



DERİN ÖĞRENME TEKNİĞİ KULLANILARAK KARS İLİNİN HAVA SICAKLIK TAHMİNİ

Muhammet Ali KARABULUT^{1*}, Emre TOPÇU²

¹ Kafkas Üniversitesi, Mühendislik Mimarlık Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Kars, Türkiye

² Kafkas Üniversitesi, Mühendislik Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, Kars, Türkiye

Anahtar Kelimeler

Sıcaklık Tahmini,
Veri Analizi,
LSTM,
Yapay Sinir Ağları.

Öz

Hava sıcaklığının doğru tahmini, su kaynakları yönetiminde, kara-atmosfer etkileşiminde ve tarımda önemli bir rol oynar. Ancak, doğrusal olmayan ve kaotik doğası nedeniyle hava sıcaklığını doğru bir şekilde tahmin etmek zordur. Son yıllarda hava sıcaklığını tahmin etmek için derin öğrenme teknikleri önerilmiştir. Bu çalışma, hava sıcaklığını tahmin etmek için kullanılan yapay sinir ağı (YSA) tabanlı yaklaşımlarından uzun kısa süreli bellek (LSTM) kapsamlı bir incelemesini sunmaktadır. Hava durumu verileri, ortalama rüzgâr hızı, yağış, kar yağışı, kar derinliği, ortalama sıcaklık, maksimum sıcaklık ve minimum sıcaklığı içeren veriler bu algoritmaya girdi olmuşturlar. Çıktı olarak ise, bir sonraki gün için ortalama sıcaklık olarak belirlenmiştir. Odak noktası Kars ilinin Merkez ilçesinin 2010-2021 dönemindeki meteorolojik ölçümlerdir. İnceleme, sinir ağı modellerinin hava sıcaklığını tahmin etmek için umut verici araçlar olarak kullanılabileceğini göstermektedir. YSA tabanlı yaklaşımlar, hızlı işlem kabiliyeti ve karmaşık problemlerle başa çıkma yetenekleri nedeniyle hava sıcaklığını tahmin etmek için yaygın olarak kullanılmasına rağmen, mevcut en iyi yöntem üzerinde henüz bir fikir birliği yoktur. Aylık ve günlük olarak hesaplanan modelin tahmin doğruluğunun yüksek olması, sıcaklık tahmini çalışmalarında bu modelin başarılı bir şekilde uygulanabileceğini göstermiştir.

AIR TEMPERATURE FORECAST OF KARS CITY USING DEEP LEARNING TECHNIQUE

Keywords

Forecasting,
Data Analysis,
LSTM,
Artificial Neural Networks.

Abstract

Accurate estimation of air temperature plays an important role in water resource management, land-atmosphere interaction, and agriculture. However, it is difficult to accurately predict air temperature due to its non-linear and chaotic nature. Deep learning techniques have been proposed to predict air temperature in recent years. This study presents a comprehensive review of long short-term memory (LSTM), one of the artificial neural networks (ANN)-based approaches used to predict air temperature. Data including weather data, average wind speed, precipitation, snowfall, snow depth, average temperature, maximum temperature and minimum temperature have been input to this algorithm. As the output, it is determined as the average temperature for the next day. The focal point is the meteorological measurements of the Central district of Kars province in the period 2010-2021. The review shows that neural network models can be used as promising tools to predict air temperature. Although ANN-based approaches are widely used for estimating air temperature due to their fast computational speed and ability to deal with complex problems, there is still no consensus on the best available method. The monthly and daily calculated model, its high estimation accuracy, showed that this model can be successfully applied in temperature estimation studies.

Alıntı / Cite

Karabulut, M. A., Topçu, E., (2022). Derin Öğrenme Teknikleri Kullanılarak Kars İlının Hava Sıcaklık Tahmini, Mühendislik Bilimleri ve Tasarım Dergisi, 10(4), 1174-1181.

