



Yapay Zeka Tabanlı Akıllı Telefon Uygulaması ile Kan Şekeri Tahmini

Volkan Kılıç*

İzmir Katip Çelebi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, İzmir, Türkiye (ORCID: 0000-0002-3164-1981),
volkan.kilic@ikcu.edu.tr

(3rd International Congress on Human-Computer Interaction, Optimization and Robotic Applications June 11-13, 2021)

(DOI: 10.31590/ejosat.950914)

ATIF/REFERENCE: Kılıç, V. (2021). Yapay Zeka Tabanlı Akıllı Telefon Uygulaması ile Kan Şekeri Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (26), 289-294.

Öz

Diyabet, insan vücudunda birçok hastalığı tetikleyen kronik bir hastalıktır. İnsan vücudunu olumsuz etkileyen diyabet için kritik şeker seviyeleri, hiperglisemi (yüksek kan şekeri) ve hipoglisemi (düşük kan şekeri) olarak adlandırılır. Kan şekerinin bu seviyelerin üstünde veya altında olması insan vücudunda çeşitli tahribatlara neden olmaktadır. Mevcut sistemler, kan şekerini sürekli ölçerek takip yapmakta olup, kritik seviyeler geçildikten sonra kullanıcıya uyarı vermektedir. Kullanıcının uyarının farketmesi, gerekli ilaç ve/veya tedbirleri almasına takiben kan şekeri istenilen seviyeye indirilebilmektedir. Bu durum, hasta vücudunun belirli bir süre kritik seviyelerde çalışmasına neden olmaktadır. Bu sorunun önüne geçebilmek için, kan şekerinin zaman içindeki değişiminden bir sonraki kan şekerinin değerini tahmin edebilecek ve böylelikle, kritik seviyelerine ulaşmadan hastayı uyarabilecek bir sistem geliştirilmiştir. Önerilen sistem, uzun-kısa süreli bellek (Long Short Term Memory-LSTM) tabanlı tekrarlayan sinir ağı (Recurrent Neural Network-RNN) ile zamanla değişen kan şekeri değerlerinden bir sonraki değeri tahmin edebilmektedir. Diyabet hastalarından elde edilen gerçek veriler ile eğitilen sistem, %95.6 doğruluğa karşılık gelen 3.72 mg/dl'den daha düşük bir hata ile kan şekerini tahmin edebilmiştir. Önerilen sistem, ayrıca, kendi geliştirdiğimiz *BffDiabetes* adlı Android uygulamamızla birleştirilmiştir. Uygulama, ölçülen kan şekeri değerini bir bulut sistemi üzerinden bir sonraki şeker seviyesini tahmin etmek için sunucuya gönderir. Sunucuda koşturulan LSTM tabanlı tahmin algoritmamız gelen değere bağlı olarak gelecek üç zaman adımı için şeker değerlerini hesaplar. Tahmin sonuçları, kan şekeri seviyesinin kritik aşamalara ulaşma eğiliminde olup olmadığını değerlendirmek için bulut sistemi üzerinden tekrar Android uygulamasına gönderilir. Bu eğilim tespit edilirse, uygulama hastayı gerekli önlemler için bir bildirimle uyarır. Böylelikle, kan şekerini ölçerek kablosuz (Bluetooth) aktarım yapan cihazlarla çalışabilecek bir platform diyabet hastalarının kullanımına sunulmaktadır günlük hayat kalitelerinin artırılması amaçlanmıştır.

Anahtar Kelimeler: Yapay Zeka, Tekrarlayan Sinir Ağı, LSTM, Akıllı Telefon, Android.

Artificial Intelligence based Blood Sugar Prediction with Smartphone Application

Abstract

Diabetes is a chronic disease that triggers many diseases in the human body. Critical sugar levels for diabetes, which negatively affects the human body, are referred to as hyperglycemia (high blood sugar) and hypoglycemia (low blood sugar). Blood sugar being above or below these levels causes various damages in the human body. Existing systems monitor blood sugar continuously, and alert the user after critical levels are passed. After the user notices the warning and takes the necessary medication and/or precautions, the blood sugar can be reduced to the desired level. This situation causes the patient's body to work at critical levels for a certain period of time. In order to avoid this problem, a system has been developed that can predict the value of the next blood sugar from the change in

