sınıflandırma problemlerinin çözümünde kullanılması, hastalıkların erken

teşhis edilmesini sağlayarak tedavi sürecini iyileştirebilir ve hastalıkla mücadelede önemli bir rol oynayabilir. Ancak, hastalık teşhisi için kullanılan makine öğrenmesi algoritmalarının performansı, veri setinin kalitesi, özellik seçimi yöntemleri ve kullanılan algoritmanın doğruluğu gibi faktörlere bağlıdır. Bu nedenle, hastalık teşhisi için makine öğrenmesi algoritmalarının kullanılması, dikkatli bir şekilde planlanmalı ve doğru veri analizi yöntemleriyle desteklenmelidir.

KAYNAKLAR

1. Russell, S.J. ve Norvig P. (2016). "Artificial intelligence: a modern approach". Malaysia: Pearson Education Limited.
2. Muggleton S. (2014). "Alan Turing and the development of Artificial Intelligence". AI communications, 27 (1), 3-10, 10.3233/AIC-130579
3. Machinery, C. (1950). "Computing machinery and intelligence-AM Turing". Mind, 59 (236), 433.
4. McCarthy J., Minsky M.L., Rochester N. ve Shannon C.E. (2006). "A proposal for the dartmouth summer research project on artificial intelligence". AI magazine, 27 (4), 12-12. <https://doi.org/10.1609/aimag.v27i4.1904>
5. Lewis, T. (2014). "A Brief History of Artificial Intelligence". Live Science. Erişim adresi: <https://www.livescience.com/49007-history-of-artificial-intelligence.html> (Erişim tarihi: 23.07.2023).
6. Öztürk K. ve Şahin M.E. (2018). "Yapay sinir ağları ve yapay zekâ'ya genel bir bakış". Takvim-i Vekayi, 6 (2), 25-36.
7. Rajeswari P., Sathishkumar V.E., Anilkumar C., Thilakaveni P. ve Moorthy U. (2023). "Big Data Analytics and Implementation Challenges of Machine Learning in Big data". Applied and Computational Engineering, p.233-238.

