

Makine Öğrenmesi ve Derin Öğrenme Yöntemlerini Kullanarak Erken Aşama Diyabet Tanısı için Karar Destek Sisteminin Geliştirilmesi: Karşılaştırmalı Bir Analiz

¹Cağlar Gurkan, ²Sude Kozalioglu ve ^{3,4}Merih Palandoken

¹Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Bölümü, İzmir Katip Çelebi Üniversitesi, Türkiye
²Mühendislik ve Mimarlık Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Eskişehir Osmangazi Üniversitesi, Türkiye

³Mühendislik ve Mimarlık Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, İzmir Katip Çelebi Üniversitesi, Türkiye

⁴Yapay Zeka ve Veri Bilimi Araştırma Merkezi, İzmir Katip Çelebi Üniversitesi, Türkiye

Özet

Yaygın olarak görülen hastalıklardan biri olan diyabetin prevalansı her yıl artmaktadır. Diyabet hastalığı erken teşhis edilmezse kalp ve damar hastalıklarına, böbrek hastalığına, körlüğe, sinir hasarlarına, felce ve organ yetmezliklerine neden olabilir. Ayrıca bu diyabet hastaları için yapılacak sağlık harcamalarının da 2040 yılında 802 milyon dolar olacağı tahmin edilmektedir. Bu durumlar göz önünde bulundurulduğunda diyabet tanısı için yapılacak çalışmalar oldukça önemlidir. Bu çalışmada, diyabet tanısı için bir karar destek sistemi geliştirmek amacıyla karar ağaçları, k-en yakın komşu, lojistik regresyon, Naive Bayes, rastgele orman, destek vektör makineleri gibi makine öğrenmesi ve çok katmanlı algılayıcı (ÇKA), evrişimli sinir ağları (ESA), tekrarlayan sinir ağları (RNN) tasarımları olan Basit RNN, Uzun Kısa Dönem Bellek Ağları (LSTM), Geçitli Tekrarlayan Birim (GRU), İki Yönlü Uzun Kısa Dönem Bellek Ağları (BiLSTM), İki Yönlü Geçitli Tekrarlayan Birim (BiGRU), ESA ve RNN hibrit modelleri olan ESA+Simple RNN, ESA+LSTM, ESA+GRU, ESA+BiLSTM ve ESA+BiGRU gibi derin öğrenme yöntemleri kullanılmıştır. Makine öğrenmesi tabanlı sınıflandırıcılar içerisinde en yüksek sınıflandırma performansını %98.10 doğruluk oranı ve %98.00 F1- skoru ile DVM elde etmiştir. Derin öğrenme tabanlı sınıflandırıcılar içerisinde en yüksek sınıflandırma performansını %99.50 doğruluk oranı ve %99.30 F1- skoru ile ESA+BiGRU hibrit modeli elde etmiştir. Genel analizde ise, derin öğrenme tabanlı sınıflandırıcıların makine öğrenmesi tabanlı sınıflandırıcılara göre daha iyi performans göstermiştir. Ek olarak CNN ve RNN tasarımlarının hibrit modelleri, yalnız modellere göre daha iyi sınıflandırma performansına sahiptir.

Anahtar Kelimeler: Diyabet, karar destek sistemi, yapay zeka, makine öğrenmesi, derin öğrenme

Development of Decision Support System for Early Stage Diabetes Diagnosis Using Machine Learning and Deep Learning Methods: A Comprehensive Analysis

Abstract

Prevalence of the diabetes which is one of the common diseases is increasing every year. If diabetes is not diagnosed early, it can cause cardiovascular diseases, kidney disease, blindness, nerve damage,