* Sorumlu Yazar: volkan.kilic@ikcu.edu.tr

blood sugar over time and thus alert the patient before reaching critical levels. The proposed system can predict the next value from the time-varying blood sugar values with the Long Short Term Memory (LSTM) based recurrent neural network (RNN). Trained with real data from diabetes patients, the system was able to predict blood sugar with an error of less than 3.72 mg/dl, corresponding to 95.6% accuracy. The proposed system is also combined with our custom-designed Android application called *BffDiabetes*. The application sends the measured blood sugar value via a cloud system to the server to predict the next sugar level. Our LSTM-based prediction algorithm run on the server calculates sugar values for the next three time steps based on the incoming value. The prediction results are sent back to the Android app via the cloud system to assess whether the blood sugar level tends to reach critical stages. If this trend is detected, the application alerts the patient with a notification for necessary precautions. In this way, it is aimed to increase the quality of daily life by offering a platform that can work with devices that make wireless (Bluetooth) transmission by measuring blood sugar.

Keywords: Artificial Intelligence, Recurrent Neural Network, LSTM, Smartphone, Android.

1. Giriş

Diyabet, pankreas bezinin yeterli insülin hormonu üretmemesi veya ürettiği insülin hormonunun etkin bir şekilde kullanılamaması durumunda ortaya çıkmaktadır. Bu durumda, besinlerden kan dolaşımına geçen şekerin seviyesi düzenlenememektedir (Association, 2014). Kan şekeri seviyesinin normal değerlerde tutulmaması, hastanın kalp, kan damarları, beyin ve böbrek gibi birçok organında hasara yol açmaktadır (Mercan, 2020; Mercan, Doğan, & Kılıç, 2020; Mercan & Kılıç, 2020).

Diyabet hastalarının yaşadığı sorunları en az indirmek ve yaşam konforunu artırmak için bir çok yardımcı araç geliştirilmiştir (Kap, Kilic, Hardy, & Horzum, 2021; Mercan, Kılıç, & Şen, 2021). Şeker ölçümlerinin daha iyi örneklenmesini sağlayan sürekli glikoz izleme (Continuous Glucose Monitoring-CGM) cihazları 5 dakikada bir kan şekeri seviyesini ölçerek mevcut tedavinin değerlendirmesine olanak sağlamaktadır (Strollo et al., 2021). Genel kullanımı sadece mevcut şeker seviyesi hakkında bilgi vermek olan bu cihazlar kullanıcıların taleplerini karşılamakta yetersiz kalmaktadır. Özellikle akıllı telefon teknolojilerindeki son gelişmeler daha yetenekli platformların geliştirilmesini sağlamıştır. Kan şekeri değerinin akıllı telefon ekranında görüntülenmenin ötesinde yapay zeka yaklaşımlarıyla bir sonraki değer tahmini yapan uygulamalar oldukça talep görmektedir. Kan şekeri değerlerini tahmin etmeye dayalı birçok çalışma yapılmıştır (Bunescu, Struble, Marling, Shubrook, & Schwartz, 2013; Daskalaki, Prountzou, Diem, & Mougiakakou, 2012; Midroni et al., 2018; Mutlu & Kılıç, 2018; Pala & Yücedağ, 2016; Pérez-Gandía et al., 2010; Song, Cai, Li, Jiang, & He, 2019; Sun, Jankovic, Bally, & Mougiakakou, 2018; Wiley, 2011; Xie & Wang, 2018; Yahyaoui, Jamil, Rasheed, & Yesiltepe, 2019). Bir çalışmada, 30 ila 60 dakikalık kan şekerini tahmin etmek için klasik bir istatistiksel yöntem olan otoregresif entegre hareketli ortalama (Autoregressive Integrated Moving Average) model tabanlı algoritma geliştirilmiştir (Song et al., 2019). Başka bir çalışmada, diyabet hastalarının kan şekeri tahminlerinin genelleştirilebilir özelliklerine sahip olduğu ancak başarı oranının yeterince yüksek olmadığı, hastaya özel tahminlerde başarı oranının daha yüksek olduğu rapor edilmiştir (Yahyaoui et al., 2019). Diğer bir çalışmada, kan şekeri tahmini için makine öğrenme yöntemleri ile hem glikoz hem de insülin bilgisini besleyen gerçek zamanlı öğrenen tekrarlayan sinir ağı (Recurrent Neural Network-RNN) kullanılmıştır. Model, hem glikoz bilgisi hem de harici insülin girdisi olan bir otoregresif (Autoregressive-AR) modelini makine öğrenmesi yöntemleriyle birleştirerek klasik bir otoregresif modelden daha iyi performans göstermiştir (Daskalaki et al., 2012).

