

Derin Öğrenme Yöntemleri ile Sıcaklık Tahmini: Diyarbakır İli Örneği

Temperature Estimation with Deep Learning Methods: The Example of Diyarbakir Province

Aynur Sevinç¹ 

Buket Kaya² 

¹Silvan MYO Bilgisayar Teknolojileri Bölümü, Dicle Üniversitesi, Diyarbakır, Türkiye

²Elazığ Organize Sanayi Bölgesi MYO Elektronik ve Otomasyon Bölümü, Fırat Üniversitesi, Elazığ, Türkiye

(sevnc.aynur03@gmail.com, bkaya@firat.edu.tr)

Received: Sep.3, 2021

Accepted: Sep.16, 2021

Published: Oct.20, 2021

Özet- Birçok uygulamada kısa vadeli sıcaklık tahminleri gereklidir. Bu tür tahminlere olan talep birçok alanla beraber özellikle enerji endüstrisinde artmıştır. Daha iyi sıcaklık tahminleri için veriye dayalı modeller giderek daha fazla popülerlik kazanmaktadır. Bu yaklaşımlar arasında derin öğrenme kavramları, yani birden çok gizli katmana sahip sinir ağları bulunmaktadır. Bu çalışmanın odak noktası, meteorolojik verilere dayalı hava sıcaklığı tahmini için derin öğrenmenin uygulanabilirliğini göstermektir. Bu kapsamda T.C. Meteoroloji Genel Müdürlüğü Meteorolojik Veri Bilgi Sunum ve Satış Sistemi'nden (MEVBİS) alınan 2014-2020 yılları arasındaki hava sıcaklığı verileri kullanılarak, Güneydoğu Anadolu Bölgesi'nde yer alan Diyarbakır ili için derin öğrenme algoritmaları ile sıcaklık tahmini yapılmıştır. Bu çalışmanın derin öğrenme mimarisini, Özyinelemeli Sinir Ağlarının (Recurrent Neural Network-RNN) özel bir türü olan Uzun-Kısa Süreli Bellek (Long-Short Term Memory-LSTM) oluşturmaktadır. Ayrıca bu çalışmada tahmin çalışmalarında kullanılan Otomatik Regresif Entegre Hareketli Ortalama (ARIMA) modeli ile de analiz yapılmış ve başarılı sonuçlar ortaya çıkmıştır. Derin öğrenme algoritmalarından LSTM ağları sıcaklığı, rüzgar hızını veya radyasyonu tahmin etmek için sıklıkla kullanılmaktadır. Sistem eğitildikten sonra R-kare skoru değeri 0.96 olarak bulunmuştur. Bu parametre değeri, gerçek hava sıcaklığı değerlerine çok yakın hava sıcaklığı tahmin değerleri elde edildiğini gösteren bir kriterdir. ARIMA ve LSTM modelimizin sağladığı tahminin doğruluğu hem uygun hem de tatmin edicidir. Bu yöntemlerle yapılan sıcaklık tahminlerinin iyi performans gösterdiği ve hava sıcaklığı tahmininde başarılı bir şekilde kullanılabileceği tespit edilmiştir.

Anahtar Kelimeler: Derin öğrenme, LSTM, ARIMA, Sıcaklık tahmini, Yapay sinir ağları.

Abstract— Short-term temperature forecasts are required in many applications. The demand for such forecasts has increased in many fields, especially in the energy industry. Data-driven models for better temperature predictions are gaining more and more popularity. These approaches include deep learning concepts, namely neural networks with multiple hidden layers. The focus of this study is to demonstrate the feasibility of deep learning for air temperature prediction based on meteorological data. In this

context, T.C. Using the air temperature data between the years 2014-2020 taken from the Meteorological Data Information Presentation and Sales System (MEVBIS) of the General Directorate of Meteorology, temperature forecasts were made with deep learning algorithms for the province of Diyarbakir, located in the Southeastern Anatolia Region. The deep learning architecture of this study is long-short term memory (LSTM), which is a special type of recursive neural networks (RNN). In addition, the analysis was made with the Automatic Regressive Integrated Moving Average (ARIMA) model used in forecasting studies in this study and successful results were obtained. Long Short Term Memories (LSTM) networks from deep learning algorithms are frequently used to predict temperature, wind speed or radiation. After the system was trained, the R-square score value was found to be 0.96. This parameter value is a criterion showing that air temperature prediction values very close to the actual air temperature values are obtained. The accuracy of the prediction provided by our ARIMA and LSTM model is both appropriate and satisfactory. It has been determined that the temperature predictions made by these methods perform well and can be used successfully in air temperature prediction.

