



PPG ve ECG Sinyallerinden Arteriyel Kan Basıncı Tahmini

Arterial Blood Pressure Estimation From PPG, ECG Signal

Hüseyin Alperen DAĞDÖGEN^{1*}, İbrahim TÜRKÖĞLU²¹Malatya Turgut Özal Üniversitesi, Yazılım Mühendisliği Bölümü, huseyin.dagdogen@ozal.edu.tr
ORCID: <https://orcid.org/0000-0003-2862-8257>²Fırat Üniversitesi, Yazılım Mühendisliği, iturkoglu@firat.edu.tr
ORCID: <https://orcid.org/0000-0003-4938-4167>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 31 Mayıs 2023
Revizyon 25 Ekim 2023
Kabul 4 Kasım 2023
Online 31 Aralık 2023

Anahtar Kelimeler:

Temassız Tansiyon Ölçümü,
Yapay Zeka,
Derin Öğrenme,
Elektrokardiyografi,
Fotoplethysmogram.

ÖZ

Yüksek kan basıncı; özellikle kritik hastalarda izlenmediği ve kontrol edilmediği takdirde daha fazla sağlık komplikasyonlarına sebep olmaktadır. Son zamanlarda dünyada sürekli tüketilen hazır gıda benzeri besinlerden dolayı kardiyovasküler hastalıklar artmaktadır. Bu hastalıklar dünyanın en yaygın ölüm sebepleri arasında yer almaktadır. Kalp ile ilgili hastalıkları tespit ve tedavi etmek için birçok parametreyle birlikte kan basıncında sürekli takip edilmelidir. Kan basıncı ölçümü için geliştirilen birçok girişimsel ve girişimsel olmayan yöntem geliştirilmiştir. Hastanelerde kullanılan çoğu yöntem girişimsel yöntemlerdir. Bu yöntemler, sürekli kan basıncı tahmini için kullanılmamaktadır. Ayrıca bir psikolojik rahatsızlık olan 'Beyaz Palto Sendromu' diye adlandırılan bir rahatsızlık vardır. Bu rahatsızlık özellikle halk arasında da 'Doktordan Korkmak' olarak bilinir. Ölçüm esnasında hastanın kan basıncının normal değerler dışında yüksek çıkmasında sebep olan bu hastalıktan kaçınmanın bir diğer yöntemi ise temassız tansiyon ölçümüdür. Bu çalışmada Photoplethysmogram (PPG) ve Electrocardiogram (ECG) gibi temassız bir şekilde toplanabilen sinyallerden Arteriyel Kan Basıncı (ABP) tahmini yapılmaktadır. Çalışmada birden fazla derin öğrenme modeli ve bu modeller farklı hiperparametreler ile karşılaştırılmıştır. Ayrıca çalışmada ölçüm metriği olarak ortalama hataların karesi (MAE) kullanılmıştır. Elde edilen sonuçlara göre LSTM model için 0.0165, LSTM ve dense katmanlarından oluşan model için 0.0258, sadece dense katmanlı mimariden oluşan birinci model için 0.0141, sadece dense katmanlı mimariden oluşan ikinci model için 0.281 sonuçları elde edilmiştir. GAN için ise ölçüm metriği olarak ikili çapraz entropi kullanılmıştır. Burada elde edilen ikili çapraz entropi değeri ise 2900 adımda eğitilen model için 2.382, 10000 adımda eğitilen model için ise 1.014 olarak ölçülmüştür. Elde edilen ABP değerlerinden sistolik tansiyon ve diyastolik tansiyon tahmini yapılmış olup elde edilen MAE sonuçları ise sistolik tansiyon için 2.19, diyastolik tansiyon için ise 0.941 olarak ölçülmüştür.

ARTICLE INFO

Article history:

Received 31 May 2023
Received in revised form 25 October 2023
Accepted 4 November 2023
Available online 31 December 2023

Keywords:

Cuffless Blood Pressure,
Artificial Intelligence,
Deep Learning,
Electrocardiograph,
Photoplethysmogram.

Doi: 10.24012/dumf.1307817

* Sorumlu Yazar

ABSTRACT

High blood pressure; It causes more health complexes, especially if the critical area is not monitored and controlled. Cardiovascular transmission is increased due to fast food-like foods consumed constantly in the world recently. It is among the most common causes of death in the world. Blood pressure, along with many parameters, must be constantly monitored for the diagnosis and treatment of heart-related diseases. Many invasive and noninvasive methods have been used for blood pressure details. Most methods used in hospitals are interventional procedures. These parameters are not used for continuous blood pressure estimation. There is also a disease called 'White Coat Syndrome', which is a psychological disorder. These disorders are known as 'Fear of the Doctor', especially among the public. Another method to avoid this disease, which is the cause of high bursts of blood pressure outside the normal values during the measurement periods, is non-contact pressure values. Arterial Blood Pressure (ABP) is estimated from signals that can be displayed at the highest level without contact, such as effective Photoplethysmogram (PPG) and Electrocardiogram (ECG). In the study, more than one deep learning model and these models were compared with different hyperparameters. Additionally, mean squared errors (MAE) was used as the measurement measurement metric. According to the obtained LSTM model, the result was 0.0165, 0.0258 for the model consisting of LSTM and dense layers, 0.0141 for the first model consisting only of dense embedded architecture, and 0.281 for the second model consisting of only dense embedded architecture. For GAN, binary cross entropy was used as the measurement metric. The binary cross entropy value obtained here was measured as 2.382 for the model that was kept until 2900, and 1.014 for the model that was kept until 10000. Systolic blood pressure and diastolic measurement were estimated from the ABP values obtained, and the MAE results obtained were measured as 2.19 for systolic blood pressure and 0.941 for diastolic blood pressure.

Giriş

1733 yılında ilk kan basıncı ölçümleri ve nabız basıncı ölçümleri yapılmıştır. Ancak bu daha çok ham ölçümler ve yirminci yüzyılın tekniklerinden çok uzak tekniklerdir. Hales, 'Anatomik Diseksiyonların Uyumsuzluğu' nedeniyle kan basıncı deneyleriyle hemen devam edememiştir. Ancak daha sonra, ventriküllerin kapasitesini ve dolaşımın diğer birçok özelliğini inceleyerek sorgularına devam etmiştir. Ancak bir yüzyıl sonra, Poiseuille'nin cıva bir manometrenin 1828'de uygulamaya konmasıyla kan basıncı üzerinde doğru bir çalışma başlamıştır. Poiseuille 1828 yılında, arteriyel kan basıncının ölçümü için cıva manometre kullanımıyla doktora disserasyonu ile Kraliyet Tıp Akademisi'nin altın madalyasını kazanmıştır. Helmholtz tarafından 1850 yılında kas hareketlerini kaydetmek için geliştirilen miyograf ve yeni bir grafik yöntemiyle nabız ilk izleyen Tubingen Vierordt tarafından bir tansiyon aleti (sphygmograf) geliştirilmiştir. Kan basıncının ilk gerçek doğru tahmini 1856 yılında cerrah Faivre tarafından yapılmıştır; bir cıva manometresine bir arter bağlanmış ve böylece doğrudan ölçüm elde edilmiştir. Bahsi geçen cıva tansiyon aleti ile femoral arter kan basıncının 120 mm/hg ve brakial arter basıncının 115 ile 120 mm/hg olduğu tespit edilmiştir. Bunlar ve diğer doğrudan okumalar, kan basıncı için normal bir aralık oluşturmada çok değerlidir. Ancak, kanül ile arter arasında doğrudan bağlantı içeren hiçbir yöntem yaygın şekilde kullanılamayabileceği için bu yöntem rutin ölçümler için kesinlikle kullanışsız bir yöntemdir[1]. Kan basıncını ölçmeye yönelik birçok cihaz, ortak bir özelliğe bağlıdır; osilometrik kan basıncını ölçmek için şişirilebilir manşetle ekstremitelerin (kol, bilek, parmak veya bacak) arterisi tıkanmalıdır veya Korotkoff seslerinin algılanmasıyla bu işlem yapılmalıdır. Nabız dalga biçimi analizi gibi kol veya bacak tıkanmasına bağlı olmayan diğer teknikler de kullanılabilir ancak bunların klinik uygulamalarda çok az uygulaması vardır. Günümüzde mevcut olan teknikler, kökenlerini geleneksel oskültasyon kan basıncı ölçüm tekniğine borçludur ve bu yeni tekniklerin gerçekten de geleneksel cıvalı tansiyon aleti kadar doğru ölçümler sunduğu gösterilmelidir. Tansiyon aletinin tanıtılmasından bu yana, cıvalı ve aneroid tansiyon aleti kan basıncını ölçmek için en popüler cihazlar olmuştur[2].