* Sorumlu Yazar: Cağlar Gurkan Adres: Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Bölümü, İzmir Katip Çelebi Üniversitesi, 35620, İzmir, TÜRKİYE. E-mail adresi: caglar.gurkan@outlook.com, Telefon Numarası: +905379770342

stroke and organ failure. In addition, health expenditures to do for these diabetes patients are estimated to be 802 million dollars in 2040. Considering these situations, studies for the diagnosis of diabetes are quite important. In this study, machine learning including decision tree, k-nearest neighbors, logistic regression, Naive Bayes, random forest, support vector machines and deep learning methods including multilayer perceptron (MLP), convolutional neural network (CNN), recurrent neural network (RNN) designs namely Simple RNN, Long Short Term Memory (LSTM), Gated Recurrent Unit (GRU), Bidirectional Long Short Term Memory (BiLSTM), Bidirectional Gated Recurrent Unit (BiGRU), CNN and RNN hybrid models, namely CNN+Simple RNN, CNN+LSTM, CNN+GRU, CNN+BiLSTM and CNN+BiGRU are used with the aim of developing a decision support system for the diagnosis of diabetes. SVM has achieved the highest classification performance among machine learning based classifiers with an accuracy rate of 98.10% and an F1-score of 98.00%. CNN+BiGRU hybrid model has achieved the highest classification performance among deep learning based classifiers with an accuracy rate of 99.50% and an F1-score of 99.30%. In general analysis, deep learning based classifiers have performed better than machine learning based classifiers. In addition, hybrid models of CNN and RNN designs have better classification performance than lean models.

Key words: Diabetes, decision support system, artificial intelligence, machine learning, deep learning

1. Giriş

Kronik diyabet hastalığının prevalansı her geçen gün artmaktadır. Dünya Sağlık Örgütü (DSÖ) tarafından paylaşılan verilerine göre dünyadaki diyabetli hasta sayısı 1980 yılında 108 milyon iken bu rakam 2014 yılında 422 milyona kadar ulaşmıştır [1]. Uluslararası Diyabet Federasyonu tarafından yapılan tahmine göre ise, yaklaşık her iki diyabetli bireyden birine teşhis konulamamaktadır. Ek olarak bu federasyon tarafından yapılan bir başka tahmine göre, 2040 yılında dünyada 642 milyon diyabet hastasının olacağı ve bu hastalar için yapılacak sağlık harcamalarının 802 milyon dolar olacağı belirtilmiştir [2,3]. Bu durum DSÖ tarafından bu alanda yapılan çalışmaların sayısını artırmıştır. Bu bağlamda DSÖ tarafından 1965 yılından 1998 yılına kadar düzenli olarak diyabet tanı ve teşhisi için rehberler yayınlanmıştır [4].

Diyabet, pankreasın vücuttaki şeker miktarını stabil seviyede tutabileceği kadar insülin hormonunu üretememesi veya vücudun üretilen insülin hormonunu düzgün bir şekilde kullanması ile birlikte ortaya çıkan kronik bir hastalıktır. Kronik diyabet hastalığı her yaş grubunda görülebilen hastaların yaşam kalitesini olumsuz yönde etkilemesine ek olarak ciddi oranda ölümle de sonuçlanabilmektedir [5]. Diyabet beraberinde kalp ve damar hastalıklarını, böbrek hastalığını, körlüğü, sinir hasarlarını, felci ve organ yetmezliklerini meydana getirmektedir [6,7]. Sonuç olarak kronik diyabet hastalığının bireyler üzerindeki sağlık açısından olumsuz etkilerine ek olarak ekonomik etkileri de göz önünde bulundurulduğunda erken aşamada hastalık teşhisinin konulabilmesi önemli bir araştırma konusu haline gelmiştir. Erken aşamada diyabet teşhisi için kullanılabilecek teknolojilerden en önemlisi yapay zeka algoritmalarıdır.

Bu çalışmada, diyabet erken tanısı için karar destek sisteminin oluşturulması amacı ile yaş, cinsiyet, poliüri, polidipsi, ani kilo kaybı, halsizlik, polifaji, genital pamukçuk, görsel bulanıklık, kaşıntı, sinirlilik, geç iyileşme, kısmi parezi, kas sertliği, alopesi, obezite olmak üzere 16 adet bilgi içer

ve diyabetik olan veya diyabetik olmamasına rağmen semptomları olan 520 bireye ait bu bilgilerden oluşan bir veri seti çalışmaya dahil edilmiştir. Bu veri seti makine öğrenmesi ve derin öğrenme yöntemleri ile diyabet pozitif ve negatif sınıflandırmasının yapılmasında kullanılmıştır.

