

Yenidoğan Laboratuvar Bulgularında LSTM Tabanlı Derin Öğrenme Ağı ile Zaman Serisi Analizi

Mahmut Çevik^{1*}, Mücahit Cihan², Nezahat Yılmaz³, Murat Konak⁴, Hanifi Soylu⁵ ve Murat Ceylan⁶

^{1*} AIVISIONTECH Elektronik Yazılım A.Ş., Konya, Türkiye (mahmut@aivisiontech.com) (ORCID: 0009-0001-8630-9564)

² Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Konya, Türkiye (mcihan@ktun.edu.tr) (ORCID: 0000-0002-1426-319X)

³ Selçuk Üniversitesi, Tıp Fakültesi, Çocuk Sağlığı ve Hastalıkları Ana Bilim Dalı, Konya, Türkiye (nzhtylmz.42@gmail.com) (ORCID: 0000-0002-1214-9692)

⁴ Selçuk Üniversitesi, Tıp Fakültesi, Dahili Tıp Bilimleri Bölümü, Konya, Türkiye (drmkonak@hotmail.com) (ORCID: 0000-0001-8728-4541)

⁵ Selçuk Üniversitesi, Tıp Fakültesi, Dahili Tıp Bilimleri Bölümü, Konya, Türkiye (hasoylu@hotmail.com) (ORCID: 0000-0003-0367-859X)

⁶ Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Konya, Türkiye (mceylan@ktun.edu.tr) (ORCID: 0000-0001-6503-9668)

Türkçe Özet – Yenidoğan yoğun bakımında kalan bebeklerde laboratuvar bulguları ve hayati değerler düzenli olarak takip edilmeli ve değerlendirilmelidir. Bebek kan damarları normal bir insana göre oldukça zayıf ve incedir. Aynı zamanda kan hacminin çok düşük olması sebebi ile sürekli olarak kan tahlili yapılamamakta veya alınan kan yetersizliği ile istenen tüm laboratuvar bulguları elde edilememektedir. Özellikle yenidoğan yoğun bakımında kalan ve diğer bebeklere göre dezavantajlı bulunan prematüre bebeklerde (preterm) bu olumsuzluklar daha sık yaşanmakta ve bunlara ek olarak preterm morbiditesinin çok daha yüksek olduğu da bilinmektedir. Bu çalışmada bebeklerden belirli bir zaman içerisinde elde edilen laboratuvar bulgularını değerlendirilerek ileriye yönelik tahminler yapan bir zaman serisi analizi gerçekleştirilmiştir. Zaman serisi analizi yöntemi olarak LSTM ağı mimarisine dayalı derin öğrenme modeli kullanılmıştır. Bu çalışma için 22 adet bebekten 161 veri elde edilmiş ve her bir bebek için belirli bir zaman içerisinde alınan laboratuvar bulguları zaman serisi verileri haline getirilmiştir. Laboratuvar bulguları olarak sıklıkla takip edilen CRP, hemoglobin ve bilirubin değerleri seçilmiştir. Her bebek için oluşturulan zaman serisi verileri ile LSTM modeli eğitilmiştir. LSTM modelinin sonuçları incelendiğinde CRP değerinin tahmininde doğruluk değerinin %29.09'da kaldığı, en yüksek tahmin sonucunun ise %43.63 ile hemoglobin değerlerinde elde edildiği gözlemlenmiştir. Bilirubin değerleri için doğruluk oranı ise %36.36'dır. Kısıtlı veri seti ile elde edilen bu sonuçların umut vaat ettiği ve gelecek çalışmalar için önemli olduğu değerlendirilmiştir.

Anahtar Kelimeler – Zaman Serisi Analizi, LSTM, Derin Öğrenme, Veri Tahmini, CRP, Hemoglobin, Bilirubin, Prematüre Morbiditesi

Atf: Çevik, M., Cihan, M., Yılmaz, N., Konak, M., Soylu, H., Ceylan, M. (2023) Yenidoğan Laboratuvar Bulgularında LSTM Tabanlı Derin Öğrenme Ağı ile Zaman Serisi Analizi. International Journal of Multidisciplinary Studies and Innovative Technologies, 7(2): 68-73.

Time Series Analysis with LSTM Based Deep Learning Network in Neonatal Laboratory Findings

Extended Abstract

Research Problem/Questions – Laboratory findings and vital values should be monitored regularly in babies hospitalized in neonatal intensive care. Infant blood vessels are quite weak compared to a normal person. At the same time, due to the very low blood volume, blood analyses cannot be performed continuously or all the desired laboratory findings cannot be obtained with insufficient blood. Especially in premature babies (preterm) who stay in neonatal intensive care and are disadvantaged compared to other babies, these problems are experienced more frequently and in addition to these, it is known that preterm morbidity is much higher.