Tansiyon, kan basıncını ifade eden bir tıbbi terim olarak kullanılmaktadır ve kanın arterler ve damarlar içindeki basıncını ifade etmektedir [3]. Tansiyon, genellikle iki bileşenle ifade edilmektedir: sistolik tansiyon, kalbin kasıldığı anki en yüksek kan basıncını temsil ederken, diyastolik tansiyon, kalp dinlendiği anki en düşük kan basıncını göstermektedir [4]. Tansiyonun normal aralıkta olması, vücudun sağlıklı bir şekilde çalışması için önemlidir. Tansiyon kanın dolaşımını düzenlemekte ve organlara oksijen ve besin taşımaktadır [5]. Tansiyonun yüksek (hipertansiyon) veya düşük (hipotansiyon) olması ciddi sağlık sorunlarına yol açabilir. Özellikle yüksek tansiyon, kalp hastalıkları, felç, böbrek problemleri ve diğer sağlık sorunlarına yol açabilen bir risk faktörüdür [6]. Tansiyon, birçok faktörden etkilenebilir, bunlar yaş, cinsiyet, genetik yatkınlık, beslenme alışkanlıkları, fiziksel aktivite düzeyi, stres ve obezite gibi faktörleri içermektedir. Bu nedenle, tansiyonun düzenli olarak ölçülmesi ve gerektiğinde tedavi edilmesi önemlidir [7].

Tıp literatürü, tansiyonun tanı ve tedavisi konularında birçok araştırma ve klinik çalışma içermektedir. Bu çalışmalar, tansiyonun nedenleri, risk faktörleri ve tedavi yöntemleri üzerine derinlemesine bilgi sağlamaktadır. Sağlık profesyonelleri, hastaların tansiyon seviyelerini izlemelerini ve uygun önlemleri alarak sağlıklarını korumalarını teşvik etmek için bu bilgilere dayanmaktadır [8].

Literatürde de kan basıncı tahmini için kullanılan başlıca iki tip sinyal türü vardır. Bunlar Photoplethysmogram (PPG) ve Electrocardiograph (ECG) dediğimiz sinyal türleridir. Bu sinyal türlerinden başlıca yapay zekâ desteği ile sistolik kan basıncı, diyastolik kan basıncı ve arteriyel kan basıncı (ABP) diye adlandırılan tansiyon türleri tespit edilmektedir. Arteriyel kan basıncı izleme (ABPM), tıbbi bir ölçüm tekniğidir ve bir bireyin kan basıncını 24 saat boyunca sürekli olarak izlemek için kullanılır [9]. Bu yöntem, günlük yaşamın normal koşullarında kan basıncının değişimlerini incelemeyi amaçlar. Genellikle bir tansiyon manşeti ve taşınabilir bir cihaz kullanılarak gerçekleştirilir [10]. ABPM, klinik ortamlar dışında kan basıncını ölçmek ve kaydetmek için kullanılır. Bu sayede beyaz önlük hipertansiyonu gibi olguların teşhis edilmesi, gece uykusu sırasında meydana gelen kan basıncı değişikliklerinin gözlemlenmesi ve gizli gece hipertansiyonunun belirlenmesi mümkün olur [11]. Ayrıca, bu yöntemle elde edilen veriler, hipertansiyon teşhisi ve kardiyovasküler risk tahmini için daha kesin bilgiler sağlar.

Bahsedilen hastalıklar ve riskler nedeniyle, özellikle ileri yaşlardaki hastalar için sürekli tansiyon takibi büyük önem taşımaktadır. Ani yükselen tansiyonlar ve hipertansiyon gibi sürekli takip gerektiren sağlık sorunları, geleneksel manşet tabanlı tansiyon ölçüm teknikleri ile tedavi edildiğinde hem maliyetli hem de hastalar için rahatsızlık yaratan bir süreç oluşturabilmektedir. Bu nedenlerle, manşet kullanmadan ve sürekli bir şekilde tansiyon ölçümü yapabilen bir çözüm gerekliliği doğmuştur. Bu çözüm, basit bir cihazla PPG ve ECG sinyallerinden ABP sinyali tahmin ederek elde edilebilir. İlgili probleme yönelik mevcut literatürde çeşitli çözüm yöntemleri bulunsa da, bu çalışma, literatürdeki diğer çalışmaların eksikliklerini ve avantajlarını inceleyerek, daha iyi sonuçlar elde edebilmek için yeni bir yaklaşım ve yapay zekâ modeli önermektedir.

Bu çalışmanın amacı; sürekli ve temassız tansiyon ölçümü gerçekleştirmek için bir yapay zekâ modeli geliştirmektir. Bu kapsamda birden çok derin öğrenme modellerinin performansı incelenmiştir. İkinci bölümde; literatürde yer alan daha önce kabul görmüş çalışmalar hakkında bilgiler verilmiştir. Literatürde yer alan çalışmaların başarımları, kullanılan teknikler ve veri ön işleme aşamaları gibi aşamaları incelenmiştir. Çalışmaların metrikleri incelenmiş ve başarılı olan çalışmalar referans alınmıştır. Üçüncü bölümde; çalışmada kullanılan veri setinin içeriği, veri setinde ki sinyallerin özellikleri hakkında bilgiler verilmiştir. Ayrıca verilerin ön işleme aşamaları ve ön işleme aşamalarında kullanılan teknikler, taban kaldırma ve normalizasyon gibi işlemlere ve bu işlemlerin sonuçlarına değinilmiştir. Çalışmada kullanılan derin öğrenme teknikleri, modellerin mimari yapıları, modellerin hiperparametreleri ve modeller hakkında bilgiler verilmiştir. Son bölüm ise; bulunan

bulgular, sonuçların tartışılması ve literatürle karşılaştırılmasını kapsamaktadır.

İlgili Çalışmalar

Bu kısımda temassız tansiyon tahmini üzerinde gerçekleştirilen klasik makine öğrenmesi ve derin öğrenme tabanlı çalışmalara yer verilmiştir. Çalışmalarda kullanılan derin öğrenme modelleri, klasik makine öğrenme modelleri ve özellik çıkarma aşamasında nasıl bir yol izlendiği konusunda araştırmalar yer almaktadır. [12] numaralı çalışmada manşet tabanlı ölçümden elde edilen fotopletismogram (PPG) sinyallerinden, klasik makine öğrenmesi algoritmaları kullanılarak tansiyon tahmin edilmesi amaçlanmıştır. Daha optimize bir sınıflandırıcı seçmek, öznelik çıkarmak ve olası makine öğrenmesi hatalarının önüne geçebilmek için ağaç tabanlı pipeline optimizasyon ağacı adı verilen (TPOT) bir araç kullanılarak en iyi regresyon modeli seçilmiştir. Verilerin ön işleme aşamasında sinyaller içerisinde yer alan potansiyel gürültüler elimine edilebilmek için TPOT içerisinde yer alan notch filtresi, band-pass filtresi ve sıfır faz filtreleri gibi filtrelerle işleme tabi tutulmuştur. Ardından tansiyon tahmini yapabilmek için rastgele orman (RF) ve en yakın komşu (KNN) algoritmaları kullanılmıştır. Çalışmada, 1000 konu için 32.061 milyon örnek içeren PhysioNet global veri kümesi kullanılmıştır. Çalışmada değerlendirme metriği olarak ortalama mutlak hata (MAE) kullanılmıştır. Elde edilen sonuçlar sistolik tansiyon için 6.52, diyastolik tansiyon için ise 4.19 olarak bulunmuştur.

Ayrıca literatürde yer alan çalışmaların birçoğunda tansiyon tahmini için, PPG sinyallerine ek olarak elektrokardiyografi (ECG) sinyalleri de kullanılmaktadır. [13] numaralı çalışmada PPG ve ECG sinyallerinden tansiyon tahmini yapılması hedeflenmiştir. Araştırma da PhysioNet veri tabanında yer alan MIMIC-II veri kümesi kullanılmıştır. Bu veri kümesi 942 hastanın 12.000 örneğini içeren 125 Hz frekanslı sinyallerden oluşmaktadır. Ayrıca çalışmada literatürden farklı olarak MIMIC-II veri setine ek olarak BCG veri seti de kullanılmıştır. Veri ön işleme işlemleri MATLAB ortamında gerçekleştirilmiştir.