Keywords: *Deep learning, LSTM, ARIMA, Temperature prediction, Artificial neural networks.*

1.Giriş

Derin öğrenme (Deep Learning-DL) farklı alanlarda çok katmanlı yapay sinir ağlarını kullanan bir yapay zeka yöntemidir. Bir makine öğrenmesi çeşidi olarak DL, bir veri kümesiyle çıktılarının tahminini yapacak olan yapay zekanın eğitilmesine olanak sağlamaktadır (Şimşek, 2019). Makine öğrenmesi çok fazla tecrübe kazanmış bir sistemin karşılaşacağı yeni bir duruma yüksek oranda başarılı tepki vermesi (tahmin etmesi) sürecidir. Buradaki tecrübe çok sayıda veri ile sağlanırken, öğrenme işlemi ise her biri farklı bir çalışma prensibine dayanan makine öğrenmesi algoritmaları ile gerçekleşmektedir (Uğuz, 2019). DL, farklı düzeylerde ve katmanlarda öğrenmeyi kullanarak üst düzey soyut kavramları modellemeyi amaçlayan bir dizi algoritmadan oluşur. Derin öğrenme tekniklerinin kökleri yapay sinir ağlarına (YSA) dayanır ve bu ağlar makine öğrenmesinde yaygın olarak kullanılan bir modeldir. Temeli 1940'lı yıllara dayanan YSA'lar son yıllarda popüler olan derin öğrenme çalışmalarının da temelini oluşturmaktadır. İnsan beyninin yapısından esinlenilerek tasarlanan, örüntü tanıma ve hata minimizasyonuna dayalı bir yöntemdir.

Derin öğrenme modelleri, son gelişmelerle birlikte temelde mühendislik hedefleri göz önünde bulundurularak geliştirilmiştir. Son yıllarda mühendislik alanında yapılan birçok bilimsel çalışmada derin öğrenme mimarileri kullanılmaktadır. Bu yöntemlerden biri tahmin modellemede sıklıkla kullanılan LSTM modelidir. Uzun Kısa Süreli Bellek (LSTM) sinir ağı, özel bir tekrarlayan sinir ağıdır (Recurrent Neural Network-RNN) ve Hochreiter ve Schmidhuber (1997) tarafından uzun vadeli bağımlılıkları ele almak için tasarlanmıştır. Bir LSTM bilgiyi hatırlamak veya unutmak için kendi hava durumuna karar verir. Konuşma ve el yazısı tanıma kullanımının yanı sıra makine çevirisi, resim yazısı, hisse senedi fiyatı tahmini, rüzgar hızı gibi çeşitli ilgi alanlarında zaman serilerinin yeniden yapılandırılması ve tahmini, deniz yüzeyi sıcaklığı tahmini, güneş ışınımı tahmini ve hava durumu tahmini çalışmalarında kullanılmaktadır (Jörges, Berkenbrink ve Stumpe, 2021). LSTM'in kısa ve uzun vadeli tahmin çalışmalarında derin ileri beslemeli sinir ağlarından ve diğer son teknoloji makine öğrenimi algoritmalarından daha iyi performans gösterdiği yapılan birçok çalışmada vurgulanmaktadır.

Otomatik Gerilemeli Entegre Hareketli Ortalama (ARIMA), geçmiş verilerin zaman serisini analiz ederek gelecek kısa vadeli tahminleri hesaplayan bir zaman serisi otomatik gerilemeli tekniktir. ARIMA modeli 1970'lerde Box ve Jenkins tarafından bir zaman serisindeki değişiklikleri matematiksel bir yaklaşımla açıklamak için oluşturulmuştur (Box, Jenkins, Reinsel ve Ljung, 2015). ARIMA tabanlı bir tahminin doğruluğu, özellikle eğitim seti verilerine ve modelde kullanılan parametrelere bağlıdır ve hemen hemen tüm ARIMA tabanlı model tahminleri, en uygun modeli seçmek için doğruluk ölçütlerini kullanır. ARIMA modelleri, mevsimsellik ve döngüsel bileşenleri olan hareketli ortalama (MA) ve otoregresif (AR) modelleri gibi basit zaman serisi modelleriyle aynı özelliklere sahiptir. Bu özellikler,

mühendislik ve bilimin çeşitli alanlarındaki farklı değişkenleri tahmin etmek için bu tür bir modelin uygulanmasını desteklemiştir (Prista, Diawara, Costa ve Jones, 2011).