Short Literature Review – Time series analyses are used in many fields such as finance, climate, meteorology, medical and military. Time series analysis, which started to develop with methods that produce solutions for linear data, now uses advanced methods such as deep learning architectures, transformer architectures and machine learning. In the medical field, time series analysis has many different uses. In this study, a time series analysis that makes forward-looking predictions by evaluating

laboratory findings obtained from infants over a certain period of time has been performed. Deep learning model based on LSTM network architecture is used as time series analysis method.

Methodology – In this study, 161 data were obtained from 22 healthy babies with sepsis, rds, nec, ikk, diaphragmatic, pneumothorax diseases and 22 healthy babies in the neonatal intensive care unit and the laboratory findings obtained within a certain period of time for each baby were converted into time series data. In the time series group created for each of 22 babies, minimum 5 and maximum 15 laboratory findings were obtained. CRP, hemoglobin and bilirubin values, which are frequently monitored, were selected as laboratory findings. The LSTM model was trained with the time series data created for each baby.

Results and Conclusions – When the model evaluation results were analyzed, it was observed that the accuracy of CRP data was very low. Since CRP values are a parameter that increases when infection increases in the body, it is a parameter that is not frequently monitored especially in healthy or non-infected infants. Therefore, CRP was the parameter with the least up-to-date data during this process. When these evaluations were examined, the parameter estimated with the highest accuracy was hemoglobin with an accuracy of 43.63% and a mean squared error of 7.37. CRP parameter showed the lowest performance with 2274.9% mean squared error and 29.09% accuracy. Bilirubin remained at 36.36% accuracy level. Data acquisition and model development processes are ongoing and these initial results are promising for future studies.

Keywords – Time Series Analysis, LSTM, Deep Learning, Data Prediction, CRP, Hemoglobin, Bilirubin, Premature morbidity

Citation: Çevik, M., Cihan, M., Yılmaz, N., Konak, M., Soylu, H., Ceylan, M. (2023) Time Series Analysis with LSTM Based Deep Learning Network in Neonatal Laboratory Findings. International Journal of Multidisciplinary Studies and Innovative Technologies, 7(2): 68-73.

I. GİRİŞ

Zaman seri analizi mevcut ve geçmişteki verilerin değişim trendlerini göz önünde bulundurarak ileriye yönelik tahminler yapan sistemlerdir [1]. Zaman serisi analizi çözümleri finans [2], iklim [3], medikal [4] ve meteoroloji [5] gibi birçok farklı alanda kullanılmaktadır. Zaman serisi analizi yöntemleri özellikle bilgisayar teknolojilerindeki hesaplama kabiliyetlerinin artırılması ile birlikte önemli ilerleme katetmiştir.

Zaman serisi analizi daha çok lineer veriler için çözümler üreten Autoregressive Moving Average (ARMA) [6] ve ARMA yöntemine verilerin durağan olmayan zamansal farklılıklarını da dikkate alan entegrasyon teriminin eklenmesi ile geliştirilen Autoregressive Integrated Moving Average (ARIMA) [7] yöntemleri ile gelişmeye başlamıştır. Gerçek dünya verilerinin lineer olmama durumları ve makine öğrenmesi yöntemlerinin gelişmesi ile beraber zaman serisi tahmini için birçok farklı makine öğrenmesi algoritması geliştirilmiştir [8]. Derin öğrenme yöntemleri her sorun için özelleştirilebilir ağ yapılarına sahip olmaları ve veri kümelerinin anlamsal bağlarını çözebilecek özellik çıkarma işlemlerini sinirsel ağları ile gerçekleştirebilmeleri sayesinde zaman seri analizi verileri için uygun çözümler olmuştur [9]. Buna ek olarak özellikle metin üretimde kullanılan ve görüntü üretimi ile ilgili alanlarda da oldukça popüler olan denetimsiz transformers mimarileri zaman serisi verileri için de kullanım alanı bulmuştur [10]. LSTM (uzun kısa süreli bellek) tabanlı derin öğrenme mimarileri, ağ yapılarındaki tekrarlayan sinir ağları ile verilerin geçmiş dönem paternlerini öğrenme ve aktarma kabiliyetine sahiptir. LSTM tabanlı mimariler ile gerçekleştirilmiş birçok zaman seri analizi çalışması mevcuttur [11], [12]. Chimmula ve Zang [13] yapmış oldukları bu çalışmada Kanada sağlık otoritesi tarafından yayınlanan Covid-19 vaka sayısı verileri ile bir LSTM modeli eğitilerek ileriye yönelik vakaların yayılım riskini tahmin ettiren bir çalışma gerçekleştirmişlerdir.