* İlgili yazar / Corresponding author: mali.karabulut@kafkas.edu.tr, +90-474-225-1150 Dahili:1612

Yazar Kimliği / Author ID (ORCID Number)	Makale Süreci / Article Process	
M. A. Karabulut, 0000-0002-2080-5485	Başvuru Tarihi / Submission Date	03.02.2022
E. Topçu, 0000-0003-0728-7035	Revizyon Tarihi / Revision Date	20.05.2022
	Kabul Tarihi / Accepted Date	10.06.2022
	Yayın Tarihi / Published Date	30.12.2022

1. Giriş (Introduction)

Küresel ısınma, hava sıcaklığındaki artışla ilişkili olduğu için son zamanlarda bilim insanlarının dikkatini çekmektedir. Artan hava sıcaklığı, deniz seviyesinin yükselmesi ve küresel ısınma gibi iklim koşullarında değişikliklere yol açmakta ve nihayetinde insan yaşamını olumsuz yönde etkilemektedir. Hava sıcaklığı, atmosferin durum değişkenidir ve hem atmosferik hem de kara yüzeyi süreçlerini etkilemektedir (Tajpar vd., 2020; Valipour vd., 2020). Hava sıcaklığı tahmini, insan yaşamını ve özelliklerini korumak için kullanıldığından hava tahmininin önemli bir parçasıdır. Hava sıcaklığı uygun bir aralıkta olmadığından insanlar potansiyel sağlık sorunları yaşayabilir (Schulte vd., 2016). Hava sıcaklığındaki aşırı değişiklikler bitkilere ve hayvanlara zarar verebilir. Sanayi, enerji ve tarım gibi çeşitli sektörler üzerindeki önemli etkisinden dolayı hava sıcaklığının doğru tahmini çok önemlidir (Sardans vd., 2006). Güvenilir hava sıcaklığı tahminleri, enerji tüketiminin doğruluğunu artırır. Hava sıcaklığı ayrıca akış (Tang vd., 2012), buharlaşma (Jovic vd., 2018) ve güneş radyasyonu (Marzo vd., 2017) gibi diğer meteorolojik değişkenleri tahmin etmede kilit faktörlerden biridir. Bu nedenle, hava sıcaklığının tahmini için uygun bir yaklaşımın bulunması hayati önem taşımaktadır ve küresel ısınma ve iklim değişikliğinin sonuçlarını hafifletebilir. Ayrıca, hava sıcaklığının doğru tahmini, insan faaliyetleri, enerji politikası ve iş geliştirme için bir plan oluşturulmasında önemli bir rol oynar (Smith vd., 2007).

Son zamanlarda, yapay sinir ağlarına (YSA) dayalı modeller, girdiler ve çıktılar arasındaki doğrusal olmayan ilişkileri yakalama yetenekleri nedeniyle meteoroloji, su kaynakları ve hidroloji gibi çeşitli disiplinlerde bilim adamlarının dikkatini çekmiştir. Çeşitli YSA tabanlı yaklaşımlar, sel (Yang vd., 2019), yağış (Lee vd., 2018), su kalitesi (Zou vd., 2020) ve hava sıcaklığı (Altan vd., 2009) tahminleri gibi birçok hidrolojik problemde başarılı bir şekilde gerçekleştirilmiştir. Biyolojik sinir sistemlerinden esinlenilerek geliştirilen YSA'lar, bağımlı ve bağımsız değişkenler arasındaki doğrusal olmayan ilişkileri modellemek için güçlü araçlardır. YSA'lar eğitim verileri üzerinden yapabildikleri genelleme sayesinde kendilerine sağlanmayan test örneklerini doğru olarak tahminleme yetileri yüksektir. Sonuç olarak, YSA tahmin modelleri, fiziksel ve istatistiksel yaklaşımlardan daha umut verici bir performans sunabilmektedir. Ayrıca, yaygın olarak kullanılan programlama ortamlarında (örneğin Matlab, Python, vb.) bir araç kutusu olarak kolayca erişilebilmektedirler.

Bu çalışma, hava sıcaklığı tahmini için derin öğrenme tekniklerinin potansiyelini araştırmaktadır. Uygulanan model uzun-kısa süreli bellek (Long-Short Time Memory - LSTM) modelidir. Kars ilinin Merkez ilçesi için geçmiş hava durumu verilerinin T.C. Meteoroloji Genel Müdürlüğünden elde edilip modeli eğitmek için kullanılmıştır. Hava durumu verileri, ortalama rüzgâr hızı, yağış, kar yağışı, kar derinliği, ortalama sıcaklık, maksimum sıcaklık ve minimum sıcaklığı vb. içeren veriler bu algoritmaya girdi olmuşturlar. Çıktı, daha sonra bir sonraki gün için ortalama sıcaklık olarak belirlenmiştir.