Bu çalışmanın amaçları iki yönlüdür: Bir derin öğrenme modeli olan LSTM'in tahmin performansını ortalama hava sıcaklıklarına bağlı olarak belirlemek ve ARIMA modelinin hava sıcaklığını tahmin etmede ne kadar doğru sonuçlar verdiğini değerlendirmektir. Bu kapsamda Diyarbakır ilinin 2014-2020 yılları arasında alınan günlük sıcaklık verileri ile geleceğe yönelik sıcaklık tahmini gerçekleştirilmiştir. Çalışmanın geri kalanı şu şekilde düzenlenmiştir; hava sıcaklığı tahmini çalışmalarına yönelik literatür araştırması, ARIMA ve LSTM modellerinin nasıl çalıştığına açıklanması, veri setinin hazırlanma süreci ve analizlerin gerçekleştirilmesi, son olarak veri analizi bulgu sonuçları ve genel sonuçlara yer verilerek çalışma sonlandırılmıştır.

1.1. İlgili Çalışmalar

Süzen ve Kayaalp (2018), derin öğrenme algoritmalarından LSTM kullanarak Isparta ili merkezi için sıcaklık tahmini çalışması gerçekleştirmişlerdir. Geliştirilen sistem eğitildikten sonra Isparta iline ait sonraki 4 yıl için günlük ortalama sıcaklıkları tahmin ettirilmiştir. Sonuç olarak; derin öğrenme algoritmaları ile geleceği tahmin etmede bu modelin başarıyla kullanılabileceği ortaya konulmuştur. Qui ve arkadaşları (2021) bir derin öğrenme yöntemi kullanarak nehir suyu sıcaklığı tahmini konulu çalışmalarında, günlük nehir suyu sıcaklıklarını tahmin etmek, iklim ve baraj inşaatının neden olduğu termal rejimdeki zamansal değişiklikleri ölçmek için bir tür derin öğrenme yöntemi olan uzun kısa vadeli sinir ağının (LSTM) potansiyelini araştırmışlardır. Sonuçlar, LSTM'in nehirlerdeki ortalama günlük su sıcaklığını tahmin etmek için diğer yöntemlerden daha iyi performans gösterdiğini ve termal rejimdeki günlük ortalama değişimleri doğru bir şekilde yakaladığını ortaya çıkarmıştır.

Fang ve arkadaşları (2021) LSTM tabanlı sıralama ile çok bölgeli iç ortam sıcaklığı tahmini konulu çalışmalarında, farklı girdi değişkenlerinden en iyi şekilde yararlanmak için, çok adımlı ileri tahmin yapmak amacıyla uzun kısa süreli bellek (LSTM) tabanlı diziden diziye (seq2seq) modelini önermişlerdir. Mevcut modelin çok kısa vadeli tahminlerde çok daha yetenekli ve güvenilir olduğu gösterilmiştir. Daha geliştirilmiş bir modelle çok bölgeli iç ortam sıcaklığı tahminini sağlamak için bir çapraz seri öğrenme stratejisi benimsenmiştir. Singh ve Mohapatra (2019) çok kısa vadeli rüzgar hızı tahmini için tekrarlanan dalgacık dönüşümü tabanlı ARIMA modeli konulu çalışmalarında, rüzgar hızının kısa vadeli ve çok kısa vadeli tahmini için son zamanlarda popüler teknikler olan ARIMA ve WT-ARIMA modellerinin eksikliğini araştırarak çok kısa vadeli rüzgar hızı tahmini için geliştirilmiş doğruluğa sahip yeni bir Tekrarlanan WT tabanlı ARIMA (RWT-ARIMA) modeli önermişlerdir.