Çalışmanın geri kalan kısmı şu şekilde oluşturulmuştur; 2. bölümde literatürdeki çalışmalar özetlenmiştir, 3. bölümde kullanılan veri seti tanıtıldıktan sonra çalışmada kullanılan yöntemler aktarılmıştır, 4. Bölümde bu yöntemler ile elde edilen sonuçlar analiz edilmiş ve karşılaştırılmıştır, 5. bölümde ise çalışma ile ilgili son bilgiler aktarılmıştır.

2. İlgili Çalışmalar

Bu bölümde, önceki benzer çalışmalardan bazıları özetlenmiştir.

Joshi ve Chawan [8] tarafından yapılan araştırmada 7 farklı öznitelik içeren veri seti ile diyabet tanısı sınıflandırma işlemi gerçekleştirilmiştir. Bu çalışmada DVM, lojistik regresyon ve ÇKA kullanılmıştır. DVM en iyi sınıflandırma performansını göstermiştir. Sapon vd. [9] tarafından yapılan araştırmada 27 farklı öznitelik içeren, 250 hastaya ait bilgiler çalışmaya diyabet tanısı sınıflandırma işlemi için dahil edilmiştir. Bu çalışmada, Bayesian Regülasyon algoritması ile %88,8'lik bir sınıflandırma performansı elde edilmiştir. Ahmed [10] tarafından yapılan araştırmada 9 farklı öznitelik içeren, 318 hastaya ait bilgiler çalışmaya diyabet tanısı sınıflandırma işlemi için dahil edilmiştir. Bu çalışmada, J48 algoritması %70,8'lik bir sınıflandırma performansı elde etmiştir. Utku [11] tarafından yapılan araştırmada 8 farklı öznitelik içeren, 500 hastaya ait bilgiler çalışmaya diyabet tanısı sınıflandırma işlemi için dahil edilmiştir. Bu çalışmada farklı optimizasyon algoritmaları DVM algoritması ile birlikte kullanılmıştır. Guguk Kuşu Araması (GKA) optimizasyon algoritması DVM ile birlikte kullanılarak en iyi sınıflandırma performansı %94,27 olarak elde edilmiştir.

3. Yöntem

Çalışmada kullanılan yöntem iki alt başlıkta incelenmiş ve bu bölümde sunulmuştur.

3.1. Veri Seti ve Veri Ön İşleme

Çalışmada kullanılan veri seti, diyabetik olan veya diyabetik olmamasına rağmen semptomları olan bireyler ile yapılan anket sonuçlarını içermektedir. Bu anket çalışması Bangladeş Sylhet Sylhet Diyabet Hastanesinde 520 kişi ile yapılmıştır ve 16 adet semptomla verilen cevapları içermektedir. Çalışmada kullanılan veri setinde 520 bireye ait diyabet ile ilişkilendirilebilen 16 adet semptom içermektedir [6]. Açık kaynak olan bu veri seti, UCI Makine Öğrenmesi Deposu aracılığı ile paylaşılmıştır [12]. Veri seti yaş, cinsiyet, poliüri, polidipsi, ani kilo kaybı, halsizlik, polifaji, genital pamukçuk, görsel bulanıklık, kaşıntı, sinirlilik, geç iyileşme, kısmi parezi, kas sertliği, alopesi, obezite olmak üzere 16 adet öznitelikten oluşmaktadır. Yaş harici öznitelikler, semptom olduğu anlamına gelen evet yani 1 ve semptom olmadığı anlamına gelen hayır yani 0 bilgilerinden

oluşmaktadır. Yaş özneliği ise 20-35, 36-45, 46-55, 56-65 ve 65 üstü şeklinde beş kümeden oluşmaktadır. Sınıf bilgisi ise diyabet pozitif ve negatif olmak üzere iki etiketten oluşmaktadır. Veri ön işleme basamağında ise öncelikle veri setindeki öznelikler min-max özellik ölçeklendirme kullanılarak 0-1 aralığında sınıflandırıcı algoritmalara dahil edilmiştir. Sonrasında 520 örnekten oluşan bu veri setinin %80'i eğitim ve %20'si test olacak şekilde ayrılmıştır.