Gerçekleştirilen bu çalışma yenidoğan bakım ünitesinde yatan prematüre bebeklerin laboratuvar bulguları olan CRP,

bilirubin ve hemoglobin değerlerinin LSTM tabanlı bir derin öğrenme modeli ile bir sonraki kan tahlili sonuçlarını tahmin etmeyi amaçlayan bir zaman seri analizi yöntemi sunmaktadır. Dünya sağlık örgütü (WHO) [14] verilerine göre dünya üzerinde her yıl 15 milyona yakın bebek erken doğmakta ve 1 milyondan fazla bebek bir yaşını tamamlayamadan ölmektedir. Türkiye’de T.C. Sağlık Bakanlığının açıkladığı [15] verilere göre 127.687 bebek erken doğmuş ve bu sayı tüm yenidoğan bebeklerin %12,2’sini oluşturmaktadır. TÜİK [16] verilerine göre Türkiye’deki bebek mortalite oranı binde 9,2 olarak kaydedilmiştir. Yenidoğan prematüre bebekler için ilk 28 gün hayatta kalabilmeleri açısından çok önemlidir. Bu önemli periyot içerisinde prematüre bebeklerin yaşamsal parametreleri ve laboratuvar bulguları düzenli olarak takip edilmek zorundadır.

Prematüre bebeklerde kan alma işlemi bebeklerin damar kalınlıklarının daha dar olması gibi sebeplerden dolayı çok acı verici olabilir, bu acı ve buna bağlı morbiditeyi azaltmak için birçok çalışma yapılmıştır [17]. Aynı zamanda bebeklerin kan hacimleri normal bir insana göre oldukça zayıf olduğu için daha az kan alınabilmekte ve bu yüzden laboratuvar testleri bazen yanıltıcı olabilmektedir.

Bu çalışmanın hedefi bebeklerin geçmiş laboratuvar bulguları takip edilerek ileriye yönelik kan tahlili parametreleri tahmini yapan bir zaman seri analizi yöntemi oluşturmaktır. Bu sayede sağlık çalışanlarının karar verme süreçlerinde destek olunması amaçlanmaktadır.

II. MATERYAL VE METOT

Bu bölümde ilk olarak veri seti elde etme süreçleri, veri setinin yapısı ve dağılımları hakkında bilgi verilecektir. Sonrasında zaman seri analizi açıklanacak ve LSTM ağları ile oluşturulan model tanıtılacaktır.

A. Veri Seti

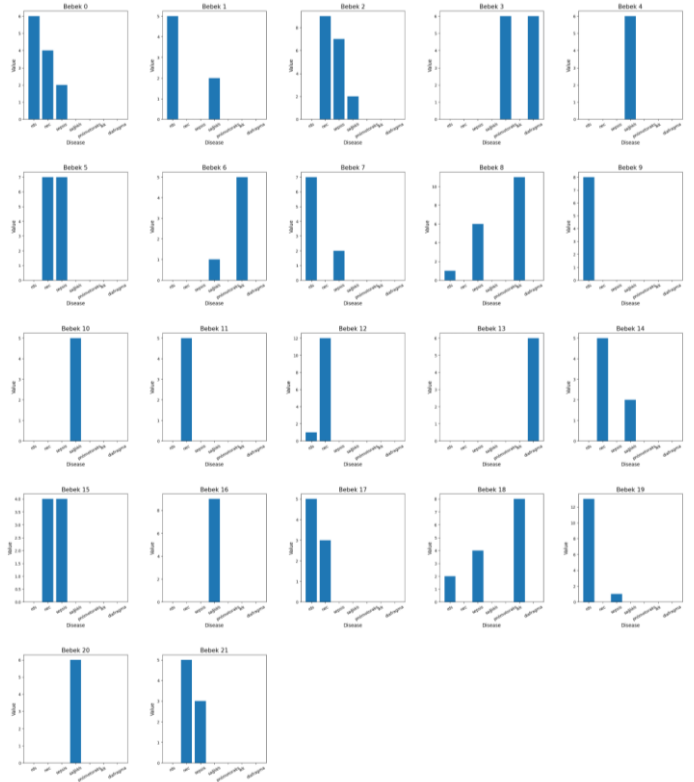
Yenidoğan premature bebeklerin laboratuvar bulgularına ait kan tahlilleri, TÜBİTAK – 1001- Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı (Proje No:

122E021) kapsamında Selçuk Üniversitesi, Tıp Fakültesi, Yenidoğan Yoğun Bakım Ünitesindeki yenidoğanlardan elde edilmiştir. Proje araştırması, Etik Kurul Onayı (2022/125) ile elde edilmiştir.