1.2. ARIMA Modeli

Hava sıcaklığı tahmini, bir zaman serisi tahmin problemi olarak ele alınabilir. ARIMA modelleri genellikle sağlam ve uygulanması kolay olduğu için kullanılır. ARIMA için mevsimsel olmayan model yapısı şu şekildedir (Zhang, 2003): *ARIMA* (p, d, q). Burada;

- ▶ *p*, modelin otoregresyonunun (AR) sırası ve farklı alınmış serinin gecikme sayısıdır.
- ▶ *d*, modeli durağan hale getirmek için farkın (I) sırasıdır.
- ▶ *q*, modelin hareketli ortalamasının (MA) sırası ve tahmin hatalarının gecikme sayısıdır.

Matematiksel olarak, tipik bir ARIMA modeli *ARIMA* (p, d, q) şeklinde ifade edilebilir.

$$y_t = c_t + \sum_{i=1}^p \phi_m y_{t-i} + \sum_{j=1}^q \theta_n e_{t-j} \quad (1)$$

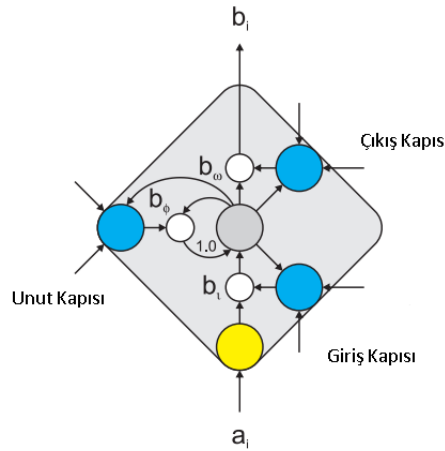
Doğası gereği durağan olan mevsimsel bir zaman serisi için *d* sıfırdır ve bu nedenle ARIMA modeli ARMA modeline indirgenir. Benzer şekilde, *d* ve *q* katsayılarının her ikisi de sıfır ise, ARIMA modeli yalnızca otoregresif bir modeldir (AR).

Zaman serisi analizi; bilgisayar bilimleri, finans ve ekonomi, dinamik modelleme, işletme gibi birçok alanda uygulama alanına sahip bir araştırma konusudur (Granger, 2014). Bu analiz türünün amacı, zaman serilerinin izlenen veri değerlerini inceleyerek tanımlanan veri yapıları ile zaman serilerinin gelecek değerlerinin tahminini yapmak için bir model ortaya çıkarmaktır (Osmanoğlu, Sunar, Wdowinski ve CabralCano, 2016). Zaman serisi analizlerinde çoğunlukla istatistiki hesaplamalara dayanan ARIMA modelleri ile makine öğrenmesine dayalı yöntemler kullanılmaktadır. ARIMA modelleri bazı önemli kısıtlamalara sahiptir, bu kısıtlamaların çözümü olarak zaman serisi analizleri için derin öğrenmeye dayalı yeni yöntemler geliştirilmiştir.

1.3.LSTM Derin Öğrenme Modeli

Son yıllarda LSTM derin öğrenme modeli yüksek doğruluk ve iyi ölçeklenebilirlik özelliklerinden dolayı zaman serisi tahmininde popülerlik kazanmış ve birçok çalışmada kullanılmıştır. LSTM, zaman dizisi boyunca değerli bilgileri korumak için gizli duruma ek olarak bir hücre durumu ekleyen özel bir RNN türüdür. Birçok zorlayıcı durumda normal RNN modelinden çok daha iyi başa çıkmaya yardımcı olabilecek özel bir kapı sistemi tarafından da kontrol edilmektedir.

LSTM tekrarlayan sinir ağı mimarisine sahip bir makine öğrenme algoritmasıdır. Model olarak kısa sürede öğrenilen bilgileri depolar ve uzun süre eğitim için kullanır. Bu nedenle, uzun kısa süreli bellek, gizli katmanda "bellek blokları" adı verilen birimleri içerir. Bu bellek blokları, geleneksel yinelenen sinir ağlarında gizli birimler olarak tanımlanabilir. Bellek blokları bir veya daha fazla bellek hücresi içerir. Her bellek bloğu, bilgi akışını kontrol etmek için giriş ve çıkış portlarına sahiptir. Giriş kapısı bellek hücresindeki giriş aktivasyon bilgilerinin akışını kontrol ederken, çıkış kapıları çıkış aktivasyon bilgisinin akışını kontrol eder. Daha sonra bellek bloklarına bir "unutma kapısı" eklenir. Unutma kapısı, hücrenin iç durumunu ölçeklendirir, hücre üzerinden giriş aktivasyonundan önce hücrenin belleğini sıfırlar. Şekil 1, bir LSTM derin ağının hücre yapısını göstermektedir.