Ön işlenmiş veri setinden özellik çıkarmak için U-Net tabanlı bir derin öğrenme mimarisi kullanılmıştır. Öz nitelikler çıkartıldıktan sonra, klasik makine öğrenmesi algoritmaları ile tahmin yapılmıştır. Bu algoritmalar içerisinde en iyi sonucu multi-layer perceptron (MLP) algoritması vermiştir. Elde edilen sonuçlar İngiliz Hipertansiyon Topluluğu (BHS) ve Tıbbi Cihazları Geliştirme Derneği (AAMI) standartlarına göre değerlendirilmiştir. Her iki standarda göre de elde edilen sonuçlar A sınıfında yer almıştır.

Literatürde sınıflandırmadan ziyade kümeleme algoritmaları da kullanılmıştır. [14] numaralı çalışmada PPG, ECG, ICG,BCG gibi sinyallerin bağımsız değişken olduğu ancak arter kan basıncı (ABP) sinyallerinin bağımlı değişken olduğu üzerinde durulmuştur. Bahsi geçen bu dört sinyallerden özellik çıkarılması ve çıkarılan bu özelliklerin makine öğrenmesi algoritmalarına verilerek tansiyon tahmini yapılması amaçlanmıştır. Daha önce bahsedilen çalışmalara ek olarak bu çalışmada doğruluğu arttırmak amacıyla kümeleme adımı içeren yeni bir yöntem sunulmaktadır. Önerilen bu yeni teknik her kümede gradyan artırma

regresyonu (GBR), rastgele orman (RF), rastgele orman regresyonu (RFR) ve multi-layer perceptron (MLP) gibi geleneksel makine öğrenmesi algoritmaları uygulayarak modeller oluşturmuştur. Bu sayede PPG ve ECG sinyallerinden nabız geçiş süresi (PTT), PPG yoğunluk oranı (PIR) ve kalp atışı hızı (HR) gibi özellikleri girdi olarak verip, ABP sinyallerinden sistolik ve diyastolik kan basıncını bağımlı olarak tahmin etmektedir. Bu çalışmada da diğerlerinde olduğu gibi PhysioNet'in MIMIC-II veri seti kullanılmıştır. 5 küme ve GBR uygulandığında SBP için MAE 2.56, DBP için ise 2.23 değerleri elde edilmiştir. Fakat kümeleme işlemi uygulanmadan elde edilen en iyi sonuçlar SBP için 6.36, DBP için 6.27 olarak ölçülmüştür.

[15] numaralı çalışmada kesik bir SBP veya DBP tahmini yapmak yerine tüm kan basıncı dalga formunu tahmin edilmesi üzerine odaklanılmıştır. PPG verilerinden, arteriyel kan basıncını tahmin edebilmek için yeni bir derin öğrenme modeli önerilmiştir. Burada ham bir şekilde verilen PPG sinyallerinden ABP sinyalini tahmin edilmesi amaçlanmıştır. Çalışmada MIMIC-II [16] veri seti kullanılmıştır. Çalışmada veri ön işleme aşamasında öncelikle verilerin gürültüden arındırılma işlemi gerçekleştirilmiş olup, ardından Z-Score normalizasyon işlemi gerçekleştirilmiştir. Ardından sinyallerin hizalandırılması işlemi gerçekleştirilmiştir. Diğer çalışmalar gibi sinyallerin birinci ve ikinci türevlerinden özellik çıkarma işlemi gerçekleştirilmiştir. Burada belirtilen ABP değerinin en yüksek noktası SBP, en düşük noktası ise DBP değerlerini vermektedir. Model olarak LSTM tabanlı bir kodlayıcı yapısı kullanılmıştır. Çalışmada LSTM modelde SBP için, mutlak hata değeri 4.05, DBP için 2.41 bulunmuştur. BHS standartlarında ise bu değerler Grade A gibi bir seviyeye ulaşmıştır.


[17] numaralı çalışmada diğer çalışmalar gibi amaç PPG ve ECG sinyallerinden SBP ve DBP tahminidir. MIMIC-II veri seti kullanılmıştır. Bu çalışmada ABPNet adı verilen bir yeni bir teknik uygulanmıştır. Bu ağ yapısı Çok Katmanlı Algılayıcılar (MLP) içeren bir yapıdadır. Çalışmada metrik olarak Root Mean Square Error (RMSE) metriği kullanılmıştır. Klasik bir MLP yapısından oluşan bu yapı için test sonuçları SBP için 3.6, DBP için ise 3.2 olmuştur. Son olarak eğitilen modeli, kendilerinin geliştirdiği ve VITAL-ECG diye adlandırılan cihaza bu modeli gömüp, giyilebilir bir cihaz halinde ölçüm yapacak şekilde düzenlemişlerdir.

Materyal ve Yöntemler

PPG, ECG ve ABP Sinyalleri


Biyomedikal cihazların ölçümleri temassız bir şekilde yapması, bu cihazları kullanan kişilere büyük bir oranda fayda sağlamaktadır. Temassız ölçüm yöntemlerinde en çok kullanılan ve fotopletismografi (Photoplethysmography) olarak adlandırılan PPG, optiksel ölçüm teknikleri günümüzde en çok kullanılan yöntemler arasında bulunmaktadır [18]. Fotopletismografi (PPG), vücut üzerinden temassız olarak bazı fizyolojik parametrelerin elde edilme tekniği olarak da adlandırılabilir. Bu yöntem kullanılarak elde edilen PPG sinyalleri içerisinde birçok fizyolojik bilgi barındırması ve temassız bir şekilde sürekli olarak izlenebilmesi nedeniyle birçok avantaja sahiptir. PPG sinyal verilerinin kaydedilmesinin temelinde kalbin kan damarlarına kan pompalaması sonucunda meydana gelen

kan damarlarındaki hacimsel değişiklikler yer almaktadır. PPG ölçümü deri üzerinden, kulak memesi, parmak ucu gibi kılcal damarların yoğun olarak bulunduğu bölgelerden rahat bir şekilde elde edildiği gibi bilek üzerinden de yapılabilmektedir. Bu ölçüm esnasında sensör kısmında verici olarak belli bir dalga boyunda ışık yayan led ve alıcı olarak da kullanılan bu dalga boyuna duyarlı bir fotodiyot kullanılmaktadır [19]. Çalışmada kullanılan veri setinde yer alan 125 Hz frekansında PPG sinyalinden bir kesit Şekil 1’de gösterilmiştir.



Şekil 1. PPG sinyal örneği.


ECG; vücut üzerine yerleştirilen elektrotlar ile belirlenen süre boyunca kalbin hareketini ve elektriksel aktivitesini ölçülerek kaydeden bir cihazdır. Kayıt yapıldıktan sonra elde edilen grafiğe ise elektrokardiyogram grafiği denir. Literatürde elektrokardiyografi, kalp kasının ve sinirsel iletim sisteminin çalışmasını incelemek üzere kalpte meydana gelen elektriksel aktivitelerin kaydedilmesi olarak tanımlanır. Bu kayıt sonucunda elde edilen grafik ECG grafiği olarak adlandırılır. Bu ölçümü yapmak için kullanılan alete de elektrokardiyograf cihazı denir. Bu cihaz kalbin kasılması sırasında oluşan elektriksel aktivitenin grafiksel olarak kayıt edilmesini sağlamaktadır. Kalp atımı olarak da adlandırılan, atriyum ve ventriküllerinin kasılması ve gevşemesi sırasında bir elektriksel aktivite oluşmaktadır. Bu aktivite, kalp ritmi, frekansı ve yayılımı hakkında pek çok veri içermektedir [13]. Çalışmada kullanılan veri setinde yer alan 125 Hz frekansında ECG sinyallerinden bir kesit Şekil 2’de gösterilmiştir.



Şekil 2. ECG sinyal örneği.

Arter kan basıncı (Arterial Blood Pressure(ABP)), kanın arter duvarında oluşturduğu basınç olarak tanımlanır. Bu basınç sabit olmamakla birlikte kalbin pompalama işlevi sırasındaki devinimlere göre değişiklik gösterebilmektedir. Sistol döneminde kanın oluşturduğu basınç sistolik tansiyonu, diyastol döneminde oluşturduğu basınç ise diyastolik tansiyonu vermektedir. Çalışmada kullanılan veri

setinde yer alan 125 Hz frekansında ABP sinyalinden bir kesit Şekil 3’te gösterilmiştir.



Şekil 3. ABP sinyal örneği.