1990 yılında tedavi sürecinde hekimlere yardımcı olacak bir diyabet tahmin modeli geliştirilmesi amacıyla Ulusal Diyabet ve Sindirim ve Böbrek Hastalıkları Enstitüsü (National Institute of

Diabetes and Digestive and Kidney Diseases) tarafından, 768 T2D hastasından önemli bilgiler içeren veri seti oluşturulmuştur. Çalışmada C 5.0 karar ağacı algoritması uygulanarak 27 kural çıkarılmıştır (Pala & Yücedağ, 2016). Başka bir çalışmada, CGM verilerinden kan şekeri seviyelerini tahmin etmek için destek vektör regresyonu (Support Vector Regression-SVR) kullanılmıştır. Ancak çalışmada, düzenli bir kübik spline interpolasyonu kullanılarak düzeltilmiş veriler kullanılmıştır (Wiley, 2011). Kişiselleştirilmiş bir glikoz tahmini sağlamak için yemek, insülin ve egzersiz modellerini SVR yöntemini ile birleştiren başka bir çalışma önerilmiştir. Bu çalışmada derin öğrenme yöntemlerinin son zamanlarda oluşturulan yöntemlerden daha iyi performans verdiği gösterilmiştir (Bunescu et al., 2013). 2018 yılında yapılan araştırmaya göre kan şekeri değerlerinin tahmininde uzun kısa süreli bellek (Long Short Term Memory-LSTM) ve iki yönlü uzun kısa süreli bellek (Bidirectional Long Short Term Memory) yöntemleri kullanılarak derin sinir ağı (Deep Neural Network) ile sonuçlar alınmıştır (Sun et al., 2018). CGM ile elde edilen verileri girdi olarak alan ve 15, 30 ve 45 dakika seviyelerini geleceğe tahmin eden ileri beslemeli bir sinir ağı (Feedforward Neural Network-FNN) kullanılmıştır (Pérez-Gandía et al., 2010). Aşırı gradyan artırma (Extreme Gradient Boosting-XGBoost) özelliğini tahmin etme yöntemlerinin geliştirilmesinde kullanılmıştır (Midroni et al., 2018). Otoregresyon eksojen (AutoRegressive Exogenous-ARX) girdiler, RNN'ler ve evrişimli sinir ağları (Convolutional Neural Network) ile karşılaştırılmış ve daha basit ARX modellerinin Ohio kan şekeri tahmini yapılmıştır (Xie & Wang, 2018). Bu makalede, yapay zeka tabanlı akıllı telefon uygulaması ile diyabet hastaları için zamanla değişen kan şekeri değerlerini tahmin etmeye dayalı yöntem önerilmiş ve önerilen yöntem kendi tasarımı olan *BffDiabetes* akıllı telefon uygulamasıyla entegre edilmiştir. Uygulama ile diyabet hastalarına kan şekeri kritik seviyeye gelmeden önce akıllı telefon üzerinden uyarı bildirimleri gönderilmektedir. Aynı zamanda kullanıcılar güncel ve tahmin edilen şeker değerlerini istedikleri zaman takip edebilmeleri sağlanmıştır.


Bu makalenin geri kalanı aşağıdaki şekilde düzenlenmiştir: Bölüm 2'de LSTM tabanlı RNN ile kan şekeri tahmini yapan yöntemimiz açıklanmıştır. Bölüm 3'te veri seti ve sonuçlar tartışıldıktan sonra vargılar ve gelecek çalışmalar Bölüm 4'te anlatılmıştır.

2. Önerilen Yöntem

Diyabet hastalarından elde edilen zamana bağlı veriler ile eğitilen LSTM tabanlı RNN kullanarak bir sonraki şeker değerini tahmin eden bir yöntemimiz bu bölümde önerilmiştir. LSTM ve RNN modelleri açıklandıktan sonra, sistemin entegre edildiği kendi tasarımı olan *BffDiabetes* Android uygulaması açıklanacaktır.


2.1. LSTM Tabanlı RNN ile Kan Şekeri Tahmini

RNN veri girişlerinden beslenir ve veri ağı girdiğinde, çıktı tekrar giriş olarak kullanılır. Şekil 1'de (Olah, 2021) gösterildiği gibi, bu çalışma şekli sinir ağında bir döngü oluşturarak hafızanın korunmasına yardımcı olur. Böylece önceki çıktı veya önceki giriş, bir sonraki çıktıyı tahmin etmede iyi bir ağırlığa sahip olur. Bu sayede, RNN modelleri dijital veri serilerini tahmininde avantaj sağlamaktadır.