Şekil 1.Yapay sinir ağının LSTM hücre yapısı
(Süzen ve Kayaalp, 2018)

2. Materyal ve Metodoloji

2.1. Veri Setinin Hazırlanması

Derin öğrenme modelinin eğitilmesi ve test süreci için kullanılan veriler Meteoroloji Genel Müdürlüğü Meteorolojik Veri Bilgi Sunum ve Satış Sistemi'nden (MEVBİS) resmi yazışma kanalıyla temin edilmiştir. Bu veri seti, Diyarbakır ilinin 2014-2020 yılları arasında her yılın aylık verilerine ait günlük sıcaklıkları içermektedir. Toplam 2271 adet veri kullanılmıştır. 2014 Şubat-2020 Nisan ayları arasını içeren veriler Microsoft Excel programında düzenlenmiş ve aylık ortalama sıcaklık değerleri hesaplanmıştır. Öğrenme modelinde kullanılan ham veriler Tablo 1'de yer almaktadır.

Tablo 1. Öğrenme modelinde kullanılan ham veriler

Sıra No	Yıl	Ay	Gün	Sıcaklık (°C)
1	2014	2	3	2.9
2	2014	2	4	0.3
3	2014	2	5	3.7
.
.
2269	2020	4	25	13.2
2270	2020	4	26	15.4
2271	2020	4	27	14.9

Tablo 1’de yer alan veriler incelendiğinde, verilen tarih aralığında hava sıcak değerlerinin yıllara, aylara ve günlere göre dağılımı görülmektedir. Sıcaklık değerleri yaklaşık olarak -10 ile 36 °C arasında değişmektedir. Her aya ait günlük sıcaklık verilerinin aritmetik ortalaması alınarak aylık ortalama sıcaklık değerleri bulunmuş ve bu veriler ayrı bir Excel dosyasına aktarılmıştır. Bir sonraki adımda derin öğrenme yöntemleriyle veri analizi gerçekleştirilmiştir.

2.2. Verilerin Derin Öğrenme ile Analiz Edilmesi

Derin öğrenme modelleri için zengin bir kütüphane sunan Python programlama dili kullanılarak *Anaconda* platformu üzerinden *Spyder* arayüzü ile analiz işlemleri gerçekleştirilmiştir. Programın verileri okuyabilmesi için Excel dosyası .csv (virgülle ayrılmış değerler dosyası) formatına çevrilmiş ve arayüz programına import edilmiştir. Aşağıda bu çalışmada kullanılan kod bloğunun bir kısmına yer verilmiştir.

Spyder arayüzü
(Python 3.8)

Python dili kod bloğu

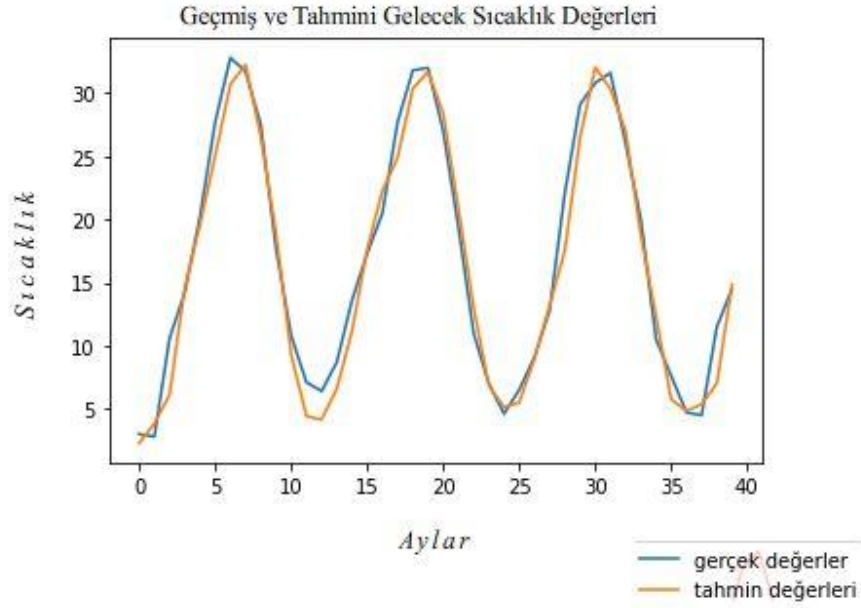
```
...
...
# create a differenced series
def difference(dataset, interval=1):
    diff = list()
    for i in range(interval, len(dataset)):
        value = dataset[i] - dataset[i - interval]
        diff.append(value)
    return Series(diff)

# invert differenced value
def inverse_difference(history, yhat, interval=1):
    return yhat + history[-interval]
...
...
```