Makalenin organizasyonu şu şekildedir. Bölüm 2'de, hava tahmini ile ilgili önceki çalışmaların literatür taraması yapılmıştır. Bölüm 3, tahmin için kullanılan LSTM tekniğini açıklamaktadır. Bölüm 4, veri setinin tanıtıldığı, modellerin uygulandığı ve sonuçların sunulduğu deneysel bölümdür. Son olarak, Bölüm 5'te sonuçlar tartışılmıştır.

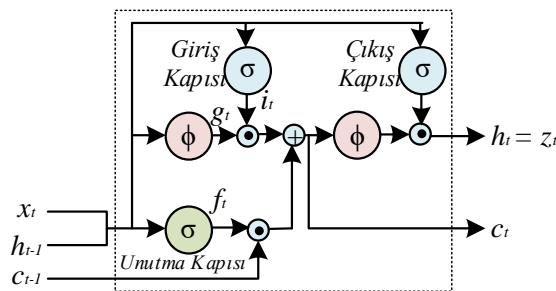
2. Kaynak Araştırması (Literature Survey)

Ustaoglu vd. (2009), Türkiye'de günlük ortalama, maksimum ve minimum hava sıcaklığını tahmin etmek için ileri beslemeli geri yayılım (FFBP), radyal temel fonksiyon (RBF) ve genelleştirilmiş regresyon sinir ağı (GRNN) olmak üzere üç farklı YSA kullanmıştır. Modeller, 1 gün öncesi hava sıcaklığını tahmin etmek için önceki yedi günün günlük hava sıcaklığı ölçümlerini kullanılmıştır. Korelasyon katsayısı (R^2) ve ortalama karekök hatası (RMSE) gibi istatistiksel parametreleri kullanarak, kullanılan tüm sinir ağı yöntemlerinin tatmin edici sonuçlar verdiğini göstermişlerdir. Kumar vd. (2013) Hindistan'da haftalık ortalama hava sıcaklıklarını tahmin etmek için FFNN'yi kullanmışlardır. Altı hafta önceki hava sıcaklığı verileri, 1 hafta sonraki hava sıcaklığını tahmin etmek için çeşitli YSA mimarilerinde kullanılmıştır. Farklı konfigürasyonların tahmin yeteneği, R^2 ve RMSE metriklerinin hesaplanmasıyla değerlendirilmiştir. Tran vd. (2020) geleneksel çok katmanlı ANN, RNN ve LSTM modellerinin hiperparametrelerini optimize etmek için bir genetik algoritma (GA) kullanmışlardır. Hibrit modeller, Güney Kore'deki Cheongju istasyonunda maksimum hava sıcaklığını tahmin etmek için kullanılmıştır. Son haftanın hava sıcaklığı gözlemleri, 1 ila 15 gün arası maksimum hava sıcaklığını tahmin etmek için girdi olarak kullanılmıştır. Sonuçlar, hibrit GA-LSTM'nin uzun vadeli hava sıcaklığı tahmini için diğer modellerden daha iyi bir performansla sahip olduğunu göstermiştir. Li vd. (2019), tarihsel gözlemlerinden yarım saatlik hava sıcaklığını tahmin etmek