ABP sinyallerinden SBP ve DBP tahmini kolaylıkla yapılabilmektedir. Burada istenilen SBP değeri ve sinyal eğer 180 mmHg’den büyük veya 80 mmHg’den küçük ise, SBP değeri hesaplamak için Denklem 1’de ki formül kullanılmaktadır [15].

$$SBP = \max(ABP) \quad (1)$$

İstenilen DBP değeri ve sinyal eğer 130 mmHg’den büyük veya 60 mmHg’den küçük ise DBP değeri hesaplamak için ise Denklem 2’de ki formül kullanılmaktadır [15].

$$DBP = \min(ABP) \quad (2)$$

Verilerin Hazırlanması

Çalışmanın bu bölümünde kullanılan veri seti ve verilerin hazırlanması hakkında bilgiler verilecektir. Çalışmada kullanılan veri seti literatürde de çoğu çalışmada kullanılan PhysioNet’e ait olan MIMIC-II [16] veri setidir.

Yoğun bakım ünitesi (ICU) hastalarının kritik durumu, yakından izleme gerektirmekte ve bunun sonucunda çok parametrelili büyük miktarda veri sürekli olarak toplanmaktadır. Bu, klinik veri madenciliği ile ilgilenen araştırmacılar için benzersiz bir fırsat oluşturmaktadır. Genel kullanıma açık bir ICU veri tabanı (çok parametrelili Akıllı İzleme) oluşturarak yoğun bakımda (MIMIC-II) daha şeffaf ve verimli bir yoğun bakım araştırma topluluğu oluşturmaya çalışılmıştır. MIMIC-II’de sunulan veriler, 2001 ile 2008 yılları arasında Beth İsrail Deaconess Tıp Merkezi’nden toplanmış ve 26,870 yetişkin hastadan oluşmaktadır. MIMIC II iki ana bileşenden oluşmaktadır; bunlar klinik veriler ve fizyolojik dalga biçimleridir. Hasta demografik bilgileri, intravenöz ilaç damlama oranları ve laboratuvar test sonuçlarını içeren klinik veriler ilişkisel bir veri tabanı olarak düzenlenmiştir. Hasta başında kaydedilen 125 Hz sinyalleri ve ilgili vital bulguları da içeren fizyolojik dalga formları açık kaynak formatında kaydedilmiştir [20].

Çalışmada kullanılan veri seti üç kanaldan oluşmaktadır;

1. PPG sinyali, FS=125Hz; parmak ucundan gelen fotopletimograf
2. ABP sinyali, FS=125Hz; girişimsel arteriyel kan basıncı (mmHg)
3. ECG sinyali, FS=125Hz; kanal II’den elektrokardiyogram

Veri ön işleme aşamasında ilk olarak, sinyaller kolay işlenebilmesi açısından 1024 numuneye bölünmüştür. Veri setinden gelen sinyaller birçok durumda ciddi taban çizgisi kaymasından zarar görmektedir. Bu nedenle, sinyalleri normalleştirmeden önce taban çizgisi gezinmesi kaldırılmıştır. Taban çizgisi kaldırılırken, Butterworth filtresi kullanılmıştır. Taban çizgisi kaldırma işlemi genellikle biyomedikal sinyal işleme gibi alanlarda kullanılmaktadır. Örnek olarak ECG sinyallerinde kalp atışları arasındaki düşük frekanslı gürültüyü (taban çizgisi) kaldırmak için Butterworth filtresi kullanılabilir. Butterworth filtresinin transfer fonksiyonu Denklem 3'te gösterilmiştir.

$$H(j\omega) = \frac{1}{\sqrt{1+(\frac{\omega}{\omega_c})^{2n}}} \quad (3)$$

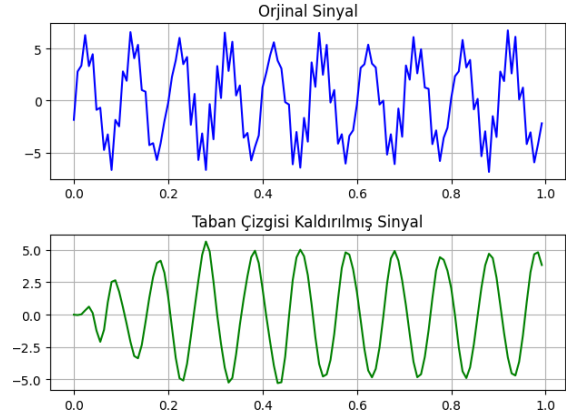
Taban çizgisi kaldırma işlemi için genellikle yüksek geçiren (high-pass) Butterworth filtresi kullanılmaktadır. Çalışmada taban çizgisi kaldırma işlemi aşağıdaki adımları içeren aşamalardan geçerek yapılmıştır

- **Sinyalin Fourier Dönüşümü Hesaplanması:** Fourier dönüşümü, bir sinyali zaman alanından frekans alanına dönüştürmektedir. Bu, sinyalin farklı frekanslardaki bileşenlerini analiz etmeyi mümkün kılmaktadır.
- **Butterworth Filtresi Uygulanması:** Hesaplanan Fourier dönüşümüne Butterworth filtresi uygulanmıştır. Bu işlem, düşük frekanslı bileşenleri (taban çizgisi) bastırmakta ve yüksek frekanslı bileşenleri (örneğin, EKG'deki QRS kompleksleri)

geçirmektedir. Filtre, kesme frekansı ve derecesi gibi parametrelere bağlıdır.

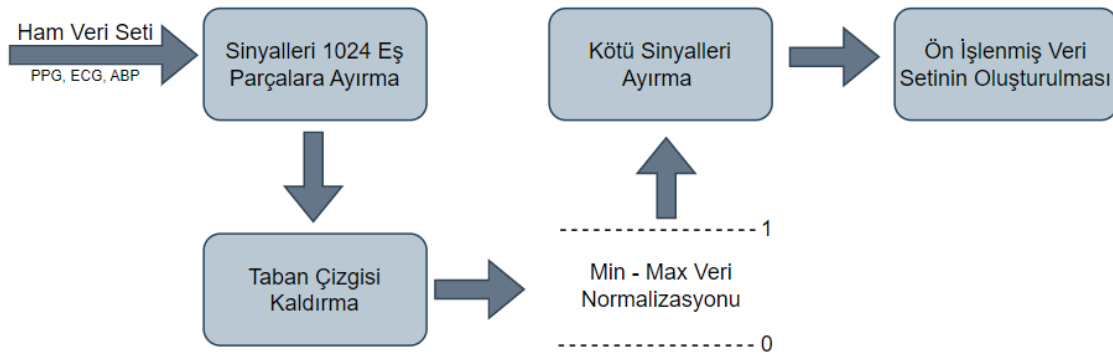
- **Ters Fourier Dönüşümü Hesaplanması:** Son aşamada ise filtrelenmiş sinyalin ters Fourier dönüşümünü hesaplanmıştır. Bu işlem, sinyali frekans alanından zaman alanına geri döndürmektedir.

Şekil 4'te taban çizgisi kaldırılmış bir sinyal örneği gösterilmiştir.



Şekil 4. Butterworth filtresi ile taban çizgisi kaldırma.

Taban çizgisi kaldırma işlemlerinin ardından sinyaller maximum normalizasyon işleminden geçirilip 0-1 arasında indirgenmiştir. Veri setinin tamamını derlemeden önce son derece bozulan sinyaller kaldırılmıştır. Veri ön işleme yapısı Şekil 5'te gösterilmiştir.



Şekil 5. Verilerin ön işleme aşamaları.

Farklı Derin Öğrenme Modelleri İle Tahmin

Çalışmada birden fazla derin öğrenme modeli kullanılıp sonuçları karşılaştırılmıştır.

Uzun Kısa Süreli Hafıza (LSTM), özellikle makine öğrenimi ve yapay zekâ alanlarında sıkça kullanılan bir derin öğrenme modeli türüdür. Özellikle zaman serileri, dil işleme, konuşma tanıma ve daha pek çok uygulamada büyük başarı elde etmiştir. LSTM modelin öne çıkan özellikleri, diğer geleneksel sinir ağı modellerine göre uzun vadeli bağımlılıkları daha etkili bir şekilde yakalayabilmesi ve bu sayede daha karmaşık veri yapılarını işleyebilmesidir.

LSTM, 1997 yılında Sepp Hochreiter ve Jürgen Schmidhuber tarafından tanıtılmıştır. LSTM, özellikle "patlayan ve kaybolan gradyanlar" olarak adlandırılan sorunu aşmak için tasarlanmıştır. Bu sorun, geleneksel tekrarlı sinir ağları (RNN)'lerin uzun süreli bağımlılıkları etkili bir şekilde yakalayamamalarından kaynaklanır ve bu nedenle eğitimleri zorlaştırmaktadır. LSTM, bu sorunu hafıza hücreleri ve kapı mekanizmaları kullanarak çözmektedir. Bu hücreler, veriyi okuma, yazma ve unutmak için öğrenilen bilgilere dayalı olarak işlemektedir [21].