3. Bulgular

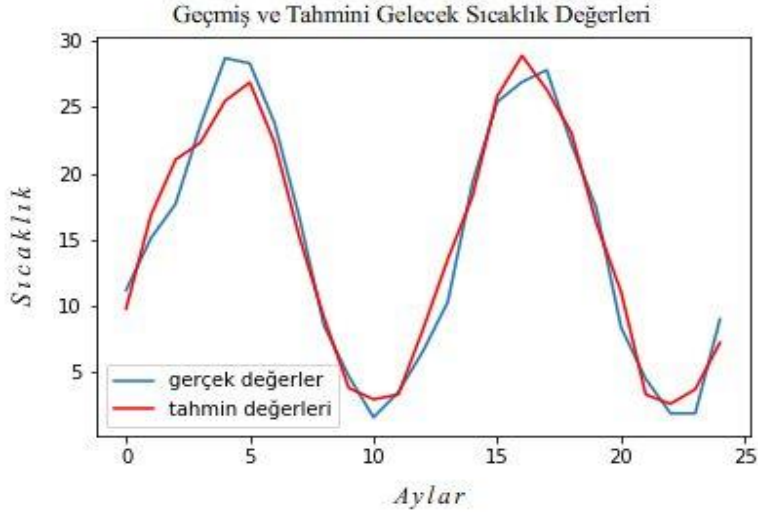
LSTM modelinde; *Epochs* (Algoritmanın veri kümesi ile kaç yinelemede eğitileceğini gösteren parametre), *Batch* (1 defada alınan miktar) ve *Nöron* sayıları değiştirilerek çeşitli yöntemler denenmiş ve en son 80 epoch, 1 batch ve 80 nöron alınarak yapılan denemede en iyi sonuç bulunmuştur. Ağın eğitiminde kullanılan bu parametrelerle gerçek değerlere en yakın tahmin değerleri elde edilmiştir. Şekil 2 ve Şekil 3’te sırasıyla LSTM ve ARIMA modeli kullanılarak elde edilen grafikler görülmektedir. Bununla birlikte, LSTM ve ARIMA ile yapılan tahminlemede hesaplanan hata kriterleri RMSE, MSE,

R^2 , MAE ölçütlerinin kavramsal açıklaması Tablo 3'te, bu çalışmada elde edilen performans-hata kriteri değerlerine ise Tablo 4'te yer verilmiştir.



Şekil 2. LSTM modeli ile Diyarbakır ili sıcaklık tahmini grafiği

Şekil 2 incelendiğinde, derin öğrenme modeli LSTM ile yapılan analiz sonucunda hava sıcaklığı tahmini değerlerin gerçek değerlere yakın olduğu görülmektedir.



Şekil 3. ARIMA modeli ile Diyarbakır ili sıcaklık tahmini grafiği

Şekil 3 incelendiğinde, ARIMA modeli ile yapılan analiz sonucunda hava sıcaklığı tahmini değerlerin gerçek değerlere yakın olduğu görülmektedir. Tablo 2'de Diyarbakır ilinde ölçülen gerçek sıcaklık değerleri ile ARIMA ve LSTM modeliyle tahminlenen sıcaklık değerleri görülmektedir.

Tablo 2. Ölçülen gerçek sıcaklık değerleri, LSTM ve ARIMA ile tahmin edilen sıcaklık değerleri

Tarih	Aylık Ortalama Gerçek Sıcaklık Değerleri (°C)	ARIMA Modeli ile Tahmin (°C)	LSTM Modeli ile Tahmin (°C)
Kasım 2018	11.0	11.8	13.4
Aralık 2018	7.0	5.0	7.9
Ocak 2019	4.6	4.2	5.9
Şubat 2019	6.5	6.0	6.5
Mart 2019	9.1	10.7	9.8
Nisan 2019	12.8	15.6	14.4
Mayıs 2019	22.1	18.9	18.7
Haziran 2019	29.1	27.4	27.5
Temmuz 2019	30.8	32.1	32.7
Ağustos 2019	31.6	29.6	30.1
Eylül 2019	26.0	27.4	25.7
Ekim 2019	20.0	19.5	17.4
Kasım 2019	10.5	12.3	11.2
Aralık 2019	7.6	5.2	6.4
Ocak 2020	4.7	4.5	5.4
Şubat 2020	4.5	6.5	6.8
Mart 2020	11.5	8.5	8.2
Nisan 2020	14.5	17.9	16.0