3.2. Kullanılan Sınıflandırıcılar

Kullanılan makine öğrenmesi yöntemleri karar ağaçları, k-en yakın komşu (KNN), lojistik regresyon, Naive Bayes (NB), rastgele orman ve destek vektör makineleri (DVM) iken derin öğrenme yöntemleri çok katmanlı algılayıcı (ÇKA), evrişimli sinir ağları (ESA), tekrarlayan sinir ağları (Recurrent Neural Network-RNN) tasarımları olan Simple RNN, Long Short-Term Memory Network (LSTM) olarak adlandırılan Uzun Kısa Dönem Bellek Ağları, Gated Recurrent Unit (GRU) olarak adlandırılan Geçitli Tekrarlayan Birim, Bidirectional Long Short Term Memory (BiLSTM) olarak adlandırılan İki Yönlü Uzun Kısa Dönem Bellek Ağları, Bidirectional Gated Recurrent Unit (BiGRU) olarak adlandırılan İki Yönlü Geçitli Tekrarlayan Birim, ESA ve RNN hibrit modelleri olan ESA+Simple RNN, ESA+LSTM, ESA+GRU, ESA+BiLSTM ve ESA+BiGRU şeklindedir.

Oluşturulan ÇKA model giriş ve çıkış katmanlarına ek olarak 4 adet gizli katmandan oluşmaktadır. Toplam 6 katmanlı mimari tasarım için; giriş katmanında öznelik sayısı olan 16 adet nöron kullanılırken çıkış katmanında sınıf sayısı olan 2 adet nöron kullanılmıştır. Ayrıca ilk gizli katmanda 64 adet nöron kullanılırken, diğer 3 gizli katmanda sırası ile 32, 16 ve 8 nöron kullanılmıştır. 4 gizli katman için aktivasyon fonksiyonu 'ReLU' olup çıkış katmanı aktivasyon fonksiyonu 'softmax'dir. Ayrıca her bir gizli katman arasında 0.3 eşik değeri ile seyreltme katmanı kullanılmıştır.

Oluşturulan ESA mimarisi özellik çıkarımı için üç konvolüsyon katmanı ve bu konvolüsyon katmanları arasında kullanılan iki maksimum havuzlama katmanını içermektedir. Sınıflandırma işlemi için ise öncelikle düzleştirme katmanı sonrasında üç adet tam bağlantı katmanı ve bu bağlantı katmanları arasında iki adet seyreltme katmanı kullanılmıştır. Konvolüsyon katmanları sırası ile 32, 64 ve 128 adet filtreden oluşurken, üç konvolüsyon katmanında da filtre boyutu 3x3, adım sayısı 1, dolgu aynı ve aktivasyon fonksiyonu ReLU olarak kullanılmıştır. Maksimum havuzlama katmanlarında havuzlama boyutu 2x2, adım sayısı 2 ve dolgu uygun olarak kullanılmıştır. Tam bağlantı katmanlarındaki nöron sayısı sırası ile 512, 256 ve sınıf sayısı olan 2'ye eşittir ve bu katmanlar için aktivasyon fonksiyonları sırası ile ReLU, ReLU ve softmax olarak kullanılmıştır. Ayrıca tam bağlantı katmanları arasında kullanılan seyreltme katmanlarının eşik değeri 0.3'e eşittir.