Yenidoğan yoğun bakımında yatan Sepsis, RDS, NEC, Pnömotoraks, İntrakranial kanama (IKK), diafragma ve sağlıklı (hafif solunum sıkıntısı olan bebekler sağlıklı olarak değerlendirilmiştir) olarak sınıflandırılmış 22 bebek çalışmaya dahil edilmiştir. Çalışma süresince bebeklerin kan tahlili sonuçları olan CRP, bilirubin ve hemoglobin değerleri kaydedilmiştir.

- CRP: C-reaktif protein (CRP) vücutta iltihap olup olmadığını veya derecesini ölçmeye yarayan bir kan testidir. Özellikle yenidoğan prematürelde sepsis (kan zehirlenmesi) veya daha lokal olarak beyin zarı, solunum veya idrar yolları enfeksiyonları gibi rahatsızlıkların erken tespiti için CRP değerleri sürekli olarak takip edilmektedir.
- Bilirubin: Bilirubin değeri kanda işlevi biten kırmızı kan hücrelerinde bulunan hemoglobinin yıkımı sonucunda ortaya çıkan bir maddedir. Bilirubin kırmızı kan hücrelerinin yıkımından sonra kana karışır ve karaciğerlerde işlenerek gaita (dışkı) yoluyla vücuttan atılır. Özellikle prematüre bebeklerde karaciğerlerin tam olarak gelişmemesi bilirubin değerlerinin olması gerekenden çok yüksek olmasına sebep olmaktadır. Bu durum en sık bilinen sarılık gibi birçok rahatsızlığa kapı aralamaktadır. Bu yüzden prematüre bebeklerde total bilirubin değeri sürekli olarak takip edilmektedir.
- Hemoglobin: Hemoglobin, kanda bulunan kırmızı kan hücrelerinde (alyuvarlar) oksijen iletiminden sorumlu olan proteindir. Akciğerler ile solunan havada bulunan oksijenin hücrelere taşımınının %97'sini hemoglobin sağlamaktadır. Yenidoğan prematürelde normal bir insan göre kan hacmi çok düşüktür, ayrıca hastalıklarına göre vücudunda bulunan kanın 1/3'üne kadarı nakil yolla alınmış olabilir. Bu yüzden özellikle anemi (kansızlık) gibi hastalıkların teşhisinde hemoglobinin değerinin takibi gereklidir.

22 bebeğin her biri için oluşturulan zaman seri grubunda bebeklerin en az 5 en çok 15 adet laboratuvar bulgusu elde edilmiştir. Bulguları toplanan bebeklerin verilerinin kaydedildiği anlarda sahip olduğu hastalıkların dağılımları Şekil 1'de görülmektedir. Bebekler birden fazla hastalığa aynı anda sahip olabileceği gözden kaçmamalıdır.



Şekil 1. 21 bebeğin hastalık dağılımları(kan tahlilleri alındığında sahip oldukları hastalıkların sayısı) yatay eksenler sırayla rds, nec, sepsis, sağlıklı, pnömotoraks, ikk, diafragma etiketlerine sahiptir. Düşey 0-12 arasındadır.

Bebeklerden elde edilen verilerin hastalıklara dağılımı Tablo 1'de görülmektedir.


Tablo 1. Elde Edilen Verilerin Hastalıklara Dağılımı

Sepsis	RDS	NEC	Pnö	İKK	Diafragma	Sağlıklı
36	48	54	6	25	12	33

22 Bebekten elde edilen laboratuvar bulguları veri seti toplam 161 veri içermektedir.

B. LSTM

Özellikle dil işleme ve zaman serisi verileri gibi geçmiş verilerin hafızada tutulması ile sonuç üretilmesi beklenen problemlerde Özyinelemeli Sinir Ağları (RNN) evrimsel sinir ağlarına göre oldukça başarılı sonuçlar vermektedir. RNN yapısı geçmiş bir nöron katmanında çıkış değerinin aynı nöronda tekrar giriş olarak kullanılmasıyla bir hafıza görevi üstlenmektedir. Şekil 2'de RNN sinir ağı yapısına ait en küçük yapı birimi olan bir hücre görülmektedir.