3.1. Hata Kriteri Ölçütleri

Hata kriteri ölçütleri, belirli bir algoritmanın/modelin çalışma türü ve güvenilirliği hakkında bize kanıt sağlayan özel formüllerdir. Bir modelin standart değerlendirmesi için çeşitli performans ölçütleri tanımlanmıştır. Literatürde yaygın olarak kullanılan ölçütlere bağlı kalınarak bu çalışmada kullanılan önemli ölçüm metrikleri Tablo 3'te listelenmiştir. Deneylerimizde elde edilen hata kriteri ölçümleri;

- Derin LSTM modelinde,
- Otomatik Regresif Entegre Hareketli Ortalama (ARIMA) modelinde hesaplanmıştır.

Tablo 3. Hata kriteri metrikleri

Metrik	Formül	Tanım/İşlevsellik
Kök Ortalama Kare Hata (RMSE)	$\sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}$	Tahmin edilen \hat{y}_i değerlerinde hata kareler ortalaması karekökü olup en önemli performans ölçütlerinden birisidir (Demirezen, 2020). RMSE değeri 0'dan ∞ 'a kadar değişebilir.
Ortalama Kare Hata (MSE)	$\frac{1}{N} \sum_{i=1}^N e_i^2$	Tahminleyicinin performansını ölçen kriterdir. Her zaman pozitif değer alır ve MSE değeri sıfıra ne kadar yakınsa tahminleyicinin o ölçüde iyi performans gösterdiği yorumu yapılabilir.

Metrik	Formül	Tanım/İşlevsellik
R Kare Skoru (R^2)	$\frac{\sum(x - \bar{x})(y - \bar{y})}{\sqrt{\sum(x - \bar{x})^2 \sum(y - \bar{y})^2}}$	Gerçek değerler ile tahmin edilen değerler arasındaki ilişkiyi ifade eden R kare skoru, 0-1 arasında değer alır. R^2 değeri 1'e ne kadar yakınsa model o kadar hassas (Kalogriou, 2000) ve uyum iyiliği uygun demektir.
Ortalama Mutlak Hata (MAE)	$1/N \sum_{i=1}^N t_i - a_i $	Doğrusal bir skor olan MAE, iki sürekli değişken arasındaki farkın ölçüsünü ifade etmektedir. Bu değer 0'dan ∞ 'a kadar değişim gösterebilir. Burada t beklenen değeri, a ise gerçek ölçüm değerini temsil etmektedir.

Bu çalışmada önerilen LSTM ve ARIMA tabanlı modellere ait ölçülen hata-performans değerleri aşağıda yer alan Tablo 4'te sunulmuştur.

Tablo 4. LSTM ve ARIMA modeline dayalı hata kriteri ölçüm değerleri

Hata Kriteri / Model	RMSE	MSE	R^2	MAE
LSTM	1.859	3.454	0.963	1.583
ARIMA	1.946	3.786	0.953	1.694

Tablo 4 incelendiğinde, R kare skoru değerinin derin LSTM ağlarında 0.963 olarak bulunduğu görülmektedir. R^2 değerinin sifira yakın çıkması, mevcut verilerin kullanılan model ile uyum durumunun uygun olmadığını gösterir. Böyle bir uygunsuzluğun görüldüğü durumda modelin değiştirilmesi gereklidir. Eğer R^2 skoru değeri bire yakın çıkarsa modelin uyum durumunun uygun olduğu çıkarımı yapılabilir ve çıkarımsal kontrol analizinin bir sonraki basamağına geçiş yapılır. Bu değerin çalışmada kullanılan iki modelde de bire yakın elde edildiği görülmektedir.