Şekil 1. Genişletilmiş RNN yapısı

Şekildeki 'A' ağı tanımlarken, X_t giriş verisini ve h_t çıkışı belirtmektedir. RNN yaklaşımında girdi verilerindeki her bilgi, önceki çıktının değeri dikkate alınarak tekrar tekrar incelenir. Böylelikle önceki zamandaki bilgileri dikkate alan öğrenme gerçekleştirilmektedir. Fakat, RNN modelini eğitmek için kullanılan zaman içinde geri yayılım (Backpropagation Through Time-BTT) algoritması, ufukta gradyan (Gradient), patlama gradyanı (Detonation Gradient) ve uzun vadeli bağımlılık sorunlarına neden olmaktadır. Geleneksel RNN yapısında görülen kaybolan (vanishing) ve patlayan (exploding) gradyan problemleri LSTM yapısı ile çözülmektedir. Yapısı Şekil 2'de (Aliberti et al., 2019) gösterilen LSTM çalışma prensibi dört adımdan oluşmaktadır.



Şekil 2. LSTM diyagramı, burada X_t bir hücrenin girdisi ve h_t bir hücrenin çıktısıdır ((Aliberti et al., 2019)'dan uyarlanmıştır).

İlk adımda hangi bilgilerin gerekli olmadığını ve hücreden kaldırılacağını belirler. Bu kararı vermek için, Şekil 2'de gösterildiği gibi, unutma kapısı katmanı (forget gate layer) adı verilen sigmoid fonksiyon katmanı kullanılır. Bu işlemler, unutma kapısı katmanında (f_t) Denklem (1) kullanılarak gerçekleştirilir ve etkinleştirme işlevi olarak sigmoid kullanılır.

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (1)$$

Denklemden W_f unutma kapısı ağırlıklarını ve b_f unutma kapısı bayes değerini ifade etmektedir. İkinci adımda hücre durumunda hangi bilgilerin saklanacağına karar verilir. Hangi girişlerin güncelleneceği, "giriş kapısı katmanı (input gate layer)" adı verilen bir sigmoid katmanı ile belirlenir. Daha sonra duruma eklenebilecek yeni aday değerlerin vektörünü oluşturan tanh tabakası Şekil 2'de gösterildiği gibi kullanılır. İkinci adımda, yeni bilginin belirlendiği giriş katmanı etkinleştirilir ve ilk olarak bilgi (i_t) Denklem (2) kullanılarak sigmoid fonksiyonu ile güncellenir. Daha sonra Denklem (3) ile yeni bilgi oluşturacak aday bilgiler tanh fonksiyonu tarafından belirlenir.

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (2)$$

$$C_t = \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad (3)$$

Denklemden W_i giriş kapısı ağırlıklarını, W_c hafıza hücresi (memory cell) ağırlıklarını, b_i giriş kapısı bayes değerini b_c hafıza hücresi bayes değerini ifade etmektedir. Üçüncü adımda, eski hücre durumu C_{t-1} , yeni hücre durumu C_t 'ye güncellenir. İlk olarak, eski durum, daha önce unutmaya karar verilen bilgileri unutarak f_t ile çarpılır. Daha sonra, Şekil 2'de gösterildiği gibi güncellenmeye karar verilen sonuçların her bir durumunun değerine göre ölçeklenen yeni aday değerleri veren C_t eklenir. Denklem (4) ile yeni bilgiler oluşturulur.

$$C_t = f_t * C_{t-1} + i_t * C_t \quad (4)$$

Son adımda, sigmoid katman, hücre durumunun hangi kısımlarının çıkarılacağına karar verilerek çalıştırılır. Daha sonra, hücre durumu tanh'dan geçirilir ve sigmoid kapının çıktısı ile çarpılır, böylece Şekil 2'de gösterildiği gibi yalnızca ihtiyaç duyulan kısımlar çıkarılır. Son olarak, çıktı katmanında (output gate layer) Denklem (5) ve (6) kullanılarak çıktı verileri elde edilir.

$$o_t = \sigma(W_{o,x} * X_t + W_{o,x} * h_{t-1} + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$