Şekil 2. RNN Sinir Ağı Yapısına ait En Küçük Birim (Hücre)

Burada h_{t-1} hücrenin bir önceki çıkışını, x_t yeni gelen girişi ve h_t çıkışı temsil etmektedir. Matematiksel ifadesi şu şekildedir:

$$h_t = \tanh(W_h * h_{t-1} + W_i * X_t) \quad (1)$$

Burada W_h gizli katmanın ağırlığını W_i giriş katmanının ağırlığını temsil etmektedir.

Veri setinin büyüdüğü ve verideki özelliklerin artmaya başladığı durumlarda RNN yapılarının hafızası eksik kalmaktadır, aynı zamanda RNN gradyan patlaması problemi de yaşamaktadır, bu durum bilginin daha ağır ilk nöronlarında kaybolmasına yol açmaktadır. Sepp Hochreiter ve Jürgen Schmidhuber [18] RNN'lerin bu temel problemlerini çözmek için LSTM ağını geliştirmişlerdir. LSTM ağları RNN'lere benzer yapılara sahiptir. Giriş, çıkış kısımlarına ek olarak LSTM'lerde unutmaya katmanı bulunmaktadır. Şekil 3'de LSTM yapısı görülmektedir.



Şekil 3. LSTM Sinir Ağı Yapısına ait En Küçük Birim (Hücre)

RNN'de olduğu gibi giriş ve çıkışlar aynı temsil edilmektedir. X_t giriş bilgisi ve h_t çıkış bilgisidir. C_t ve C_{t-1} giriş ve çıkışlar aslında LSTM'i RNN'den ayıran en temel parçadır. Bu Hücre yolu ile bilgi taşınmaktadır. Bu sayede ağ bir hafıza edinmektedir. σ sigmoid fonksiyonu temsil etmektedir. Sigmoid fonksiyon $[0,1]$ aralığında değer almaktadır. Aşağıda matematiksel ifadesi yazılan hücrenin ilk kısmındaki aktivasyon işlemi ile geçmişten gelen hangi bilgilerin hafızada tutulup tutulmayacağına karar verilmektedir. Bu kısma unutmaya kapısı (forget gate) denmektedir:

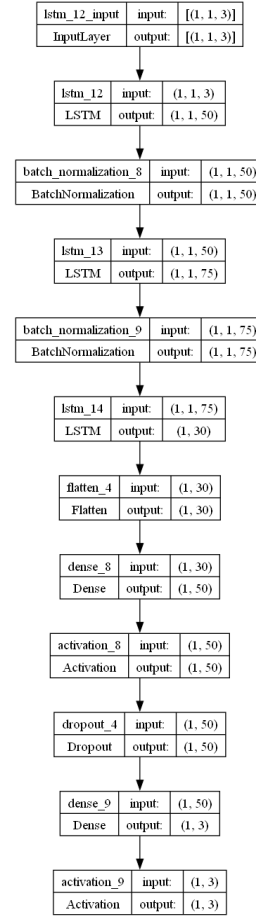
$$forget\ gate = \sigma(W_f(h_{t-1}, x_t) + b_f) \quad (2)$$

W_f ağırlık değerini, b_f bias değerini temsil etmektedir.

Giriş ve çıkış kapıları ise RNN yapısına benzerlik göstermektedir.

C. LSTM Modeli

Bu çalışmada oluşturulan LSTM derin öğrenme modeli 3 LSTM ağı yapısından ve tam bağlantılı sinir hücresi yapısına bağlanmaktadır. Şekil 4'de ağın model yapısı görülmektedir.