için LSTM kullanmışlardır. LSTM modeli, farklı pencereler altında derin sinir ağı (DNN) ve rastgele orman (RF) yaklaşımları ile karşılaştırılmıştır. LSTM ile oluşturulan ağın DNN ve RF yöntemlerinden daha üstün olduğu gözlemlenmiştir. Abhishek vd. (2012), 1999–2009 yılları arasında Kanada'da günlük maksimum hava sıcaklığını tahmin etmek için ileri beslemeli sinir ağının (FFNN) uygulanabilirliğini araştırmışlardır. Giriş verileri, son 10 yılda günlük maksimum hava sıcaklığı ölçümlerinden oluşmaktadır. Sinir ağlarının performansını değerlendirmek için farklı transfer fonksiyonları, gizli katman sayısı ve nöronlar test edilmiştir. Sonuçlar tan-sigmoid transfer fonksiyonuna sahip YSA'nın en iyi maksimum hava sıcaklığı tahminlerini ürettiğini göstermektedir. Afzali vd. (2012), İran'ın Kerman şehrinde son 15 gün verileri kullanılarak 1 gün sonraki ortalama, minimum ve maksimum hava sıcaklığını tahmin etmek için iki farklı türde sinir ağı geliştirmiştir (FFNN ve Elman sinir ağı). Sonuçlar, her iki sinir ağının da tatmin edici hava sıcaklığı tahminleri sağladığını göstermektedir. Salman vd. (2015), hava tahmini için Tekrarlayan Sinir Ağı (RNN), Koşullu Kısıtlı Boltzmann Makinesi (CRBM) ve Evrimsel Sinir Ağı (CNN) gibi derin öğrenme tekniklerini araştırmıştır. Xingjian vd. (2015), yerel bir bölgedeki gelecekteki yağış yoğunluğunu nispeten kısa bir süre içinde tahmin etmek için evrimsel-LSTM adlı bir derin öğrenme modeli geliştirmişlerdir. Yang vd. (1997), tropikal siklon yoğunluğu tahminleri yapmak için uzun bir kısa süreli bellek (LSTM) modeli kullanmışlardır. Günümüzde hava olaylarını tahmin etmek için makine öğrenmesi tekniklerinin yanı sıra derin öğrenme tekniklerinin kullanıldığı çeşitli uygulamalar bulunmaktadır.

3. Uzun-kısa süreli bellek (Long Short Term Memory Network, LSTM)

LSTM ilk olarak Hochreiter (1997) tarafından sunulmuştur. LSTM, uzun vadeli bağımlılıkları öğrenmek için geliştirilmiş bir RNN sınıfıdır. Tekrarlayan sinir ağları, birimler arasındaki bağlantıların yönlendirilmiş bir döngü oluşturduğu yapay sinir ağlarının bir alt sınıfıdır. Bu döngü, dinamik zamansal davranışın sergilenmesine izin veren dahili bir ağ durumu yaratır (Salcedo vd., 2012). Geleneksel ileri beslemeli sinir ağlarından farklı olarak, LSTM'nin geri besleme bağlantıları vardır. RNN'ler verileri soldan sağa tarar. LSTM, dizi tahmini görevlerinde uzun vadeli bağımlılıkları öğrenebilen özel bir RNN türüdür. Bu model, geleneksel RNN'leri eğitme problemini, kaybolan gradyan problemini, sabit hata karesel birimlerini ekleyerek ele alır (Rajendra vd., 2019). Tipik bir LSTM birimi, bir hücre, bir giriş kapısı, bir çıkış kapısı ve bir unutmaya kapısından oluşur. Hücre keyfi zaman aralıklarında değerleri hatırlar ve üç kapı (unutma kapısı, giriş kapısı ve çıkış kapısı) hücrenin içine ve dışına bilgi akışını düzenler. LSTM birimleri Şekil 1'de görülebilir, x_t : LSTM biriminin giriş vektörü, f_t : geçidin aktivasyon unutmaya vektörünü, i_t : giriş kapısının aktivasyon vektörü, c_t : hücre durum vektörü, h_t : LSTM biriminin çıkış vektörü. Girdi sayısı arttığında, ilk birkaç girdiye olan gradyanlar kaybolur ve sıfıra eşitlenir. LSTM, hücreye bilgi ekleyebilen, düzenleyebilen veya çıkarabilen iç kapıları kullanarak bu sorunu çözebilir.