Oluşturulan Simple RNN, LSTM, GRU, BiLSTM ve BiGRU mimari tasarımları için sırası ile üç adet Simple RNN, LSTM, GRU, BiLSTM ve BiGRU katmanı kullanılmıştır. Bu katmanların ardından ise tahmin işleminin gerçekleştirilmesi amacı ile sınıf sayısı olan 2 kadar nöron bulunan yoğun katman kullanılmıştır. Simple RNN, LSTM, GRU, BiLSTM ve BiGRU mimari

tasarımlarının objektif olarak karşılaştırılması için Simple RNN, LSTM, GRU, BiLSTM ve BiGRU katmanlarındaki birim sayısı sırası ile 128, 64 ve 32'dir.

Oluşturulan ESA+Simple RNN, ESA+LSTM, ESA+GRU, ESA+BiLSTM ve ESA+BiGRU hibrit modellerinin, yalın modellerle objektif olarak karşılaştırılabilmesi için yalın modellerdeki katman sayıları ve bu katmanların hiperparametreleri değiştirilmeden hibrit modellerde de kullanılmıştır. Bu beş adet hibrit modele ait katman hiperparametreleri ve sayıları ise aşağıda açıklanmıştır;

a) Özellik çıkarımı için üç konvolüsyon katmanı ve bu konvolüsyon katmanları arasında iki maksimum havuzlama katmanı kullanılmıştır. Konvolüsyon katmanları sırası ile 32, 64 ve 128 adet filtreden oluşurken, üç konvolüsyon katmanında da filtre boyutu 3x3, adım sayısı 1, dolgu aynı ve aktivasyon fonksiyonu ReLu olarak kullanılmıştır. Maksimum havuzlama katmanlarında havuzlama boyutu 2x2, adım sayısı 2 ve dolgu uygun olarak kullanılmıştır.

b) Sınıflandırma işlemi için Simple RNN, LSTM, GRU, BiLSTM ve BiGRU mimari tasarımları için sırası ile üç adet Simple RNN, LSTM, GRU, BiLSTM ve BiGRU katmanı kullanılmıştır. Kullanılan Simple RNN, LSTM, GRU, BiLSTM ve BiGRU katmanlarındaki birim sayısı sırası ile 128, 64 ve 32'dir. Bu katmanların ardından ise tahmin işleminin gerçekleştirmesi amacı ile sınıf sayısı olan 2 kadar nöron bulunan yoğun katman kullanılmıştır.

Derin öğrenme tabanlı sınıflandırıcıların eğitiminde optimizasyon fonksiyonu olarak Adam, kayıp fonksiyonu olarak seyrek kategorik çapraz entropi kullanılmıştır. Öğrenme oranı ise 1e-3 olarak kullanılırken tüm sınıflandırıcılar 64 küme boyutu ile 100 epok boyunca eğitilmiştir. Derin öğrenme modelleri Keras kütüphanesi kullanılmıştır. Makine öğrenmesi tabanlı sınıflandırıcıların hiperparametre optimizasyonu için GridSearchCV kullanılmıştır. Bu sınıflandırıcılar scikit-learn kütüphanesi kullanılarak geliştirilmiştir. Tüm sınıflandırıcı algoritmalar Python programlama dilinde Spyder entegre geliştirme ortamında oluşturulmuştur. Kullanılan donanım ise NVIDIA GTX 950M'dir.

Bu çalışmada kullanılan makine öğrenmesi ve derin öğrenme tabanlı sınıflandırıcıların performansları, doğruluk oranı ve F1-skoru değerlerine göre karşılaştırılmış ve bölüm 4'te gösterilmiştir.

4. Deneysel Analiz ve Tartışma

Kullanılan sınıflandırıcılar ile elde edilen sonuçlar ve karşılaştırmalı analizler bu bölümde iki alt başlık ile sistematize edilmiştir.