Denklemden o_t çıkış kapısı aktivasyon vektörünü, b_o çıkış kapısı bayes değerini tanımlamaktadır. Çalışmada kullanılan LSTM modelinde yalnızca bir nöron kullanılmıştır. LSTM nöronu tek sınıflı sınıflandırma problemini çözmeye çalıştığı için tek elemanlı bir çıktı vektörü vermektedir. Veri setindeki her bir bit değeri modele tek tek verilir ve modelin bu girdilerden tahminler yapması beklenir. Tahmin yapabilmek için $[t - 19, t]$ aralığındaki herhangi bir yerde herhangi bir zamanda t için dürtü bilgileri saklanacağı bir pencere (window) aralığı kullanılmıştır. LSTM sayesinde, gizli durum ve hücre durumu herhangi bir zamanda t değeri için $t + 1$ girişi kullanılır ve bu bilgiler daha sonraki zaman adımlarına aktarılabilir. 20 zaman adımında, gizli durum ve hücre durumu sıfırlanır ve önceki 20 adımdan tekrarlayan gradyan hesaplaması engellenir. Önemli bilgiler $[1, 20]$ dizisi içinde olduğundan, sıfırlama süresinin 20'ye atanması uygun görülmüştür. Reset periyodu için daha küçük bir sayı seçildiğinde, bilgiye ulaşmadan sıfırlama gerçekleşebilir ve daha büyük bir sayı seçildiğinde, gereksiz gradyan hesaplamaları yapılarak hesaplama maliyeti artırılması söz konusudur. Bu çalışmada kullanılan LSTM modeli ve ilgili parametreler Bölüm 3'te detaylı olarak anlatılmıştır.

2.2. Akıllı Telefon Uygulaması BffDiabetes

Önerdiğimiz kan şekeri tahmin yöntemi, diyabet hastalarının günlük hayatında kolay ve konforlu bir şekilde kullanabilmesi için, kendi tasarımı olan Android uygulamayla entegre edilmiştir. Kan şekeri ölçüm sensörleriyle Bluetooth üzerinden kablosuz haberleşebilen uygulamamız, ölçüm verilerinden elde ettiği bilgilerle bir sonraki kan şekerinin tahmin edilen değerini uygulamanın ekranında göstermektedir. Kritik seviyelere doğru eğilim başladığında kullanıcıya sesli ve görsel uyarı vermektedir. Android Studio platformunda Java dili kullanılarak geliştirilen uygulamamız, diyabet hastalığının ömür boyu tedavi gerektiren kronik bir hastalık olması nedeniyle *sonsuz den en iyi arkadaş (Bff)* esinlenerek, uygulamaya *BffDiabetes* adı verilmiştir. Sensörden gelecek verinin işlenip tahmin işleminin gerçekleştirilebilmesi için ilgili verinin bulut sistemi üzerinden sunucuya gönderilmesi gerekmektedir. Böylelikle, sunucuda

koşuturulan tahmin algoritması yeni değeri tahmin edebilecek ve bu değer tekrar bulut sistemi üzerinden *BffDiabetes* ekranında gösterilecektir. Bulut sistemi üzerinden veri transferi için Firebase Realtime Database kullanılmıştır.

Firebase Realtime Database, bulut tabanlı bir NoSQL (Yalnızca SQL Değil) veritabanı sistemidir. Herhangi bir SQL sorgusuna ihtiyaç duymadan JSON (JavaScript Object Notation) parametreleri ile yönetebilirler. Veri depolamaya ek olarak, eşzamanlı işlem ile veri değişikliklerinin anlık izlenmesine izin vermektedir (Li, Yen, Lin, Tung, & Huang, 2018; Moroney, 2017). Firebase Realtime Database, tüm verileri bir JSON nesnesi olarak ağaç yapısı olarak tutmaktadır. JSON ağacına veri eklenildiğinde, veriler JSON biçiminde bir düğüm haline gelir (Firebase, 2021). Bu şekilde uygulamaya uygun veriler döndürülür veya veritabanının eklenmesi, silinmesi veya güncellenmesi gerçekleştirilmektedir.



Şekil 3. Çalışmada Kullanılan Veri Seti

3. Deneysel Sonuçlar

Bu bölümde, kullanılan veri seti açıklandıktan sonra kullanılan veri metrikleri ve deneysel sonuçlar tartışılmıştır.

3.1. Veri Seti

Bu çalışmada, diyabet hastalarının kullandığı CGM cihazından beş dakikada bir alınan gerçek kan şekeri değerleriyle oluşturulan veri seti kullanılmıştır. Sürekli glikoz izleme cihazı sayesinde bu ölçümler dijital ortamda kayıt altına alınmıştır. Şekil 3'te gösterilen gerçek veri seti, toplamda her 5 dakikada bir gerçekleşen 14 günlük verilerden oluşmaktadır. Oluşturulan veri seti, zamanla değişen kan şekeri değerlerinden oluşur. Veri setinin %80'i eğitim, %20'si test için kullanılmıştır.