Şekil 1. LSTM biriminin gösterimi (Representation of LSTM unit)



Şekil 2. LSTM sistem modeli (LSTM system model)

Bu ağlar, ağ çıktısı ile beklenen çıktı arasındaki hatayı en aza indirmek için eğitilir ve bu tür öğrenmeye, ağı Derin Öğrenme alanında eğitmek için geri yayılım kullanarak denetimli öğrenme tekniği denir (Smith vd., 2007). Klasik ileri beslemeli sinir ağlarından farklı olarak, LSTM'nin geri besleme bağlantıları vardır. Şekil 2'de bir LSTM sistem modeli gösterilmektedir. Ayrıca önerilen sistemin pseudo kodu Algoritma 1'de verilmektedir.

Algoritma 1. LSTM sisteminin pseudo kodu (Pseudo code of the LSTM system)

- 1: **Input:** x= Günlük/Aylık veriler
 - 2: **for** t=1:...: 4380/144 **do**
 - 3: **Hesaplama:** Tahmin edilen ortalama sıcaklık
 - 4: **end for**
 - 5: **Output:** Ortalama sıcaklık
-

4. Deneysel Sonuçlar (Experimental Results)

4.1 Veri Seti ve Özellikleri (Dataset and Features)

1/1/2010 ile 31/12/2021 tarihleri arası Kars ilinin Merkez ilçesi istasyonundan her gün için hava durumu verileri, T.C. Meteoroloji Genel Müdürlüğü tarafından sağlanmıştır. Veri setinin özellikleri arasında ortalama rüzgâr hızı, yağış, ortalama nem, ortalama buhar basıncı, ortalama güneşlenme şiddeti, güneşlenme süresi, ortalama sıcaklık, maksimum sıcaklık ve minimum sıcaklık bulunmaktadır. Tablo 1'de 4380 güne ait meteorolojik ölçümlerden oluşan veri seti gösterilmektedir. Tablo 2'de 144 aya ait meteorolojik ölçümleri içeren aylık veri seti gösterilmektedir. Algoritmayı eğitmek için ilk 10 yıla ait veriler, test etmek için ise son iki yıla ait veriler kullanılmıştır. Ağ eğitilmeden önce veriler veri setindeki en büyük değere bölünerek normalize edilmiştir. Tablo 3'te ağın eğitilmesi sırasında LSTM içerisinde kullanılan parametreler gösterilmektedir.

Tablo 1. 2010-2021 Yılları Arasındaki Kars İlinin Günlük Veri Seti (Daily Data Set of Kars City Between 2010-2021)

No	TOPLAM AÇIK YÜZEY BUHARLAŞMASI mm	ORTALAMA AKTÜEL BASINÇ Pa	ORTALAMA NEM %	ORTALAMA GÜNEŞLENME ŞİDDETİ	GÜNLÜK ORTALAMA RÜZGAR HIZI m/sn	GÜNEŞLENME SÜRESİ saat	ORTALAMA SICAKLIK °C
1	4,90	818,20	85,50	267,01	2,00	5,50	-2,80
2	4,60	816,90	77,80	450,48	4,20	4,60	1,70
3	1,20	812,90	83,50	448,07	4,30	2,70	1,40
4	0,90	813,30	85,70	533,22	2,60	0,00	-0,60
5	1,20	821,60	72,50	447,66	1,60	1,80	-7,00
.
.
.
4376	3,20	821,00	65,20	172,84	1,50	9,90	15,30
4377	2,50	821,50	71,70	93,67	1,30	9,60	17,30
4378	2,70	822,20	65,30	46,09	1,30	10,80	19,90
4379	2,60	821,40	70,00	81,33	1,20	10,50	21,30
4380	3,60	822,80	67,70	177,20	1,40	10,60	19,90

Tablo 2. 2010-2021 Yılları Arasındaki Kars İlinin Aylık Veri Seti (Monthly Data Set of Kars City Between 2010-2021)