4.1. Makine Öğrenmesi Tabanlı Sınıflandırıcılar ile Elde Edilen Sonuçlar

Çalışmada makine öğrenmesi tabanlı sınıflandırıcılar olan karar ağaçları, KNN, lojistik regresyon, NB, rastgele orman ve DVM kullanılmıştır. Bu sınıflandırıcılar ile elde edilen doğruluk oranı ve F1-skoru değerleri Tablo 1'de gösterilmiştir. Performans analizi yapılırken de bu iki değer göz

önünde bulundurulmuştur. Doğruluk oranı ile F1-skoru değerlerinin birbirleriyle tutarlı olduğu da Tablo 1’de gözlemlenebilmektedir.

Karar ağaçları, KNN, lojistik regresyon, NB, rastgele orman ve DVM sınıflandırıcıları ile elde edilen doğruluk oranları sırası ile %93.30, %98.00, %95.20, %93.30, %97.10 ve %98.10 iken F1-skorumları sırası ile %92.90, %97.90, %94.90, %92.70, %96.90 ve %98.00’dır. Makine öğrenmesi tabanlı sınıflandırıcılar ile elde edilen sonuçlar göz önünde bulundurulduğunda, en yüksek sınıflandırma performansını %98.10 doğruluk oranı ve %98.00 F1- skoru ile DVM elde etmiştir. İkinci en yüksek sınıflandırma performansını %98.00 doğruluk oranı ve %97.90 F1- skoru ile KNN elde etmiştir. Üçüncü en yüksek sınıflandırma performansını %97.10 doğruluk oranı ve %96.90 F1- skoru ile rastgele orman elde etmiştir. Fakat KNN sınıflandırıcısı ile elde edilen doğruluk oranı, komşu sayısı parametresi ile birlikte değişkenlik göstermektedir. Sonuç olarak KNN sınıflandırıcısı ile daha yüksek doğruluk oranı elde edilebilir.

Tablo 1. Makine öğrenmesi tabanlı sınıflandırıcılar ile elde edilen doğruluk oranı ve F1-skoru değerleri

Kullanılan Sınıflandırıcı	Doğruluk Oranı	F1-skoru
Karar Ağaçları	0.933	0.929
KNN	0.980	0.979
Lojistik Regresyon	0.952	0.949
NB	0.933	0.927
Rastgele Orman	<u>0.971</u>	<u>0.969</u>
DVM	0.981	0.980

Not: Birinci, ikinci ve üçüncü en yüksek başarımları gösteren sınıflandırıcı algoritmaların elde ettiği sonuçlar sırası ile kalın-altı çizili, kalın ve altı çizili olarak gösterilmiştir.

4.2. Derin Öğrenme Tabanlı Sınıflandırıcılar ile Elde Edilen Sonuçlar

Çalışmada derin öğrenme tabanlı sınıflandırıcılar olan ÇKA, ESA, Simple RNN, LSTM, GRU, BiLSTM, BiGRU, ESA+Simple RNN, ESA+LSTM, ESA+GRU, ESA+BiLSTM ve ESA+BiGRU kullanılmıştır. Bu sınıflandırıcılar ile elde edilen doğruluk oranı ve F1-skoru değerleri Tablo 2’de gösterilmiştir. Performans analizi yapılırken de bu iki değer göz önünde bulundurulmuştur. Doğruluk oranı ile F1-skoru değerlerinin birbirleriyle tutarlı olduğu da Tablo 2’de gözlemlenebilmektedir.

ÇKA, ESA, Simple RNN, LSTM, GRU, BiLSTM, BiGRU, ESA+Simple RNN, ESA+LSTM, ESA+GRU, ESA+BiLSTM ve ESA+BiGRU sınıflandırıcıları ile elde edilen doğruluk oranları sırası ile %99.00, %98.10, %98.90, %87.50, %89.40, %91.30, %98.10, %99.30, %98.20, %99.10, %98.30 ve %99.50 iken F1-skorumları sırası ile %99.00, %98.00, %98.60, %87.20, %89.10, %91.00, %98.00, %99.10, %98.00, %99.00, %98.10 ve %99.30’dur. Derin öğrenme tabanlı sınıflandırıcılar ile elde edilen sonuçlar göz önünde bulundurulduğunda, en yüksek sınıflandırma performansı %99.50 doğruluk oranı ve %99.30 F1- skoru ile ESA+BiGRU hibrit modeli ile elde edilmiştir. İkinci en yüksek sınıflandırma performansı %99.30 doğruluk oranı ve %99.10 F1- skoru ile ESA+Simple RNN hibrit modeli ile elde edilmiştir. Üçüncü en yüksek sınıflandırma performansı %99.10 doğruluk oranı ve %99.00 F1- skoru ile ESA+GRU hibrit modeli ile elde edilmiştir. Elde