Bu çalışmada öncelikli olarak kullanılan derin öğrenme modeli Bölüm LSTM modelidir. LSTM birimi sayısı için farklı hiperparametre değerleri {128, 256, 512, 1024} test


edilmiştir. LSTM modeli, geçici veri alma özelliği nedeniyle uygundur. PPG, ABP ve ECG sinyallerinin hepsi önemli geçici bileşenlere sahiptir. LSTM model mimarisi Şekil 6'da gösterilmiştir.

İkinci olarak LSTM ve dense katmanının birleşiminden oluşan bir model tercih edilmiştir. Mimarideki bu değişiklik, modelin değerleri çıkarmaya başlamadan önce tüm girişi görmesi durumunda daha iyi ABP sinyalleri tahmin edip etmeyeceğini değerlendirmek için eklenmiştir. Bu mimaride ise {128, 256, 512, 1024} LSTM birimi test edilmiştir. Mimarinin yapısı Şekil 7'de gösterilmiştir.


Üçüncü olarak kullanılan modeller de daha yüksek boyutlara sahip dense katmanları kullanılmıştır. Bu, modelin bir otomatik kodlayıcı olarak hareket etmesine ve giriş verilerini gürültüden arındırmasına olanak tanımaktadır. Ayrıca Şekil 7'deki modelin kod çözücü/kodlayıcı yapısı, farklı biyomedikal sinyaller arasında bir kod çözücü görevi görecektir şekilde tasarlanmıştır.

Diğer kullanılan dense katmanlı mimariler ise Şekil 8'de ve Şekil 9'da gösterilmiştir. Çalışmada ek olarak GAN mimarisi de kullanılmıştır.


Generative Adversarial Networks (GAN) fikri 2014 yılında Ian Goodfellow'un arkadaşlarıyla yaptığı bir muhabbet sırasında ortaya atılmış ve ardından bilimsel bir makale olarak yayınlanmıştır. GAN modelinde bir veri üretmek istenilir ve o veriden yeterli sayıda örnek verilirse modele, yine aynı veri tipinde yeni örnekler ürettirebilmektedir. Sisteme binlerce kuş fotoğrafı verilirse sistem, bir kuşun nasıl görünmesi gerektiğini öğrenecek ve yeni kuş fotoğrafları üretecektir. GAN mimarisinde birbirleriyle çekişme halinde bulunan iki farklı yapay sinir ağı bulunmaktadır. Bu yapay sinir ağları Üretken (Generator) ve Ayırt Edici (Discriminator) ağlar olarak adlandırılır. Üretken ağ, gerçekte örtüşen veya gerçeğe benzeyen benzersiz veriler üretirken ayırt edici ağ ise sahte ve gerçek verileri birbirinden ayırt etmeye çalışmaktadır. Bu iki sinir ağı birbirleriyle çekişirken ayırt edici ağ giderek gerçek ve sahte resimleri daha iyi ayırt etmeye başlamaktadır. Üretken ağ ise daha gerçekçi sahte resimler üretimi yapmaktadır. Bu düzen çok güzel bir örnek olan hırsız ve polis ikilisine benzetilmektedir. Vakit ilerledikçe polis, hırsızları bulabilmek için sahte paraların tespitinde daha başarılı olmaktadır. Hırsız ise polisi yenebilmek için daha gerçekçi sahte paralar üretmeye başlar [22].




Şekil 6. LSTM tabanlı model.



Şekil 7. LSTM ve dense tabanlı model.



Şekil 8. Dense tabanlı model.



Şekil 9. Dense tabanlı model-2.

Başarım Değerlendirmesi

Çalışmada birden çok derin öğrenme modeli kullanılmış ve bu modellerin başarımları karşılaştırılmıştır. Kullanılan modellerin mimarilerinden ve detaylarından bir önceki bölümde bahsedilmiştir. Optimize edilmiş parametrelerle en iyi ağ mimarisini belirlemek için birkaç farklı çalışma yapılmıştır. Bu bölümde kullanılan farklı parametrelere göre sonuçlar karşılaştırılacaktır.

LSTM Model

LSTM modellerde birim sayısına, adım sayısına, kullanılan aktivasyon fonksiyonuna ve küme büyüklüğüne göre çalışma gerçekleştirilmiştir. LSTM birimi sayısı için farklı hiperparametre değerleri sırası ile {128, 256, 512, 1024}, {10, 50, 100}, {Doğrusal, ReLU, ELU, SeLU, Sigmoid}, {32, 64, 128} test edilmiştir.

Tablo 1. LSTM model birim sayısına göre başarı performansı

Parametreler	Birim Sayısı	Ortalama Hataların Karesi
Kodlayıcı = LSTM	128	0.0165
Adım Sayısı = 50	256	0.0191
Küme Büyüklüğü = 32	512	0.0287
Aktivasyon = Doğrusal	1024	0.0175

Birim sayısına göre karşılaştırma yapıldığında Tablo 1’de görülmektedir ve birim sayısı arttıkça modelin başarı oranı düşmektedir. Fakat sonuçlarda da görüldüğü üzere 1024 birimde başarı yükselişi söz konusudur. En düşük hata 128 birimde elde edilmiştir. Sonuçlara göre 128 birim için model en optimize sonucu vermektedir.

Tablo 2. LSTM model adım sayısına göre başarı performansı

Parametreler	Eğitim Tur Sayısı	Ortalama Hataların Karesi
Kodlayıcı = LSTM	10	0.114
Birim Sayısı = 128	50	0.0165
Küme Büyüklüğü = 32	100	0.0287

Tablo 2’de LSTM modelin adım sayısına göre başarı performansı karşılaştırılmasında en optimal sonuç 50 adımda görülmektedir. Adım sayısı azaldıkça hata oranının daha fazla olduğunu söyleyebiliriz. Ancak adım sayısı yükselince ise hata oranı azalmaya rağmen yavaş bir şekilde artmaktadır.

Tablo 3. LSTM model küme büyüklüğüne göre başarı performansı

Parametreler	Küme Büyüklüğü	Ortalama Hataların Karesi
Kodlayıcı = LSTM	32	0.0165
Birim Sayısı = 128	64	0.0168
Adım Sayısı = 50	128	0.0186

Küme büyüklüğü parametre güncellemesinin gerçekleştiği ağa verilen alt örneklerin sayısı olarak tanımlanmaktadır. Toplu boyut için iyi bir varsayılan değer 32 olabilir. Ayrıca 32, 64, 128, 256 ve benzeri değerler de kullanılmaktadır. Çalışma da Tablo 3’teki küme büyüklüğüne göre başarı performansı karşılaştırılmasında farklı değerlerde denenmiş en optimal sonuç 32 değerinde elde edilmiştir.


Tablo 4. LSTM model aktivasyon fonksiyonuna göre başarı performansı

Parametreler	Aktivasyon Fonksiyonu	Ortalama Hataların Karesi
Kodlayıcı = LSTM	Doğrusal	0.0165
Birim Sayısı = 128	ReLU	0.0284
Adım Sayısı = 50	ELU	0.0170
Küme Büyüklüğü = 32	SeLU	0.0200
	Sigmoid	0.0240

Aktivasyon fonksiyonları nöronların toplam fonksiyonunda üretilen çıktılarının nasıl bir değişimden geçmesi gerektiğini belirlemede kullanılmaktadır. Tablo 4’te görüldüğü gibi “Doğrusal (Linear)” aktivasyon fonksiyonu en optimal sonucu vermiştir. Tüm deneyler sonucunda elde edilen en optimal sonucu veren hiperparametreler şöyledir;

- Birim sayısı = 128,
- Adım sayısı = 50,
- Küme büyüklüğü = 32,
- Aktivasyon fonksiyonu = Doğrusal.

Şekil 10’da eğitilen LSTM modelin tahmin grafiği verilmiştir.



Şekil 10. LSTM Modelin Tahmin Grafiği.

LSTM + Dense Model

Çalışma da LSTM ve dense katmanlarından oluşan hibrit bir model de tercih edilmiştir. Birim sayısına, adım sayısına ve küme büyüklüğüne göre çalışma gerçekleştirilmiştir. LSTM birimi sayısı için farklı hiperparametre değerleri sırası ile {128, 256, 512,1024}, {10, 50, 100}, {32, 64, 128} test edilmiştir.

Geliştirilmiş olan hibrit model de LSTM model gibi 128 birim en iyi sonucu vermiştir. Tablo 5'te LSTM ve dense modelin birim sayısına göre başarı karşılaştırılması incelendiğinde birim sayısı arttıkça başarı oranı da doğrusal bir şekilde düşmektedir. En optimal sonuç en düşük birim sayısındadır.