No	TOPLAM AÇIK YÜZEY BUHARLAŞMASI mm	ORTALAMA AKTÜEL BASINÇ Pa	ORTALAMA NEM %	TOPLAM GÜNEŞLENME SÜRESİ	ORTALAMA RÜZGAR HIZI m/sn	ORTALAMA SUBUHARI BASINCI Pa	ORTALAMA SICAKLIK °C
1	118,20	822,30	82,30	72,60	2,20	4,00	-3,60
2	140,80	816,60	81,20	69,20	2,30	4,60	-1,30
3	146,70	821,40	67,70	125,20	3,40	5,10	2,60
4	156,30	822,30	74,20	96,80	2,30	6,40	4,90
5	149,30	821,50	70,90	150,40	2,20	8,50	10,00
.
.
.
140	133,00	825,00	70,00	134,00	3,10	4,30	0,20
141	129,80	825,00	84,90	10,90	2,40	5,00	-2,40
142	10,40	822,70	66,00	2231,50	2,30	7,20	6,50
143	579,60	821,70	74,30	0,00	2,70	9,80	-6,80
144	164,00	819,90	79,20	127,00	2,60	10,40	-6,20

Tablo 3. Ağın Eğitilmesinde Kullanılan Parametreler (Parameters Used in Training the Network)

PARAMETRE	DEĞER
Giriş	6
Çıkış	1
Nöron	13
Katman	4
Epochs	125
Batch Boyutu	100
Öğrenme oranı	0.001

4.2 Değerlendirme Metrikleri (Evaluation Metrics)

Tahmin için önerilen yöntemlerin performansını değerlendirmek için, hataların karesel ortalamasının karekökü (RMSE), ortalama kare hata (MSE), ortalama mutlak hata (MAE), ortalama mutlak yüzde hatası (MAPE) ve korelasyon katsayısı (R^2) olmak üzere beş metrik kullanılmıştır. Bu metrikler genellikle zaman serisi tahmininde değerlendirme için kullanılmaktadır. Metrik değerler aşağıdaki gibi hesaplanmaktadır:

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (H_{tah,j} - H_{ölç,j})^2} \quad (1)$$

$$MSE = \frac{1}{N} \sum_{j=1}^N (H_{tah,j} - H_{ölç,j})^2 \quad (2)$$

$$MAE = \frac{1}{N} \sum_{j=1}^N |H_{tah,j} - H_{ölç,j}| \quad (3)$$

$$MAPE = \frac{1}{N} \sum_{j=1}^N \left| \frac{H_{tah,j} - H_{ölç,j}}{H_{ölç,j}} \right| \quad (4)$$

$$R^2 = \frac{N \left(\sum_{j=1}^N H_{tah,j} H_{ölç,j} \right) - \left(\sum_{j=1}^N H_{tah,j} \right) \left(\sum_{j=1}^N H_{ölç,j} \right)}{\sqrt{\left(N \sum_{j=1}^N (H_{tah,j})^2 - (H_{ölç,j})^2 \right) \left(N \sum_{j=1}^N (H_{ölç,j})^2 - (H_{tah,j})^2 \right)}} \quad (5)$$


Burada H_{tah} , tahmin edilen ortalama sıcaklık $H_{ölç}$, ölçülen ortalama sıcaklık ve N , veri kümesindeki eleman sayısıdır.

4.3 Sonuçlar ve Analiz (Results and Analysis)

Bu çalışmada, sınıflandırma ve regresyon analizi için kullanılan denetimli öğrenme modeli olan destek vektör makineleri (SVM) ile LSTM incelenmiştir. Ancak LSTM modelinin performansı, modelin karmaşıklığı arttıkça hem aylık hem de günlük ölçümler ile gerçekleştirilen tahminlerin çok daha iyi olduğu gözlemlenmiştir. Bu, değerlendirme metrikleriyle yapılan performans karşılaştırmasıyla ayrıca doğrulanmaktadır. Performans metrikleri Tablo 4'de gösterilmektedir. Ayrıca Şekil 3'te 2010-2021 yıllarına ait yıllık ortalama sıcaklık gerçek değerlerinin ve LSTM ile tahmin edilen değerlerinin karşılaştırılması verilmektedir.