edilen bu sonuçlar incelendiğinde ESA+RNN hibrit modelleri, ESA ve RNN yalın modellerine göre daha iyi performans göstermiştir. ÇKA modelin ise daha hızlı sonuç vermesi ve en yüksek dördüncü sınıflandırma performansını göstermesi nedeni ile kullanılabilirliği yüksektir.

Tablo 2. Derin öğrenme tabanlı sınıflandırıcılar ile elde edilen doğruluk oranı ve F1-skoru değerleri

Kullanılan Sınıflandırıcı	Doğruluk Oranı	F1-skoru
ÇKA	0.990	0.990
ESA	0.981	0.980
Simple RNN	0.989	0.986
LSTM	0.875	0.872
GRU	0.894	0.891
BiLSTM	0.913	0.910
BiGRU	0.981	0.980
ESA+Simple RNN	0.993	0.991
ESA+LSTM	0.982	0.980
ESA+GRU	<u>0.991</u>	<u>0.990</u>
ESA+BiLSTM	0.983	0.981
ESA+BiGRU	0.995	0.993

Not: Birinci, ikinci ve üçüncü en yüksek başarımları gösteren sınıflandırıcı algoritmaların elde ettiği sonuçlar sırası ile kalın-altı çizili, kalın ve altı çizili olarak gösterilmiştir.

Makine öğrenmesi ve derin öğrenme tabanlı sınıflandırıcılar ile elde edilen sonuçlar birlikte göz önünde bulundurulduğunda en iyi altı sınıflandırma performansını sırası ile %99.50 doğruluk oranı ve %99.30 F1- skoru ile ESA+BiGRU hibrit modeli, %99.30 doğruluk oranı ve %99.10 F1- skoru ile ESA+Simple RNN hibrit modeli, %99.10 doğruluk oranı ve %99.00 F1- skoru ile ESA+GRU hibrit modeli, %98.10 doğruluk oranı ve %98.00 F1- skoru ile DVM, %98.00 doğruluk oranı ve %97.90 F1- skoru ile KNN, %97.10 doğruluk oranı ve %96.90 F1- skoru ile rastgele orman elde etmiştir. Bu bağlamda derin öğrenme tabanlı sınıflandırıcılar, makine öğrenmesi tabanlı sınıflandırıcılara göre daha iyi tahmin performansı göstermiştir.

5. Sonuç

Diyabet erken tanı sisteminin geliştirilmesi amacı ile bu çalışmada makine öğrenmesi ve derin öğrenme teknolojileri kullanılmıştır. Bu erken tanı sistemi için kullanılan veri setinde yaş, cinsiyet, poliüri, polidipsi, ani kilo kaybı, halsizlik, polifaji, genital pamukçuk, görsel bulanıklık, kaşıntı, sinirlilik, geç iyileşme, kısmi parezi, kas sertliği, alopesi, obezite olmak üzere 16 adet özneliği içeren ve diyabetik olan veya diyabetik olmamasına rağmen semptomları olan 520 bireyin bilgileri bulunmaktadır. Kullanılan makine öğrenmesi yöntemleri karar ağaçları, KNN, lojistik regresyon, NB, rastgele orman ve DVM iken derin öğrenme yöntemleri ÇKA, ESA, Simple RNN, LSTM, GRU, BiLSTM, BiGRU'ya ek olarak ESA+Simple RNN, ESA+LSTM, ESA+GRU, ESA+BiLSTM ve ESA+BiGRU hibrit modelleridir. Kullanılan tüm yöntemler arasında en iyi sınıflandırma performansını %99.50 doğruluk oranı ve %99.30 F1- skoru ile ESA+BiGRU hibrit modeli elde etmiştir. Elde edilen iyi sonuçların gelecekte yapılacak diğer araştırmalarla desteklenmesi ile birlikte diyabet erken tanısı için yardımcı bir aracın geliştirilmesi mümkündür. Böylelikle sağlık çalışanlarının iş yükü azaltılırken insan faktöründen kaynaklanan hatalar da