Şekil 4. LSTM Model Yapısı Parametreleri

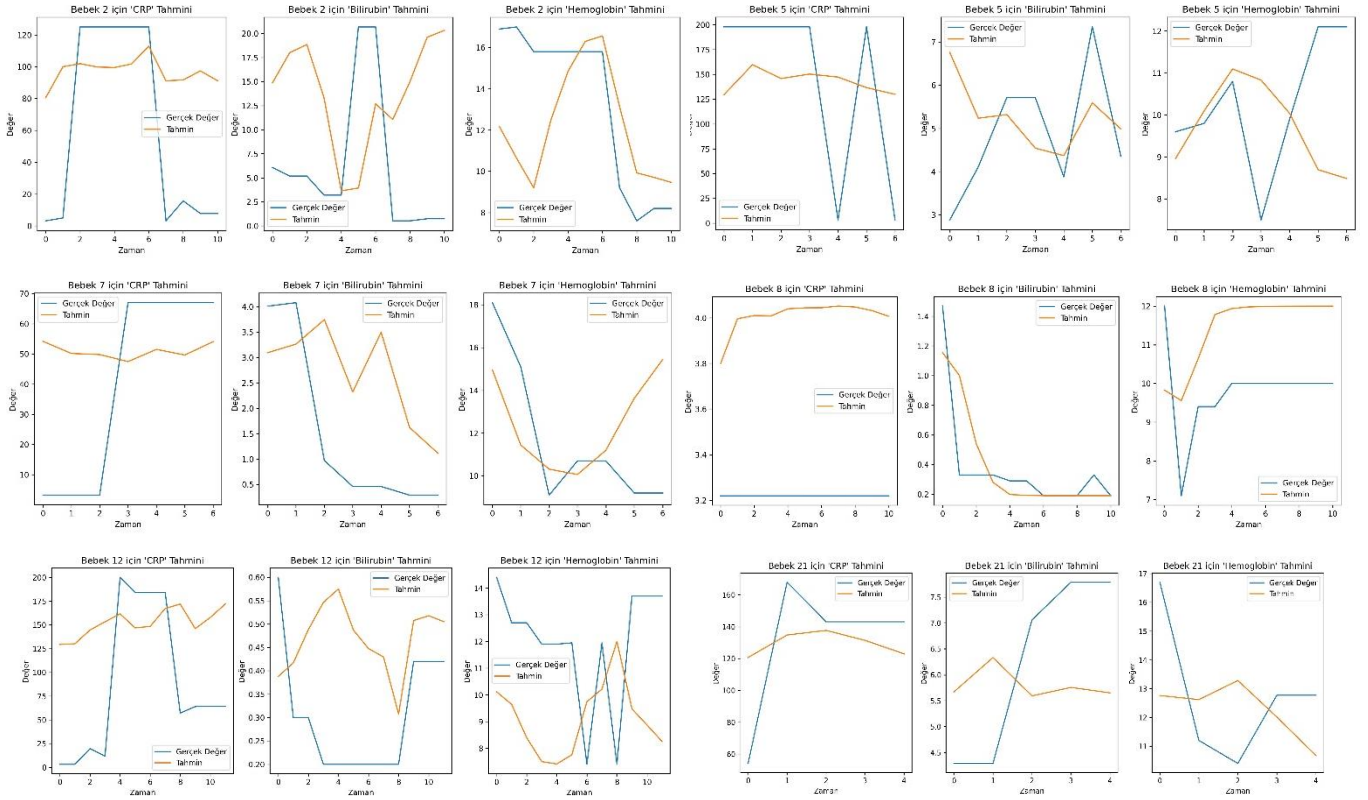
Modelin girişi CRP, hemogloblin ve bilirubin değerlerini alacağı için (1,1,3) olacak şekilde ayarlanmıştır. İlk LSTM ağı 50, ikinci 75, üçüncü ağ 30 hücre içermektedir. Her ağ geçişinde "BatchNormalization" uygulanmıştır. Ağın ileri zamanlı tahmin yapabilmesi için tam bağlantılı katmanlar eklenmiştir. Çıkış aktivasyon fonksiyonu olarak tanh aktivasyon fonksiyonu belirlenmiştir. Tanh fonksiyonu aşağıda görülmektedir. Tanh girdileri $[-1,1]$ aralığında düzenlenmiştir:

$$\tanh = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$

Model eğitilirken hata metriği olarak ortalama karesel hata metriği kullanılmıştır. Ortalama karesel hatanın (OKH) formülü aşağıda görülmektedir.

$$OKH = \frac{1}{n} \sum_{i=1}^n (Y_i - \tilde{Y}_i)^2 \quad (5)$$

Burada Y_i gerçek değeri \tilde{Y}_i tahmin edilen değerleri temsil etmektedir.



Şekil 5. LSTM Modeli Çıktıları

III. DENEYSEL SONUÇLAR

22 bebekten alınan 161 adet laboratuvar bulgularına dayanan veri setinin dağılımı yukarıda veri seti bölümünde anlatılmıştır. LSTM ağı mimarisi ile hazırlanmış modeli eğitmeden önce CRP, hemoglobin ve bilirubin kan parametreleri her bebeğe ait veriler için birer adım geri kaydırarak her t anındaki veriye t+1 anındaki değeri hedef değerleri olacak şekilde veri seti düzenlenmiştir. Bu sayede eğitim işlemi bir denetimli öğrenmeye çevrilmiştir. LSTM modeli her bir bebeğe ait zaman seri verisi için eğitilmiştir. Bebekler arasındaki geçişlerde modelin hafızası sıfırlanmıştır.