Tablo 4. Performans Metrikleri (Performance Metrics)

		R-Squared	RMSE	MSE	MAE	MAPE
LSTM	Aylık	0,9867	0,4821	0,2324	0,4649	0,0242
	Günlük	0,9937	0,4976	0,2476	0,4987	0,0174
SVM	Aylık	0,8632	0,4244	0,1801	0,4152	0,0199
	Günlük	0,8869	0,4383	0,1921	0,4289	0,0154



Şekil 3. 2010-2021 yılları arasındaki Kars ilinin yıllık ortalama sıcaklık gerçek ve LSTM ile tahmin edilen değerlerinin karşılaştırılması (Comparison of annual average temperature actual and LSTM predicted values of Kars city between 2010-2021)

5. Sonuç ve Tartışma (Result and Discussion)

Bu çalışmada, Kars ilinin Merkez ilçesine ait istasyondan alınan gerçek hava durumu verilerini kullanarak ortalama günlük hava sıcaklığını tahmin etmek için LSTM uygulanabilirliği araştırılmıştır. Ortalama hava sıcaklığı, kendi tarihsel değerlerinin yanı sıra ortalama rüzgâr hızı, yağış, ortalama nem, ortalama buhar basıncı, ortalama güneşlenme şiddeti, güneşlenme süresi, ortalama sıcaklık, maksimum sıcaklık ve minimum sıcaklık gibi diğer hava değişkenlerinin bir fonksiyonu olarak modellenmiştir. Sonuçlar, daha karmaşık derin sinir ağları kullanıldığında tahminlerin doğruluğunun arttığını göstermektedir. Aylık ve güncel olarak ele alınan durumlarda günlük ele alınan durumun 0,9937 oranında doğruluk oranına sahip olduğu gözlemlenmektedir.

Gelecekteki çalışmalarda, çok değişkenli, çok adımlı ve çok bölge bir hava durumu tahmin problemi oluşturmak için daha fazla konumun dahil edilmesi amaçlanmaktadır. Sıcaklık tahmini için barometrik basınç, bağıl nem,

rüzgâr yönü, rüzgâr hızı gibi daha fazla hava değişkeninin etkisini araştırılması planlanmaktadır. Son olarak, daha doğru tahminler oluşturup oluşturamayacaklarını görmek için daha karmaşık derin öğrenme tabanlı tahmin modelleri denenecektir.

Teşekkür (Acknowledgement)

Bu çalışmaya katkılarından dolayı T.C. Meteoroloji Genel Müdürlüğü'ne teşekkür ederiz.

Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the authors.

Kaynaklar (References)