8. Pachamanova D., Tilson V. ve Dwyer-Matzky K. (2022). "Case article—Machine learning, ethics, and change management: A data-driven approach to improving hospital observation unit operations". *INFORMS Transactions on Education*, 22 (3). p.178-187. <https://doi.org/10.1287/ited.2021.0251ca>
9. Dewailly D. (2016) "Diagnostic criteria for PCOS: is there a need for a rethink?". *Best Practice & Research Clinical Obstetrics & Gynaecology*, 37, 5-11. <https://doi.org/10.1016/j.bpobgyn.2016.03.009>
10. Michelmores K.F., Balen A.H., Dunger D.B. ve Vessey M.P. (1999). "Polycystic ovaries and associated clinical and biochemical features in young women". *Clinical endocrinology*, 51 (6), 779-786. <https://doi.org/10.1046/j.1365-2265.1999.00886.x>
11. Ethirajulu A., Alkasabera A., Onyali C.B., Anim-Koranteng C., Shah H.E., Bhawnani N. ve Mostafa J.A. (2021). "Insulin resistance, hyperandrogenism, and its associated symptoms are the precipitating factors for depression in women with polycystic ovarian syndrome". *Cureus*, 13 (9). 10,7759/cureus.18013
12. Aydos, A., Öztumur, Y. ve Dedeoğlu, B. G. (2016). "Polikistik over sendromu ve moleküler yaklaşımlar". *Türk Hijyen ve Deneysel Biyoloji Dergisi*, 73(1), 81-88.
13. Jedel E., Gustafson D., Waern M., Sverrisdottir Y.B., Landen M., Janson P.O., Labrie F., Ohlsson C. ve Stener-Victorin E. (2011). "Sex steroids, insulin sensitivity and sympathetic nerve activity in relation to affective symptoms in women with polycystic ovary syndrome". *Psychoneuroendocrinology*, 36 (10):1470-9. <https://doi.org/10.1016/j.psyneuen.2011.04.001>
14. Standeven L.R., Olson E., Leistikow N., Payne J.L., Osborne L.M. ve Hantsoo, L. (2021). "Polycystic ovary syndrome, affective symptoms, and neuroactive steroids: a focus on allopregnanolone". *Current psychiatry reports*, 23 (6), 36. <https://doi.org/10.1007/s11920-021-01244-w>
15. Kuntal C., Vyas J., Chaudhary A., Hemani S. ve Rajoria L. (2021). "A study of metabolic syndrome in women with polycystic ovary syndrome at tertiary care center". *International Journal of Reproduction, Contraception, Obstetrics and Gynecology*, 10 (6), 2427-2432.
16. Jiang V.S., Hawkins S.D. ve McMichael A. (2022). "Female pattern hair loss and polycystic ovarian syndrome: more than just hirsutism". *Current Opinion in Endocrinology & Diabetes and Obesity*, 29 (6), 535-540. <https://doi.org/10.1097/MED.0000000000000777>
17. Kałużna M., Nomejko A., Słowińska A., Wachowiak-Ochmańska K., Pikosz K., Ziemnicka K. ve Ruchała M. (2021). "Lower sexual satisfaction in women with polycystic ovary syndrome and metabolic syndrome". *Endocrine Connections*, 10 (9), 1035-1044. <https://doi.org/10.1530/EC-21-0257>
18. Sharma A. ve Verbeke W.J. (2020). "Improving diagnosis of depression with XGBOOST machine learning model and a large biomarkers Dutch dataset (n= 11,081)". *Frontiers in big Data*, 3, 15. <https://doi.org/10.3389/fdata.2020.00015>
19. Chen T. ve Guestrin C. (2016). "Xgboost: A scalable tree boosting system". In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 785-794. <https://doi.org/10.1145/2939672.2939785>
20. Dhaliwal S.S., Nahid A.A. ve Abbas R. (2018). "Effective intrusion detection system using XGBoost". *Information*, 9 (7), 149. <https://doi.org/10.3390/info9070149>.
21. Ning Y.L., Sun C., Xu X.H., Li L., Ke Y.J., Mai Y., ... Chen W.T. (2023). "Tendency of dynamic vasoactive and inotropic medications data as a robust predictor of mortality in patients with septic shock: An analysis of the MIMIC-IV database". *Frontiers in Cardiovascular Medicine*, 10, 1126888. <https://doi.org/10.3389/fcvm.2023.1126888>
22. Chen S., Zhou W., Tu J., Li J., Wang B., Mo X., Tian G., Lv K. ve Huang Z. (2012). "A novel XGBoost method to infer the primary lesion of 20 solid tumor types from Gene expression data". *Frontiers in genetics*, 12, 632761. <https://doi.org/10.3389/fgene.2021.632761>
23. Ogunleye A. ve Wang Q.G. (2019). "XGBoost model for chronic kidney disease diagnosis". *IEEE/ACM transactions on computational biology and bioinformatics*, 17 (6), 2131-2140, 10,1109/TCBB.2019.2911071
24. Sharma N. (2018). "XGBoost. The extreme gradient boosting for mining applications". Munich: GRIN Verlag.
25. Ramraj S., Uzir N., Sunil R. ve Banerjee S. (2016). "Experimenting XGBoost algorithm for prediction and classification of different datasets". *International Journal of Control Theory and Applications*, 9(40), 651-662.
26. Ramaneswaran S., Srinivasan K., Vincent, P.D.R ve Chang C.Y. (2021). "Hybrid inception v3 XGBoost model for acute lymphoblastic leukemia classification". *Computational and Mathematical Methods in Medicine*, 1-10, <https://doi.org/10.1155/2021/2577375>
27. Liew, X.Y., Hameed N. ve Clos J. (2021). "An investigation of XGBoost-based algorithm for breast cancer classification". *Machine Learning with Applications*, 6, 100154. <https://doi.org/10.1016/j.mlwa.2021.100154>
28. Denny A., Raj A., Ashok A., Ram C.M. ve George R. (2019) "i-hope: Detection and prediction system for polycystic ovary syndrome (pcos) using machine learning techniques". In *TENCON 2019-2019 IEEE Region 10 Conference (TENCON)*, 673-678. IEEE.