3.2. Sonuçlar

Bu çalışmada önerilen yöntemin performansını ölçmek için RMSE ve ortalama mutlak hata (Mean Absolute Error-MAE) metrikleri kullanılmıştır. RMSE, bir model tarafından öngörülen değerler ile gerçekte gözlemlenen değerler arasındaki farkın sıklıkla kullanılan bir ölçüsüdür. MAE, orijinal veriler kullanılarak yapılan bir tahmin yönteminin, tahmin

doğruluğunun bir ölçüsüdür. Ayrıca, eğitimden elde edilen doğrulama (validation) ve test doğrulukları değerleri de Tablo 1'de verilmiştir.

Tablo 1. Performans metrikleriyle modelin başarısının değerlendirilmesi

	RMSE (mg/dl)	MAE (mg/dl)	Doğrulama Doğruluğu	Test Doğruluğu
Önerilen Yöntem	3.72	4.14	95.60	94.20

Önerdiğimiz yöntemde, RMSE değeri 3.72 mg/dl ve MAE 4.14 mg/dl olarak elde edilmiştir. Bu sonuçlara ek olarak, doğrulama doğruluk değeri %95.60 ve test doğruluk değeri %94.20 elde edilmiştir. Deneysel, çift katmanlı LSTM katmanı kullanılarak 200 devir (epoch) ile gerçekleştirilmiştir. Adagrad'ı bir optimize edici olarak kullanırken, öğrenme hızı (Learning Rate) 0.001, bırakma (Dropout) 0.5 olarak belirlenmiştir. Hata işlevi için RMSE ve MAE kullanılmıştır. Elde ettiğimiz sonuçlar literatürdeki benzer çalışmalarda kıyaslanmış ve karşılaştırma Tablo 2'de verilmiştir. RMSE metriğine dayalı karşılaştırmada (Midroni et al., 2018) ve (Xie & Wang, 2018)'de sırasıyla 19.32 mg/dl ve 19.59 mg/dl gibi yüksek hata değerleri rapor edilmiştir. Önerdiğimiz çalışmaya en yakın sonuçlar (Pérez-Gandía et al., 2010) ve (Wiley, 2011)'de sırasıyla 4.13 mg/dl ve 4.50 mg/dl olmasına rağmen çalışmamızda elde edilen 3.72 mg/dl sonucunun gerisinde kalmaktadır. Bu karşılaştırma, önerdiğimiz yöntemin literatürdeki sonuçlara kıyasla daha iyi performans gösterdiğini kanıtlamaktadır.

Tablo 2. Kan Şekeri Tahmin Çalışmaları

	Yöntem	RMSE (mg/dl)
(Wiley, 2011)	SVR	4.50
(Pérez-Gandía et al., 2010)	FNN	4.13
(Midroni et al., 2018)	XGBoost	19.32
(Xie & Wang, 2018)	ARX	19.59
Önerilen Yöntem	LSTM	3.72

Önerilen yöntem daha sonra *BffDiabetes* adlı Android uygulamamızla birleştirilmiştir. *BffDiabetes*, kullanıcı kaydı ve kullanıcı giriş ekranı, uygulama ana ekranı, gezinme çekmecesi menüsü, bildirim gönderme, grafikler, alarm yöneticisi, hatırlatıcı, mevcut durum ve tahmin edilen durum olmak üzere dokuz temel ekrana sahiptir. Uygulamanın temel ekran görüntüleri Şekil 4'te verilmiştir. Şekil 4a ve b'de gösterildiği gibi, kullanıcılar kayıt olma ve oturum açma aşamalarını tamamlayarak uygulamaya giriş yapabilmektedir. Kayıt olma aşamasında uygulamaya ilk kez giriş yapacak kullanıcılardan kayıt ekranındaki bilgileri doldurarak kayıt olmaları istenmektedir. Kayıt olma işlemi başarı ile tamamlandıktan sonra kullanıcılar giriş ekranına gelerek uygulamaya giriş yapabilirler. Uygulamaya giriş yapılırken Android Studio'nun SharedPreferences özelliği kullanılmıştır. Böylece, oturum açmış kullanıcılar uygulamadan manuel olarak çıkış yapmadıkları sürece kaldıkları yerden devam edebilmektedirler. Kullanıcı giriş yaptığında, ana ekranda diyabet hakkında bilgi sahibi olabilecekleri makaleler ve kısa videolar yer almaktadır. Kullanıcıların uygulama içinde istediklerine hızlı bir şekilde ulaşmalarını sağlamak için yandan açılır ekran (Navigation Drawer) eklenmiştir.