Tablo 5. LSTM+Dense model birim sayısına göre başarı performansı

Parametreler	Birim Sayısı	Ortalama Hataların Karesi
Kodlayıcı = LSTM+Dense	128	0.0258
Adım Sayısı = 50	256	0.0278
Küme Büyüklüğü = 32	512	0.0279
Aktivasyon = ReLU	1024	0.0302

Tablo 6'da verilen LSTM ve D modelin adım sayısına göre başarı karşılaştırılması sonuçlardan yola çıkarak, 50 adımlık eğitimin en iyi sonucu verdiğini söyleyebiliriz. Adım sayısı azaldıkça ve arttıkça hata oranının yükselmesi başarımın düştüğünü göstermektedir.

Tablo 6. LSTM+Dense model adım sayısına göre başarı performansı

Parametreler	Eğitim Tur Sayısı	Ortalama Hataların Karesi
Kodlayıcı = LSTM+Dense	20	0.0398
Birim Sayısı = 128	50	0.0258
Küme Büyüklüğü = 32	100	0.0287
Aktivasyon = ReLU		

Ağa verilen alt örneklerin sayısında bir önceki modele benzer olarak 32 küme büyüklüğü en iyi sonucu vermektedir. Küme boyutu büyüdükçe hata oranının arttığı Tablo 7'de görülmektedir.


Tablo 7. LSTM+Dense model küme büyüklüğüne göre başarı performansı

Parametreler	Küme Büyüklüğü	Ortalama Hataların Karesi
Kodlayıcı = LSTM+Dense	32	0.0258
Birim Sayısı = 128	64	0.0275
Adım Sayısı = 50	128	0.0283
Aktivasyon = ReLU		

Hata oranı ve küme büyüklüğü doğru orantılıdır. Elde edilen sonuçlara göre modelin en optimal sonuç veren hiperparametreleri şöyledir;

- Birim sayısı = 128,
- Adım sayısı = 50,
- Küme büyüklüğü =32,
- Aktivasyon fonksiyonu = ReLU.

Şekil 11'da eğitilen LSTM ve Dense katmanlarından oluşan modelin tahmin grafiği verilmiştir.



Şekil 11. LSTM + Dense Modelin Çıktı Grafiği.

Dense Katmanlı Model

Yoğunluk (dense), çoğu durumda çalışan standart bir katman türüdür. Yoğun bir katmanda, önceki katmandaki tüm düğümler mevcut katmandaki düğümlere bağlanır. Çalışmada yoğunluk katmanından oluşan iki adet mimari bulunmaktadır. Farklı hiperparametrelere göre sonuçlar elde edilmiş ve en optimal sonuç sunulmuştur.

Çalışma sonuçları Tablo 8'de gösterildiği üzere dense modeli için küme büyüklüğüne göre başarı performansı incelendiğinde en optimal sonuç 128 küme büyüklüğünde alınmıştır. Küme boyutu büyüdükçe doğrusallıkta doğru orantılı bir şekilde büyümektedir.

Tablo 8. Dense modeli için küme büyüklüğüne göre başarı performansı

Parametreler	Küme Büyüklüğü	Ortalama Hataların Karesi
Kodlayıcı = Dense	32	0.0176
Adım Sayısı = 50	64	0.0142
Aktivasyon = Sigmoid	128	0.0141

Sigmoid en yaygın kullanılan aktivasyon fonksiyonlarından birisidir ve [0,1] aralığında çıktı üretmektedir. Çalışmada, Tablo 9'da dense modeli için aktivasyon fonksiyonuna göre başarı performansı karşılaştırılmasında en optimal sonuç "Sigmoid" aktivasyon fonksiyonu tarafından üretilmektedir.

Tablo 9. Dense modeli için aktivasyon fonksiyonuna göre başarı performansı

Parametreler	Aktivasyon Fonksiyonu	Ortalama Hataların Karesi
Kodlayıcı = Dense	Doğrusal	0.0176
Adım Sayısı = 50	ReLU	0.0167
Küme Büyüklüğü = 128	Sigmoid	0.0141

Önerilen birinci dense katmanlı mimari modelinin çıktısı Şekil 12'de gösterilmiştir

Model: "sequential"

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 1000, 128)	384
dropout (Dropout)	(None, 1000, 128)	0
batch_normalization (Batch Normalization)	(None, 1000, 128)	512
dense_1 (Dense)	(None, 1000, 256)	33024
dropout_1 (Dropout)	(None, 1000, 256)	0
batch_normalization_1 (Batch Normalization)	(None, 1000, 256)	1024
dense_2 (Dense)	(None, 1000, 512)	131584
dropout_2 (Dropout)	(None, 1000, 512)	0
batch_normalization_2 (Batch Normalization)	(None, 1000, 512)	2048
dense_3 (Dense)	(None, 1000, 256)	131328
dropout_3 (Dropout)	(None, 1000, 256)	0
batch_normalization_3 (Batch Normalization)	(None, 1000, 256)	1024
dense_4 (Dense)	(None, 1000, 128)	32896
dropout_4 (Dropout)	(None, 1000, 128)	0
batch_normalization_4 (Batch Normalization)	(None, 1000, 128)	512
dense_5 (Dense)	(None, 1000, 1)	129

Total params: 334,465
Trainable params: 331,905
Non-trainable params: 2,560

Şekil 12. Birinci modelin mimarisi ve parametreleri.

İkinci dense katmanlı mimarisi ise ek olarak dense katmanlarından oluşmaktadır. Birinci model de olduğu gibi küme büyüklüğü ve aktivasyon fonksiyonu üzerinden karşılaştırma yapılmıştır. En optimal sonuç seçilmiştir.

Tablo 10'da görüldüğü gibi dense modeli-2 için küme büyüklüğüne göre başarı performansı incelendiğinde en optimal sonuç 128 değerinde elde edilmiştir fakat bu model diğer önerilen modellere göre düşük sonuç vermiştir.

Tablo 10. Dense katmanlı model-2 için küme büyüklüğüne göre başarı performansı

Parametreler	Küme Büyüklüğü	Ortalama Hataların Karesi
	32	0.283
Kodlayıcı = Dense		
Adım Sayısı = 50	64	0.289
Aktivasyon = Sigmoid	128	0.281

Tablo 11'de sunulduğu üzere dense modeli-2 için aktivasyon fonksiyonuna göre başarı performansı karşılaştırılmasında en başarılı aktivasyon fonksiyonu "Sigmoid" olmuştur.

Tablo 11. Dense katmanlı model-2 için aktivasyon fonksiyonuna göre başarı performansı

Parametreler	Aktivasyon Fonksiyonu	Ortalama Hataların Karesi
	Doğrusal	0.318
Kodlayıcı = Dense		
Adım Sayısı = 50	ReLU	0.312
Küme Büyüklüğü = 128	Sigmoid	0.281

Modelin başarımında en optimal sonuçlar sunulmuştur. İkinci modelin mimarisi Şekil 13'de ki gibidir;

Model: "sequential_1"

Layer (type)	Output Shape	Param #
dense_12 (Dense)	(None, 1000, 128)	384
dropout_7 (Dropout)	(None, 1000, 128)	0
batch_normalization_7 (Batch Normalization)	(None, 1000, 128)	512
dense_13 (Dense)	(None, 1000, 256)	33024
dropout_8 (Dropout)	(None, 1000, 256)	0
batch_normalization_8 (Batch Normalization)	(None, 1000, 256)	1024
dense_14 (Dense)	(None, 1000, 512)	131584
dense_15 (Dense)	(None, 1000, 1)	513

Total params: 167,041
Trainable params: 166,273
Non-trainable params: 768

Şekil 13. İkinci modelin mimarisi ve parametreleri.

Önerilen modellerin en iyi sonuçları veren hiperparametreleri şöyledir;

- Birinci model için;
 - Adım sayısı = 50,
 - Küme büyüklüğü = 128,
 - Aktivasyon fonksiyonu = Sigmoid.
- İkinci model için;
 - Adım sayısı = 50,
 - Küme büyüklüğü = 128,
 - Aktivasyon fonksiyonu = Sigmoid.