Her bir bebeğe ait zaman seri verisi için model 1000 epoch eğitilmiştir. Optimizasyon yöntemi olarak “Adam” optimizasyon yöntemi belirlenmiştir. Modelin oluşturulmasında ve veri ön işleme aşamaları Python 3.11.4 yazılım dilinde gerçekleştirilmiştir. Model işlemleri için Tensorflow, keras ve sklarn kütüphanelerinden faydalanılmıştır. Veri ön işleme ve eğitim işlemleri için 16Gb RAM’e sahip dizüstü bilgisayar içerisindeki NVIDIA GeForce RTX 3070Ti ekran kartı kullanılmıştır. Model sonuçları bazı bebekler için Şekil5’de görülmektedir. Mavi grafik süreç içerisinde bebeğin kan tahlilleri sonucundaki ilgili parametrelerin gerçek değerlerini, turuncu grafik ise model tarafından tahmin edilen değerleri göstermiştir. Grafikler dikkatli incelendiğinde modelin yüksek doğruluk değerlerine ulaşamadığı gözlemlenebilmektedir. Her bir bebekte kan parametresi için ayrı ayrı ortalama karesel hatalar ve doğruluk (%) değerleri Tablo 2’de görülmektedir.

Tablo 2. Kan Parametreleri İçin Model Doğruluğu

Metrik	CRP	Bilirubin	Hemoglobin
Ortalama Karesel Hata	2274.90	14.22	7.37
Doğruluk (%)	29.09	36.36	43.63

IV. TARTIŞMA

Bu çalışmada LSTM ağı mimarisine sahip bir model yenidoğan yoğun bakımında yatan prematüre bebeklerin laboratuvar bulgularına ait veriler ile eğitilerek bir zaman seri analizi çalışması gerçekleştirilmiştir. Veri elde etme sürecinde her bebek için farklı gün ve periyotlarda veri toplanmış ve veri standardizasyonu sağlanamamıştır. Veri toplama sürecinde özellikle sağlıklı bebeklerin kan tahlilleri sık yapılmadığı için veri alma periyotları ciddi derecede uzamıştır. Bu yüzden her bebek için en fazla 15 en az 5 laboratuvar bulgusu sonuçları kaydedilebilmiştir. Model değerlendirme sonuçları incelendiğinde özellikle CRP verilerinin doğruluk değerinin çok düşük olduğu gözlemlenmiştir. CRP değerleri vücutta enfeksiyon arttığında yükselen bir parametre olduğu için özellikle sağlıklı veya enfeksiyon geçirmeyen bebeklerde sık elde edilmeyen bir parametredir. Bu yüzden bu süreç içerisinde en az güncel veri alınan parametre CRP olmuştur. CRP değerinin zaman seri analizinde diğer parametrelere göre daha düşük doğruluk elde etmesinin sebebinin bu olduğu

düşünülmektedir. Diğer Hemoglobin ve Bilirubin parametreleri incelendiğinde CRP'ye göre daha yüksek doğruluk değerleri elde ettikleri ama tatmin edici sonuçlara ulaşamadıkları gözlemlenmiş ama bebeklerden daha sık periyotlarda güncel laboratuvar bulgusu elde edildiğinde oluşturulacak veri setlerin daha yüksek model doğruluklarına ulaşacağına dair umut vaat edici sonuçlar elde edilmiştir.

V. SONUÇ

Yenidoğan yoğun bakım ünitesinde kalan sepsis, rds, nec, ikk, diafragma, pnömotoraks hastalıklarına sahip ve sağlıklı 22 prematüre bebekten 161 adet veri elde edilmiş ve bu veriler her bebek için zaman seri verileri haline getirilerek bir LSTM modeli eğitilmiştir. Bu LSTM modeli her bebek için giriş olarak verilen CRP, bilirubin ve hemoglobin değerlerini eski değerleri de hafıza bölümünde değerlendirerek bir sonraki laboratuvar bulgularında hangi sonuçları elde edebileceğine dair çıktı vermektedir. Bu değerlendirmeler incelendiğinde en yüksek doğrulukla tahmin edilen parametre %43.63 doğruluk ve 7.37 ortalama karesel hata değeri ile Hemoglobin olmuştur. 2274.9 ortalama karesel hata ve %29.09 doğruluk değeri ile en düşük performansı CRP parametresi göstermiştir. Bilirubin ise %36.36 doğruluk seviyesinde kalmıştır.

Veri alma ve model geliştirme süreçleri devam etmekte olup elde edilen bu ilk sonuçlar gelecek çalışmalar için umut vaat etmektedir.

TEŞEKKÜR

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK, proje numarası: 122E021) tarafından desteklenmiştir.