Şekil 4. BffDiabetes uygulamasının temel ekranları şunlardır: (a)'da giriş ekranı, (b)'de kayıt ekranı, (c)'de yandan açılır ekran (navigation drawer), (d)'de normal değerler için ana ekran, (e)'de grafik görüntüleme ekranı, (f)'de normal değerler için durum taraması, (g)'de normal değerler için tahmin edilen durum taraması, (h)'de diyabet değerleri için ana ekran, (i)'de diyabet değerleri için mevcut durum taraması, (j)'de diyabet değerleri için tahmini durum taraması

Şekil 4c'de görüldüğü gibi uygulama, alarm, hatırlatma ve dünyadaki diyabet hastalığı ile ilgili güncel bilgilere ulaşmak için Diabetes.org sitelere erişim kolaylığı sağlamaktadır. Kullanıcı bu ekran ile Şekil 4d'de gitmek istediği sayfayı kolaylıkla bulabilir, LSTM modeli kullanılarak elde edilen tahmin edilen değerler ve mevcut değerler ekrana gelebilir. Algoritmamız 5, 10 ve 15 dakika ilerisi için Şekil 4d'de gösterildiği üzere tahminler üretmektedir. Yapılan tahminlere dayalı grafikler Şekil 4e'de gösterildiği üzere, kullanıcıların analiz etmesi kolaylaştırmak için verilmiştir. Şekil 4f ve g'de gösterildiği gibi, iki ayrı sayfa mevcut değerler ve tahmin edilen değerler görülebilmektedir. Bunların yanı sıra emojiler ve püf noktaları kullanılarak kullanıcının anlık durumu yorumlaması kolaylaştırılmıştır. Şekil 4d ve h'de gösterilen resimler sırasıyla karşılaştırıldığında, ilk resim normal durumdaki değerleri gösterirken, ikinci resim kullanıcının o anki durumunun diyabetli olduğunu göstermektedir. Dairesel ilerleme çubuğu normal durumlar için yeşil görünürken, diyabet ve hipoglisemide durumunda kırmızı olmaktadır. Benzer durumlar Şekil 4i ve j'de diyabetin olduğu vakalar için gösterilmiştir. Tahmin edilen kan şekeri değeri diyabet bulgusu olduğunda kullanıcıya uyarı mesajı

gönderilmektedir. Kullanıcıya akıllı telefonun bildirim kütünden bir sesli ve titreşimli bilgi mesajı verilmektedir.

4. Vargılar

Bu çalışmada, kan şekeri değerini tahmin etmek için LSTM tabanlı RNN modeli önerilmiştir. Önerilen modeli eğitmek ve performans değerlendirmesi yapmak için her 5 dakikada bir diyabetik hastalardan alınan veriler toplanmıştır. Bu veriler eğitim ve test seti olarak iki gruba ayrılmıştır. Eğitim verileri sadece modelin öğrenme sürecinde kullanılırken, test verileri modelin performans değerlendirmesi için kullanılmıştır. Performans metrikleri analiz edildiğinde, RMSE 3.72 mg/dl, MAE 4.14 mg/dl, doğrulama doğruluğu %95.6 ve test doğruluğu %94.2 olarak elde edilmiştir. Önerilen model Android uygulaması BffDiabetes'e entegre edilerek diyabet hastalarının kullanımına sunulmuştur. Son olarak, gelecekte çalışmalarda kan şekeri değerini tahmin etmek için insülin, bazal metabolizma, uyku durumu, açlık ve yemek sonrası kan şekeri vb. özellikler değerlendirilerek model geliştirilecektir. Meta sezgisel algoritmalar kullanılarak LSTM modelinin parametrelerinin optimize edilmesi hedeflenilmektedir.