GAN Model

Çalışmada kullanılan modelde farklı metrikler ve aktivasyon fonksiyonları kullanılmıştır. 2900 ve 10000 adımda eğitilen iki model eğitilmiş ve bu eğitimlerin sonuçları karşılaştırılmıştır. Öncelikle karşılaştırma yapılan metrik şöyledir;

- İkili çapraz entropi: İkili çapraz entropi kayıp fonksiyonu bir örneği iki sınıftan birisine ait olarak sınıflandırılan problemlerde kullanılmaktadır. Örnek verilecek olursa bir görüntünün kedi veya köpek olduğu belirlenmek isteniyorsa devreye bu kayıp fonksiyonu girmektedir. Köpek ise 1, kedi ise 0 olarak işaretleyebilmektedir.
- Sızdıran ReLU: Sızdıran ReLU özellikle küçük ağlar için önem arz etmektedir. Küçük ağlarda normal ReLU kullanıldığında geri yayılım yapmak için gradyan elde etmek nerdeyse imkansızdır. Sızdıran ReLU ile ağ tüm değerlerin sıfır olduğu alanlarda bile gradyana sahip olabilir.

GAN mimarisine ait olan ayırt edici ağı yapısı Şekil 14'te, üretken ağı mimarisi ise Şekil 15'te gösterilmiştir.

Model: "sequential_9"

Layer (type)	Output Shape	Param #
flatten_5 (Flatten)	(None, 2000)	0
dense_25 (Dense)	(None, 512)	1024512
leaky_re_lu_17 (LeakyReLU)	(None, 512)	0
dense_26 (Dense)	(None, 256)	131328
leaky_re_lu_18 (LeakyReLU)	(None, 256)	0
dense_27 (Dense)	(None, 1)	257

Total params: 1,156,097
Trainable params: 1,156,097
Non-trainable params: 0

Şekil 14. GAN ayırt edici ağ mimarisi ve parametreleri.

Model: "sequential_10"

Layer (type)	Output Shape	Param #
dense_28 (Dense)	(None, 256)	25856
leaky_re_lu_19 (LeakyReLU)	(None, 256)	0
batch_normalization_9 (Batch Normalization)	(None, 256)	1024
dense_29 (Dense)	(None, 512)	131584
leaky_re_lu_20 (LeakyReLU)	(None, 512)	0
batch_normalization_10 (Batch Normalization)	(None, 512)	2048
dense_30 (Dense)	(None, 1024)	525312
leaky_re_lu_21 (LeakyReLU)	(None, 1024)	0
batch_normalization_11 (Batch Normalization)	(None, 1024)	4096
dense_31 (Dense)	(None, 2000)	2050000
reshape_3 (Reshape)	(None, 1000, 2)	0

Total params: 2,739,920
Trainable params: 2,736,336
Non-trainable params: 3,584

Şekil 15. GAN üretken edici ağ mimarisi ve parametreleri.

2900 adımla eğitilen GAN'dan elde edilen sonuçlar, [-0.8,1.0] yerine [0.02,0.52] arasında değişen, 10000 adımla eğitilen GAN'dan elde edilen sonuçlara göre çok daha yakındır. Elde edilen sonuçlar Tablo 12 ve Tablo 13'te gösterilmiştir.


Tablo 12. GAN mimarisi 2900 adım eğitim sonuçları

Parametreler	İkili Çapraz Entropi
Kodlayıcı = GAN Adım Sayısı = 2900 Küme Büyüklüğü = 32 Aktivasyon = Tanh - Sigmoid Kayıp = İkili Çapraz Entropi	2.382


Tablo 13. GAN mimarisi 10000 adım eğitim sonuçları

Parametreler	İkili Çapraz Entropi
Kodlayıcı = GAN Adım Sayısı = 10000 Küme Büyüklüğü = 32 Aktivasyon = Tanh - Sigmoid Kayıp = İkili Çapraz Entropi	1.014

İlgili sonuçlara ait tahmin grafikleri de Şekil 16 ve Şekil 17'de gösterilmiştir.



Şekil 16. GAN tahmin sonuçları.



Şekil 17. GAN adım sayısına göre tahmin karşılaştırması (Soldaki 10000, sağdaki 2900)

Tüm sonuçlar göz önüne alındığında ABP değerlerinden SBP ve DBP tahminleri yapılabilmektedir. Denklem 1 ve Denklem 2'de verilen formüller ile SBP ve DBP tahmini yapıldığında elde edilen sonuçlarda en iyi sonuç veren model için MAE değeri SBP için 2.19, DBP için ise 0.941'tür.

BHS (British Hypertension Society) Standardı

İngiliz Hipertansiyon Topluluğu (BHS), literatürde bir metrik olarak sıklıkla kullanılan BP ölçüm cihazlarını ve yöntemlerini değerlendirmek için bir standart olarak hareket etmek üzere yapılandırılmış bir protokol [4] tanıtmıştır. BHS standardı, sonuçları esas olarak üç kategoriye ayırırken, performansı mutlak hataya dayalı olarak değerlendirmektedir; Derece A, B ve C. Dereceler, tahmin mutlak hatalarının yüzde kaçının sırasıyla 5 mmHg, 10 mmHg ve 15 mmHg'nin altına (küçük veya eşit) düştüğü ölçülerek sağlanmaktadır. Bir algoritmanın veya boru hattının belirli bir derece elde etmesi için üç kategorinin de kriterlerini karşılaması gerektiğinden bahsetmek gerekmektedir. Ayrıca C Derecesi gereksinimlerini karşılayamayan çalışmalar için D Derecesi vardır[4].

BHS standardına göre ABP için ortalama hataların karesi hemen hemen tüm tahminler için A seviyesi eşiği olan 5

mmHg'nin altında veya ona eşit olduğu görülebilmektedir. BHS standardına göre ABP sınıflandırması sonuçları Tablo 14'te gösterilmiştir.

Tablo 14. BHS standardına göre ABP sınıflandırması

		Kümülatif Hata Oranı		
		≤5mmHg	≤10mmHg	≤15mmHg
Gerçekleştirilen Çalışma Sonuçları	ABP	91.35%	98.35%	98.85%
	A Seviye	60%	80%	95%
BHS Standartları	B Seviye	50%	75%	90%
	C Seviye	40%	65%	85%

AAMI (Association for the Advancement of Medical Instrumentation) Standardı

Tıbbi Aletleri Geliştirme Derneği (AAMI), BP ölçüm cihazlarını ve algoritmalarını değerlendirmek için BHS ile benzer bir standart [4] önermiştir. Bu standarda göre, BP ölçüm sistemlerinin sırasıyla 5 mmHg ve 8 mmHg'den küçük veya eşit büyüklükte (mutlak değer) bir Ortalama Hatası (ME) ve Standart Sapması (STD) olmak zorundadır. Ayrıca değerlendirilecek denek sayısı 85 veya daha fazla olmalıdır.

Tablo 15'te sunulduğu gibi AAMI standardına göre ABP sınıflandırması, modelden gelen tahminler, AAMI standardının her iki kategorisini de karşılamaktadır ve kriterlerle büyük bir marj tutmaktadır.

Tablo 15. AAMI standardına göre ABP sınıflandırması

		ME	SS	Örnek Sayısı
Sonuçlar	ABP	0.09	0.94	26,870
AAMI Standart		≤5 mmHg	≤8 mmHg	≥85

Bulgular ve Tartışma

Çalışmada elde edilen tahmin sonuçlarından ve elde edilen MSE kayıp değerlerinden, bu problem için en uygun model, 128 LSTM biriminden oluşan modeldir. LSTM modeli, ABP sinyalinin hem genliğini hem de periyodikliğini tahmin etmiştir. LSTM+Dense katmanlarından oluşan model, genliği daha sonraki zaman adımlarında tahmin etme konusunda sınırlı yetenek göstermiştir, ancak genel sinyal tahmininde bir takım gürültüler mevcuttur. Dense katmanlı modeller, yalnızca periyodiklik verilerini yakalayabilmiş ve ABP sinyalinin genliğini tahmin edememiştir.

GAN tarafından oluşturulan üretken modeli, ilk veri setine benzeyen modeller üretmeyi başarmıştır. Benzerlik, grafiklerdeki zirvelere ve bunların neredeyse eşit aralıklarla düzenli olarak meydana gelmesine dikkat edilerek fark edilebilmektedir. Gerçek verilerle karşılaştırıldığında, GAN, her bir yerel maksimum kümesi arasındaki eğrilerin düzgünlüğünden yoksundur. Ancak bu, eğitim verilerinin başlangıç boyutunun büyük olmadığını kabul ederek ve bu nedenle modelin özelliklerini geliştirmesine izin vermediği yönünde açıklanabilir.

Elde edilen sonuçlar incelenecek olursa modeller içerisinde en iyi sonuç veren model olan LSTM modelin en büyük

avantajı, temassız bir şekilde elde edilen verilerden ABP tahminini düşük bir hata oranı ile elde etmesidir. Her ne kadar model SBP ve DBP değerlerini tahmin edemiyor olsa da, bir ABP sinyal boyunu tahmin edebilmektedir. Tahmin edilen dalga formu doktorların tıbbi bir teşhis için başvurabilecekleri kadar özellik içermektedir.