4. Sonuç

Çalışmada, 2014 Şubat–2020 Nisan tarihleri arasında Diyarbakır ilinin ortalama günlük hava sıcaklığı verileri kullanılarak LSTM derin öğrenme algoritmaları ve zaman serisi analizi modellerinden ARIMA ile sıcaklık tahmini yapılmıştır. Toplam 2271 adet veri ile çalışma gerçekleştirilmiştir. Tahminleme çalışmalarında sıklıkla kullanılan ARIMA ve LSTM modelinin eğitilmesi, test edilmesi ve geleceğe yönelik tahminleme için Anaconda platformunda çalışan Spyder arayüzü üzerinde çalışılmıştır. En önemli performans ölçüt kriterlerinden biri olarak kabul edilen RMSE değeri ARIMA modelinde 1.946, LSTM modelinde ise 1.859 olarak bulunmuştur. RMSE metriğinin sıfır değerini alması modelin hiç hata yapmadığı anlamına gelmektedir. Bununla birlikte, R^2 skoru değerlerinin bire yakın bulunması çalışma verilerimiz için seçilen modelin uygunluğunu göstermektedir. Son olarak bu çalışmada, LSTM ve ARIMA ile yapılan sıcaklık tahminlerinin iyi performans sonuçları verdiği ve bu modellerin hava sıcaklığı tahmininde başarılı bir şekilde kullanılabileceği gösterilmiştir.

Teşekkür

Bu bilimsel çalışma sürecini gerçekleştirmek için gerekli verilerin kullanımına izin veren T.C. Meteoroloji Genel Müdürlüğü'ne teşekkürü borç biliriz.

Kaynaklar

- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- Demirezen, S. (2020). *Türkiye'de Gün Öncesi Piyasası İçin Elektrik Fiyatlarının Tahmini*. Yüksek Lisans Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Fang, Z., Crimier, N., Scanu, L., Midelet, A., Alyafi, A., & Delinchant, B. (2021). Multi-zone indoor temperature prediction with LSTM-based sequence to sequence model☆. *Energy and Buildings*, 245, 111053.
- Granger, C. W. J. and Newbold, P. (2014). *Forecasting economic time series*, Academic Press.
- Jörges, C., Berkenbrink, C., & Stumpe, B. (2021). Prediction and reconstruction of ocean wave heights based on bathymetric data using LSTM neural networks. *Ocean Engineering*, 232, 109046.
- Kalogriou S.A. (2000). Applications of artificial neural-networks for energy systems, *Applied Energy*, 67: 17-35.
- Osmanoğlu, B., Sunar, F., Wdowinski, S. and CabralCano, E.. (2016). Time series analysis of InSAR data: Methods and trends", *ISPRS Journal of Photogrammetry and Remote Sensing*, 115: 90-102.
- Prista, N., Diawara, N., Costa, M. J., & Jones, C. M. (2011). Use of SARIMA models to assess data-poor fisheries: a case study with a sciaenid fishery off Portugal. *Fishery Bulletin*, 109(2).
- Qiu, R., Wang, Y., Rhoads, B., Wang, D., Qiu, W., Tao, Y., & Wu, J. (2021). River water temperature forecasting using a deep learning method. *Journal of Hydrology*, 595, 126016.
- Sherstinsky, A. (2018). *Fundamentals of Recurrent Neural Network and Long Short-Term Memory Network*.
- Singh, S. N., & Mohapatra, A. (2019). Repeated wavelet transform based ARIMA model for very short-term wind speed forecasting. *Renewable energy*, 136, 758-768.
- Süzen, A. A., & Kayaalp, K. (2018). Derin Öğrenme Yöntemleri İle Sıcaklık Tahmini: Isparta İli Örneği. *In International Academic Research Congress INES*.
- Uğuz, S. (2019), *Makine Öğrenmesi Teorik Yönleri ve Python Uygulamaları ile Bir Yapay Zeka Ekolü*, 1.Baskı, Nobel Yayıncılık, Ankara.
- Utku, A. & Akcayol, M. A. (2021). Derin Öğrenme Tabanlı Model ile Bir Olayın Sonraki Olma Zamanının Tahmini. *Politeknik Dergisi*, 24(1), 1-15.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.
- Makine Öğrenmesi, Doğru Metrik Seçimi. İnternet adresi: <https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/> Erişim Tarihi: 08.08.2021.
- Belirleme Katsayısı (2021). İnternet adresi: https://tr.wikipedia.org/wiki/Regresyon_analizi Erişim Tarihi: 08.08.2021.