Kaynakça

- Aliberti, A., Pupillo, I., Terna, S., Macii, E., Di Cataldo, S., Patti, E., & Acquaviva, A. (2019). A multi-patient data-driven approach to blood glucose prediction. *J IEEE Access*, 7, 69311-69325.
- Association, A. D. (2014). Diagnosis and classification of diabetes mellitus. *J Diabetes care*, 37(Supplement 1), S81-S90.
- Bunescu, R., Struble, N., Marling, C., Shubrook, J., & Schwartz, F. (2013). *Blood glucose level prediction using physiological models and support vector regression*. Paper presented at the 2013 12th International Conference on Machine Learning and Applications.
- Daskalaki, E., Prountzou, A., Diem, P., & Mougiakakou, S. G. (2012). Real-time adaptive models for the personalized prediction of glycemic profile in type 1 diabetes patients. *J Diabetes technology therapeutics*, 14(2), 168-174.
- Firestore. (2021). Firestore Realtime Database. Retrieved from <https://firebase.google.com/docs/database>
- Kap, Ö., Kilic, V., Hardy, J. G., & Horzum, N. (2021). Smartphone-based colorimetric detection systems for glucose monitoring in the diagnosis and management of diabetes. *J Analyst*.
- Li, W.-J., Yen, C., Lin, Y.-S., Tung, S.-C., & Huang, S. (2018). *JustIoT Internet of Things based on the Firestore real-time database*. Paper presented at the 2018 IEEE International Conference on Smart Manufacturing, Industrial & Logistics Engineering (SMILE).
- Mercan, Ö. B. (2020). *Deep Learning based Colorimetric Classification of Glucose with Au-Ag nanoparticles using Smartphone*. Paper presented at the 2020 Medical Technologies Congress (TIPTEKNO).
- Mercan, Ö. B., Doğan, V., & Kılıç, V. (2020). *Time Series Analysis based Machine Learning Classification for Blood Sugar Levels*. Paper presented at the 2020 Medical Technologies Congress (TIPTEKNO).
- Mercan, Ö. B., & Kılıç, V. (2020). *Fuzzy classifier based colorimetric quantification using a smartphone*. Paper presented at the International Conference on Intelligent and Fuzzy Systems.
- Mercan, Ö. B., Kılıç, V., & Şen, M. (2021). Machine learning-based colorimetric determination of glucose in artificial saliva with different reagents using a smartphone coupled μ PAD. *J Sensors Actuators B: Chemical*, 329, 129037.
- Midroni, C., Leimbögl, P., Baruah, G., Kolla, M., Whitehead, A., & Fossat, Y. (2018). *Predicting glycemia in type 1 diabetes patients: experiments with xg-boost*. Paper presented at the KHD@ IJCAI.
- Moroney, L. (2017). The firebase realtime database. In *The Definitive Guide to Firebase* (pp. 51-71): Springer.
- Mutlu, A. Y., & Kılıç, V. (2018). *Machine learning based smartphone spectrometer for harmful dyes detection in water*. Paper presented at the 2018 26th Signal Processing and Communications Applications Conference (SIU).
- Olah, C. (2021). Understanding LSTM Networks. Retrieved from <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Pala, T., & Yücedağ, İ. (2016). *Veri Madenciliği Tekniklerinden Sınıflandırma Kullanılarak Tip 2 Diyabet Tanısı*. Paper presented at the International Artificial Intelligence and Data Processing Symposium.
- Pérez-Gandía, C., Facchinetti, A., Sparacino, G., Cobelli, C., Gómez, E., Rigla, M., . . . Hernandez, M. (2010). Artificial neural network algorithm for online glucose prediction from continuous glucose monitoring. *J Diabetes technology therapeutics*, 12(1), 81-88.
- Song, W., Cai, W., Li, J., Jiang, F., & He, S. (2019). *Predicting Blood Glucose Levels with EMD and LSTM Based CGM Data*. Paper presented at the 2019 6th International Conference on Systems and Informatics (ICSAI).
- Strollo, F., Furia, A., Verde, P., Bellia, A., Grusso, M., Mambro, A., . . . Gentile, S. (2021). Technological innovation of Continuous Glucose Monitoring (CGM) as a tool for commercial aviation pilots with insulin-treated diabetes and stakeholders/regulators: A new chance to improve the directives? *%J diabetes research clinical practice*, 172.
- Sun, Q., Jankovic, M. V., Bally, L., & Mougiakakou, S. G. (2018). *Predicting blood glucose with an LSTM and Bi-LSTM based deep neural network*. Paper presented at the 2018 14th Symposium on Neural Networks and Applications (NEUREL).
- Wiley, M. T. (2011). *Machine learning for diabetes decision support*. Ohio University,
- Xie, J., & Wang, Q. (2018). *Benchmark machine learning approaches with classical time series approaches on the blood glucose level prediction challenge*. Paper presented at the KHD@ IJCAI.
- Yahyaoui, A., Jamil, A., Rasheed, J., & Yesiltepe, M. (2019). *A decision support system for diabetes prediction using machine learning and deep learning techniques*. Paper presented at the 2019 1st International Informatics and Software Engineering Conference (UBMYK).