- Tajfar, E.; Bateni, S.M.; Lakshmi, V.; 2020. Estimation of surface heat fluxes via variational assimilation of land surface temperature, air temperature and specific humidity into a coupled land surface-atmospheric boundary layer model. *J. Hydrol.* 583, 124577.
- Valipour, M.; Bateni, S.M.; Gholami Sefidkouhi, M.A.; Raeini-Sarjaz, M.; Singh, V.P., 2020. Complexity of Forces Driving Trend of Reference Evapotranspiration and Signals of Climate Change. *Atmosphere (Basel)*, 11, 1081.
- Schulte, P.A.; Bhattacharya, A.; Butler, C.R.; Chun, H.K.; Jacklitsch, B.; Jacobs, T.; Kiefer, M.; Lincoln, J.; Pendergrass, S.; Shire, J.; et al., 2016. Advancing the framework for considering the effects of climate change on worker safety and health. *J. Occup. Environ. Hyg.* 13, 847–865.
- Sardans, J.; Peñuelas, J.; Estiarte, M., 2006. Warming and drought alter soil phosphatase activity and soil P availability in a Mediterranean shrubland. *Plant Soil*, 289, 227–238.
- Tang, C.; Crosby, B.T.; Wheaton, J.M.; Piechota, T.C. Assessing streamflow sensitivity to temperature increases in the Salmon River Basin, Idaho. *Glob. Planet. Change* 2012, 88–89, 32–44.
- Jovic, S.; Nedeljkovic, B.; Golubovic, Z.; Kostic, N. Evolutionary algorithm for reference evapotranspiration analysis. *Comput. Electron. Agric.* 2018, 150, 1–4.
- Marzo, A.; Trigo, M.; Alonso-Montesinos, J.; Martínez-Durbán, M.; López, G.; Ferrada, P.; Fuentealba, E.; Cortés, M.; Batlles, F.J., 2017. Daily global solar radiation estimation in desert areas using daily extreme temperatures and extraterrestrial radiation. *Renew. Energ.* 113, 303–311.
- Smith, D.M.; Cusack, S.; Colman, A.W.; Folland, C.K.; Harris, G.R.; Murphy, J.M. Improved Surface Temperature Prediction for the Coming Decade from a Global Climate Model. *Science* 2007, 317, 796–799.
- Yang, T.; Sun, F.; Gentine, P.; Liu, W.; Wang, H.; Yin, J.; Du, M.; Liu, C., 2019. Evaluation and machine learning improvement of global hydrological model-based flood simulations. *Environ. Res. Lett.*, 14, Water, 13, 1294 14 of 15.
- Lee, J.; Kim, C.G.; Lee, J.E.; Kim, N.W.; Kim, H., 2018. Application of artificial neural networks to rainfall forecasting in the Geum River Basin, Korea. *Water (Switzerland)*, 10, 1448.
- Zou, Q.; Xiong, Q.; Li, Q.; Yi, H.; Yu, Y.; Wu, C., 2020, A water quality prediction method based on the multi-time scale bidirectional long short-term memory network. *Environ. Sci. Pollut. Res.*, 27, 16853–16864.
- Altan Dombayci, Ö.; Gölcü, M. Daily means ambient temperature prediction using artificial neural network method: A case study of Turkey. *Renew. Energ.* 2009, 34, 1158–1161.
- Ustaoglu, B.; Cigizoglu, H.K.; Karaca, M. Forecast of daily mean, maximum and minimum temperature time series by three artificial neural network methods. *Meteorol. Appl.* 2008, 15, 431–445.
- Kumar, P.; Kashyap, P.; Ali, J. Temperature Forecasting using Artificial Neural Networks (ANN). *J. Hill Agric.* 2013.
- Tran, T.T.K.; Lee, T.; Kim, J.S. Increasing neurons or deepening layers in forecasting maximum temperature time series? *Atmosphere (Basel)* 2020, 11, 1072.
- Li, C.; Zhang, Y.; Zhao, G. Deep Learning with Long Short-Term Memory Networks for Air Temperature Predictions. In *Proceedings of the 2019 International Conference on Artificial Intelligence and Advanced Manufacturing (AIAM)*, Dublin, Ireland, 16–18 October 2019; pp. 243–249.
- Abhishek, K.; Singh, M.P.; Ghosh, S.; Anand, A. Weather Forecasting Model using Artificial Neural Network. *Procedia Technol.* 2012, 4, 311–318.
- Afzali, M.; Afzali, A.; Zahedi, G. The Potential of Artificial Neural Network Technique in Daily and Monthly Ambient Air Temperature Prediction. *Int. J. Environ. Sci. Dev.* 2012, 3, 33–38.
- Salman, A.G., Kanigoro, B., Heryadi, Y., 2015. Weather forecasting using deep learning techniques, in: 2015 International Conference on Advanced Computer Science and Information Systems (ICACSIS), IEEE. pp. 281–285.
- Xingjian, S., Chen, Z., Wang, H., Yeung, D.Y., Wong, W.K., Woo, W.c., 2015. Convolutional lstm network: A machine learning approach for precipitation nowcasting, in: *Advances in neural information processing systems*, pp. 802–810.
- Yang, Q., Lee, C.Y., Tippet, M.K., 2020. A long short-term memory model for global rapid intensification prediction. *Weather and Forecasting* 35, 1203–1220. Hochreiter, S. Long Short-Term Memory. *Neural Comput.* 1997, 1780, 1735–1780.
- Salcedo-Sanz, S.; Deo, R.C.; Carro-Calvo, L.; Saavedra-Moreno, B., 2016. Monthly prediction of air temperature in Australia and New Zealand with machine learning algorithms. *Theor. Appl. Climatol.*, 125, 13–25.
- Rajendra, P.; Murthy, K.V.N.; Subbarao, A.; Boadh, R., 2019. Use of ANN models in the prediction of meteorological data. *Model. Earth Syst. Environ.*, 5, 1051–1058.

Smith, B.A.; McClendon, R.W., 2007. Hoogenboom, G. Improving Air Temperature Prediction with Artificial Neural Networks. Int. J. Comput. Inf. Eng., 1, 3159.