minimumuna indirilebilecektir. Buna ek olarak diyabet erken tanısı sayesinde, diyabetin insan hayatı üzerindeki etkileri kontrol altına alınabilecek, diyabet tanı ve tedavisi için yapılan sağlık harcamaları da optimum seviyede tutulabilecektir.

Teşekkür

M. Islam, Rahatara Ferdousi, S. Rahman, Humayra Yasmin Bushra'ya oluşturdukları veri setini halka açık olarak paylaştıklarından dolayı bilime yapmış oldukları katkı için teşekkür ederiz.

Referanslar

- [1] Diabetes. Accessed July 29, 2021. <https://www.who.int/news-room/fact-sheets/detail/diabetes>
- [2] Ogurtsova K, da Rocha Fernandes JD, Huang Y, et al. IDF Diabetes Atlas: Global estimates for the prevalence of diabetes for 2015 and 2040. *Diabetes Res Clin Pract.* 2017;128:40-50. doi:10.1016/j.diabres.2017.03.024
- [3] Han Cho N. *IDF Diabetes Atlas 2019.*; 2019.
- [4] Deperlioğlu Ö, Köse U. Diagnosis of Diabete mellitus Using Deep Neural Network. In: *2018 Medical Technologies National Congress, TIPTEKNO 2018.* Institute of Electrical and Electronics Engineers Inc.; 2018. doi:10.1109/TIPTEKNO.2018.8596975
- [5] Punthakee Z, Goldenberg R, Katz P. Definition, Classification and Diagnosis of Diabetes, Prediabetes and Metabolic Syndrome. *Can J Diabetes.* 2018;42:S10-S15. doi:10.1016/j.jcjd.2017.10.003
- [6] Islam MMF, Ferdousi R, Rahman S, Bushra HY. Likelihood Prediction of Diabetes at Early Stage Using Data Mining Techniques. In: *Advances in Intelligent Systems and Computing.* Vol 992. Springer, Singapore; 2020:113-125. doi:10.1007/978-981-13-8798-2_12
- [7] Harris MI, Klein R, Welborn TA, Knudman MW. Onset of NIDDM occurs at least 4-7 yr before clinical diagnosis. *Diabetes Care.* 1992;15(7):815-819. doi:10.2337/diacare.15.7.815
- [8] Joshi TN, Chawan PM. Diabetes Prediction Using Machine Learning Techniques. *Ijera.* 2018;8(1):9-13. doi:10.9790/9622-0801020913
- [9] Sapon MA, Suehazlyn Z, Ismail K, Zainudin S. Prediction of Diabetes by using Artificial Neural Network. In: *In Proceedings of the 2011 International Conference on Circuits, System and Simulation, Singapore.* ; 2011:299-303.

- [10] Ahmed TM. Developing a predicted model for diabetes type 2 treatment plans by using data mining. *J Theor Appl Inf Technol.* 2016;90(2):181-187.
- [11] Köse U. Zeki Optimizasyon Tabanlı Destek Vektör Makineleri ile Diyabet Teşhisi. *J Polytech.* 2018;22(3):557-566. doi:10.2339/politeknik.418851
- [12] Dua D, Graff C. UCI Machine Learning Repository [<http://archive.ics.uci.edu/ml>]. Irvine, CA: University of California, School of Information and Computer Science. 2019