



Derin sinir ağları modeli ile standardize yağış indeksi tahmini

Standard precipitation index estimation with deep neural network model

Levent Latifoğlu^{1,*} 

^{1,*}Erciyes Üniversitesi, İnşaat Mühendisliği Bölümü, 51240, Kayseri Türkiye

Öz

Kuraklık, yaşamı doğrudan etkileyen ve çok çeşitli olumsuz etkileri olan doğal bir afettir. Kuraklığı tahmin etmek üzere farklı kuraklık indeksleri kullanılmaktadır. Bu indekslerden en yaygın olarak kullanılanlardan biri de Standardize Yağış İndeksidir (SYİ). Gerçekleştirilen çalışmada Türkiye'ye ait Rize, Konya ve Şanlıurfa illerinin 3, 6, 9 ve 12 aylık SYİ verileri 1-3 ileri zamanlı olarak tahmin edilmiştir. Tahmin çalışmasını gerçekleştirmek üzere Uzun Kısa Süreli Bellek Ağları (Long Short Term Memory Networks, LSTM) ve Çift Yönlü Uzun Kısa Süreli Bellek Ağlarından (Bidirectional Long Short Term Memory Networks, biLSTM) oluşan Derin Sinir Ağları modelleri geliştirilmiştir. Tahmin performansını değerlendirmek üzere Ortalama Mutlak Hata (Mean Absolute Error, MAE), Ortalama Karese Hata (Mean Squared Error, MSE), Korelasyon katsayısı (Correlation Coefficient, R) ve Belirlilik katsayısı (Determination Coefficient, R²) parametreleri kullanılmıştır. Elde edilen sonuçlar tahmin parametreleri ve saçılma grafikleri ile değerlendirildiğinde biLSTM içeren derin sinir ağları modelinin performansının oldukça iyi olduğu ve 3 ileri zamanlı tahminde bile yüksek korelasyona sahip sonuçlar elde edilebileceğini göstermiştir.

Anahtar kelimeler: Kuraklık, Standardize yağış indeksi, Derin sinir ağları, LSTM, biLSTM

1 Giriş

Kuraklık, toplumların yanı sıra tarımsal ve hidrolojik sistemler üzerinde de önemli etkisi olan, yağış eksikliği ile karakterize edilen karmaşık yapıya sahip ve döngüsel bir olaydır [1, 2]. Gün geçtikçe artarak küresel ve yerel bir sorun haline gelen kuraklık, toprağın bozulmasıyla birlikte çölleşmeye, sosyal problemlere, kıtlığa ve yoksullaşmaya neden olmaktadır [3,4]. İklim değişikliği ile ilgili çalışmalarda son yıllarda kuraklığa dikkat çekilmekte olup tarımsal veya çevresel yönetime yardımcı olmak üzere kuraklık riskini analiz ve tahmin etmek için birçok çalışma yapılmaktadır. Ancak, bu durum, son zamanlarda, yağış miktarı hakkında fikir veren ve nihayetinde kuraklıkları izleme yeteneğini geliştiren çok sayıda modelleme yaklaşımının geliştirilmesiyle mümkün olmaktadır. Kuraklık yönetim ve tahmin tekniklerini geliştirmeyi amaçlayan kuraklık risk analizi, kuraklığın mekânsal değişkenliğine dayanmaktadır ve esas olarak kuraklıkların büyüklüğü, süresi, yoğunluğu ve mekânsal boyutuna odaklanılmaktadır.

Abstract

Drought is a natural disaster that directly affects life and has a wide variety of negative effects. Different drought indices are used to predict drought. One of the most widely used of these indices is the Standardized Precipitation Index (SPI). In this study, the 3, 6, 9 and 12-month SPI data of Rize, Konya and Şanlıurfa provinces of Turkey were estimated 1-3 forward time. Deep Neural Networks models consisting of Long Short Term Memory Networks (LSTM) and Bidirectional Long Short Term Memory Networks (biLSTM) have been developed to perform the prediction study. The Mean Absolute Error (MAE), Mean Squared Error (MSE), Correlation Coefficient, R and Determination Coefficient (R²) parameters were used to evaluate the forecasting performance. When the results obtained are evaluated with the performance parameters and scatter plots, it has been shown that the performance of the deep neural network model with biLSTM is quite good and that high correlation results can be obtained even in 3 forward-time predictions.