Yazarların Katkıları

M.Çevik: Veri toplama, Araştırma ve Metodoloji, Yazılım, Yazım – orjinal taslak, **M.Cihan:** Veri küratörlüğü, Araştırma ve Metodoloji, **N.Yılmaz:** Veri toplama, **M. Konak** ve **H. Soylu:** Kaynaklar. **M. Ceylan:** Kavramsallaştırma, Metodoloji, Doğrulama, Yazım - inceleme ve düzenleme.

Çıkar Çatışmaları Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yazarlar bu çalışmanın Araştırma ve Yayın Etiği İlkelerine uygun olduğunu beyan ederler.

KAYNAKÇA

- [1] N. I. Sapankevych and R. Sankar, "Time Series Prediction Using Support Vector Machines: A Survey", IEEE Computational Intelligence Magazine, vol. 4, no. 2, pp. 24-38, 2009
- [2] O.B. Sezer, M.U. Gudelek, A. M. Ozbayoglu, "Financial time series forecasting with deep learning: A systematic literature review: 2005–2019", Applied Soft Computing, vol. 90, pp. 106-181, 2020
- [3] T. Dimri, S. Ahmad, M. Sharif "Time series analysis of climate variables using seasonal ARIMA approach" J Earth Syst Sci, pp. 129-149, 2020
- [4] R. B. Penfold, F. Zhang, "Use of Interrupted Time Series Analysis in Evaluating Health Care Quality Improvements", Academic Pediatrics, vol. 13, pp.38-44, 2013
- [5] S. S. Vakhare, R. R. Manza, M. M. Mhaske, "Time Series Analysis and Forecasting of Temperatures Records of Aurangabad District in

- Maharashtra", International Journal for Modern Trends in Science and Technology, vol.6, pp. 291-295, 2020
- [6] G. Box, G. Jenkins, G. Reinsel, G. Ljung, "Time Series Analysis: Forecasting and Control", New Jersey, John Wiley & Sons,
- [7] S. Makridakis, M. Hibon, "ARMA Models and the Box-Jenkins Methodology", Journal of Forecasting, vol.16, pp.147-163
- [8] N.K. Ahmed, A.F. Atiya, N. El Gayar, H. El-Shishiny, "An Empirical Comparison of Machine Learning Models for Time Series Forecasting", Econometric Reviews, vol. 29, pp.594-621, 2010
- [9] B. Lim, S. Zohrem, "Time-series forecasting with deep learning: a survey", Royal Society, vol. 379, Issue 2194, 2021
- [10] S. Ahmed, I.E. Nielsen, A. Tripathi, S. Siddique, R.P. Ramachandran, G. Rassol, "Transformers in Time-Series Analysis: A Tutorial" Circuits Syst Signal Process, vol. 42, pp. 7433–7466, (2023)
- [11] A. Kumar Dubey, A. Kumar, V. Garcia-Díaz, A. Kumar Sharma, K. Kanhaiya, "Study and analysis of SARIMA and LSTM in forecasting time series data", Sustainable Energy Technologies and Assessments, vol. 47, pp. 101474, 2021
- [12] S. Siami-Namini, N. Tavakoli and A. Siami Namin, "A Comparison of ARIMA and LSTM in Forecasting Time Series", 17th IEEE International Conference on Machine Learning and Applications (ICMLA), Orlando, FL, USA, pp. 1394-1401, 2018
- [13] V.K.R. Chimmula, L. Zhang, "Time series forecasting of COVID-19 transmission in Canada using LSTM networks", Chaos, Solitons & Fractals, vol. 135, pp. 109864, 2020
- [14] Anonim, 2023, Preterm Birth [online], World Health Organization, <https://www.who.int/news-room/fact-sheets/detail/preterm-birth> [Ziyaret Tarihi: 15 Ekim 2023]
- [15] Anonim, 2021, Dünya Prematüre Günü [online], T.C. Sağlık Bakanlığı, Halk Sağlığı Genel Müdürlüğü, <https://hsgm.saglik.gov.tr/tr/haberler-cocukergen/dunya-premature-gunu.html> , [Ziyaret Tarihi: 16 Ekim 2023]
- [16] Anonim, 2023, Ölüm ve Ölüm Nedeni İstatistikleri, 2021 [Online], <https://data.tuik.gov.tr/Bulten/Index?p=Olum-ve-Olum-Nedeni-İstatistikleri-2021-45715> , [Ziyaret Tarihi: 5 Mayıs 2023]
- [17] O. Kapellou, "Blood sampling in infants (reducing pain and morbidity)", BMJ Clinical Evidence, vol. 2009 0313, 2009
- [18] S. Hochreiter, J. Schmidhuber, "Long Short-Term Memory", Neural Computation, vol. 9, no. 8, pp. 1735-1780, 1997