Ayrıca önerilen model dünya standartlarında geçerli olan BHS ve AAMI standartlarını da A seviye düzeyinde karşılayacak tahminler üretmiş ve geçerli olduğunu ispatlamıştır. Mevcut yaklaşım, elde edilen sinyallerdeki hareket yapılarını ele alacak şekilde tasarlanmadığından, mevcut sistemi giyilebilir bir cihaz için doğrudan kullanmak zor olacaktır.

Çalışmada 26.870 yetişkin hastadan elde edilen PPG ve ECG sinyallerinden ABP sinyali tahmini yapılmıştır. Elde edilen sonuçlar incelenecek olursa, karmaşık özellik mühendisliği yapılmadan kan basıncı tahmini gerçekleştirme işleminde başarılı sonuçlar elde edilmiştir.

Gerçekleştirilen çalışmanın literatürde ki diğer çalışmalarla karşılaştırılması Tablo 16'da verilmiştir.

Tablo 16. Literatürde ki diğer çalışmalarla karşılaştırılması

Çalışmalar	Veri Seti	Metot	MAE (SBP- DBP)
[12]	MIMIC-II	TPOT	6.52 – 4.19
[13]	MIMIC-II	U-Net	2.728 – 1.166
[14]	MIMIC-II	Kümeleme	2.561 – 2.231
[17]	MIMIC-II	LSTM	4.05 – 2.41
Gerçekleştirilen Çalışma	MIMIC-II	LSTM	2.19 – 0.941

Model çoğunlukla çok temiz sinyaller üzerinde eğitildiğinden, model performansını büyük ölçüde etkileyebilir. Ancak, hareket artefaktı birçok yolla düzeltiler. Sonuç olarak, önerilen model, gerçek zamanlı, invazif olmayan BP izleme uygulamaları için uzaktan izleme sunucularında ve mobil uygulamalarda dağıtım için uygun olabilir.

Sonuçlar

Çalışmanın sonuçları, literatürdeki benzer çalışmalardan önemli ölçüde daha iyi sonuçlar elde ettiğini göstermektedir. Bu başarının ardında, veri ön işleme aşamasından eğitim süresine ve test tekniklerine kadar bir dizi faktörün etkisi olduğu görülmektedir. Önerilen ve eğitim sonucunda kaydedilen derin öğrenme modeli, diğer çalışmalarda görülen örnekler gibi giyilebilir cihazlara entegre edilerek kritik hastalık durumlarında sürekli tansiyon takibi için kullanılabilir. Ancak, bu uygulamanın etkisini çeşitli faktörler etkileyebilir; hastanın uyku durumu, aktivite seviyesi, yaş ve kronik rahatsızlıklar gibi etkenler tansiyon sonuçlarını etkileyebilir. Bu nedenle sürekli tansiyon takibi için uygun bir ortam sağlanmalı ve hastanın özel durumları da dikkate alınmalıdır. Modelin tahmin ettiği arteriyel kan basıncı (ABP) sinyalleri, sistolik ve diyastolik tansiyon tahminlerinin temelini oluşturmaktadır. Arteriyel kan basıncı tahmini, eğitilen modeller aracılığıyla yüksek başarımlı oranlarına ulaşmış ve bu sayede tansiyon türlerinin doğru tahmin edilmesini sağlamıştır. Bu çalışma, sürekli tansiyon izlemesi için önemli bir adım olarak değerlendirilebilir.

Teşekkür

Bu çalışmada, Fırat Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi (FÜBAP) tarafından TEKF.23.29 numaralı proje ile desteklenmiştir. Desteklerinden dolayı FÜBAP birimine teşekkür ederiz.

Kaynaklar

- [1] J. Booth, "A short history of blood pressure measurement," *Proceedings of the Royal Society of Medicine*, vol. 70, no. 11, pp. 793–799, 1977. doi:10.1177/003591577707001112.
- [2] G. Beevers, "ABC of hypertension: Blood pressure measurement," *BMJ*, vol. 322, no. 7292, pp. 981–985, 2001. doi:10.1136/bmj.322.7292.981.
- [3] "High blood pressure ," [www.heart.org](https://www.heart.org/en/health-topics/high-blood-pressure), <https://www.heart.org/en/health-topics/high-blood-pressure> (accessed Oct. 16, 2023).
- [4] "High blood pressure in adults - hypertension: Medlineplus medical encyclopedia," *MedlinePlus*, <https://medlineplus.gov/ency/article/000468.htm> (accessed Oct. 16, 2023).
- [5] "Hypertension," *World Health Organization*, https://www.who.int/health-topics/hypertension#tab=tab_1 (accessed Oct. 16, 2023).
- [6] "Low blood pressure (hypotension)," *Mayo Clinic*, <https://www.mayoclinic.org/diseases-conditions/low-blood-pressure/symptoms-causes/syc-20355465> (accessed Oct. 16, 2023).
- [7] "Know your risk for high blood pressure," *Centers for Disease Control and Prevention*, https://www.cdc.gov/bloodpressure/risk_factors.htm (accessed Oct. 16, 2023).
- [8] "High blood pressure," *Centers for Disease Control and Prevention*, <https://www.cdc.gov/bloodpressure/index.htm> (accessed Oct. 16, 2023).
- [9] M. Holanger, S. E. Kjeldsen, K. Jamerson, and S. Julius, "Smoking and overweight associated with masked uncontrolled hypertension: A hypertension optimal treatment (HOT) sub-study," *Blood Pressure*, vol. 30, no. 1, pp. 51–59, 2020. doi:10.1080/08037051.2020.1787815.
- [10] E. O'Brien, "From measurement to profiles, phenomena and indices: A workshop of the European Society of Hypertension," *Blood Pressure Monitoring*, vol. 10, no. 6, pp. 291–295, 2005. doi:10.1097/00126097-200512000-00001.
- [11] G. Parati et al., "European Society of Hypertension Practice Guidelines for Ambulatory Blood Pressure Monitoring," *Journal of Hypertension*, vol. 32, no. 7, pp. 1359–1366, 2014. doi:10.1097/hjh.0000000000000221.
- [12] S. M. Fati, A. Muneer, N. A. Akbar, and S. M. Taib, "A continuous cuffless blood pressure estimation using tree-based pipeline optimization tool," *Symmetry*, vol. 13, no. 4, p. 686, 2021. doi:10.3390/sym13040686.
- [13] S. Mahmud et al., "A shallow U-net architecture for reliably predicting blood pressure (BP) from Photoplethysmogram (PPG) and Electrocardiogram (ECG) signals," *Sensors*, vol. 22, no. 3, p. 919, 2022. doi:10.3390/s22030919.
- [14] A. Farki, R. Baradaran Kazemzadeh, and E. Akhondzadeh Noughabi, "A novel clustering-based algorithm for continuous and noninvasive cuff-less blood pressure estimation," *Journal of Healthcare Engineering*, vol. 2022, pp. 1–13, 2022. doi:10.1155/2022/3549238.
- [15] L. N. Harfiya, C.-C. Chang, and Y.-H. Li, "Continuous pressure estimation using exclusively photoplethysmography by LSTM-based signal-to-signal translation," *Sensors*, vol. 21, no. 9, p. 2952, 2021. doi:10.3390/s21092952.
- [16] A. L. Goldberger et al., "Physiobank, PhysioToolkit, and PhysioNet," *Circulation*, vol. 101, no. 23, 2000. doi:10.1161/01.cir.101.23.e215.
- [17] A. Paviglianiti, V. Randazzo, E. Pasero, and A. Vallan, "Noninvasive arterial blood pressure estimation using abpnet and vital-ECG," *2020 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, 2020. doi:10.1109/i2mtc43012.2020.9129361.
- [18] J. Kraithl, U. Timm, H. Ewald, and E. Lewis, "Non-invasive measurement of blood components," *2011 Fifth International Conference on Sensing Technology*, 2011. doi:10.1109/icsenst.2011.6136976.
- [19] "A wireless heart rate monitoring system based on photoplethysmography (PPG) technique," *Strad Research*, vol. 7, no. 9, 2020. doi:10.37896/sr7.9/011.
- [20] Joon Lee et al., "Open-access mimic-II database for Intensive Care Research," *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2011. doi:10.1109/iembs.2011.6092050.
- [21] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- [22] I. Goodfellow et al., "Generative Adversarial Networks," *Communications of the ACM*, vol. 63, no. 11, pp. 139–144, 2020. doi:10.1145/3422622.