Keywords: Drought, Standard precipitation index, Deep neural networks, LSTM, biLSTM

Diğer doğal afetlerden farklı olarak, kuraklıkların oluşma süresi yavaştır [5]. Kuraklıkların sonuçları, kuraklığın başlangıcına, ekosistemler ve hidrolojik sistemler tarafından algılandıkları zamana göre uzun sürelerde ortaya çıkmaktadır. Bu özelliği nedeniyle, kuraklığı başlangıcında uyarabilen bir kuraklık izleme sistemi, kuraklığın en olumsuz etkilerinin önemli bir şekilde azaltulmasına yol açabilecektir.

Günümüzde kuraklığın mekânsal ve zamansal boyutu ile şiddetini belirlemeye yönelik Standart Yağış Buharlaşma İndeksi (Standardized Precipitation Evapotranspiration index, SPEI), Palmer Kuraklık Şiddet İndeksi (Palmer Drought Severity Index, PDSI), Etkili Kuraklık İndeksi (Effective Drought Index, EDI) ve Keşif Kuraklık İndeksi (Reconnaissance Drought Index, RDI) gibi birçok farklı kuraklık indeksi hesaplanmaktadır [6-9]. Ancak McKee ve diğerleri tarafından geliştirilen Standardize Yağış İndeksi (SYİ, Standardized Precipitation Index, SPI), diğerlerine göre birçok avantajı olan etkili bir kuraklık indeksidir [10,

* Sorumlu yazar / Corresponding author, e-posta / e-mail: latifoglu@erciyes.edu.tr (L. Latifoğlu)

Geliş / Received: 18.07.2022 Kabul / Accepted: 28.09.2022 Yayınlanma / Published: 14.10.2022

doi: 10.28948/ngumuh.1145279

11]. SYİ sadece yağış verilerini gerektirmesi nedeniyle hesaplanması diğer indekslerden daha kolaydır. Böylece, akarsu akışı, evapotranspirasyon ve toprak nemi bilgileri gibi diğer parametrelerin kolayca erişilebilir olmayabileceği, verinin az olduğu bölgelerde kuraklık risk analizi ve tahmininde oldukça faydalıdır. SPI, hem zaman hem de mekân açısından karşılaştırılabilir ve birden fazla zaman ölçeği için hesaplanabilmektedir [12,13]. Böylece kuraklıkların süresinin, büyüklüğünün ve yoğunluğunun belirlenmesine olanak sağlayarak çeşitli kuraklık türlerini hidrolojik, tarımsal veya çevresel olarak tanımlamaktadır. Olasılıksal temellere dayanarak hesaplanması kuraklık analizinde önemli yer tutmasına yol açmıştır ve dünyanın birçok bölgesinin kuraklık analizi için yaygın olarak kullanılmaktadır. Bu nedenle SYI tahmini kuraklık analizinde önemli olmaktadır.

Herhangi bir hidrolojik olayın tahmini, fiziksel, kavramsal ya da veriye dayalı bir yaklaşım kullanılarak yapılabilmektedir. Ancak veriye dayalı modeller değişken sayısı bakımından daha az bilgi gerektirdikleri ve daha kısa sürelerde geliştirilebildikleri için fiziksel temelli modellere göre bir takım avantajlara sahiptir. Veriye dayalı modellerin geliştirilmesinde Özyinelemeli Hareketli Ortalama (Autoregressive Moving Average, ARMA) modellerin kullanıldığı lineer yaklaşımların yerini son yıllarda Yapay Zeka modellerine dayalı lineer olmayan yaklaşımlar almaktadır [14, 15].

Adamowski ve arkadaşları Yapay Sinir Ağları (YSA), Destek Vektörleri ve Dalgacık Sinir Ağları kullanarak 3 aylık ve 12 aylık SYİ tahmini üzerine çalışmıştır. Çalışmanın sonucunda Dalgacık Sinir Ağları yaklaşımının tahmin performansını artırdığını göstermiştir [16]. Khan ve arkadaşları, Dalgacık Dönüşümü, Özyinelemeli Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average, ARIMA) ve Yapay Sinir Ağları kullanarak SYİ ve Standart Yıllık Yağış İndeksinin başarıyla tahmin edilebileceğini göstermiştir [16]. Çitakoğlu ve arkadaşları yaptığı bir çalışmada, akarsu akış kuraklık indeksini Dalgacık Modeli ve Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (Adaptive Neural-Fuzzy Inference Systems, ANFIS) kullanarak tahmin etmiştir [17]. Literatür çalışmaları incelendiğinde SYİ'nin geçmiş değerlerini kullanarak SYİ ve kuraklık tahmini yapan modellerde YSA, Destek Vektör Makineleri ve Karar Ağaçları içeren makine öğrenimi tekniklerinin kullanıldığı görülmüştür [18].

Ayrıca derin sinir ağları mimarilerinden olan Uzun Kısa Süreli Bellek Ağları (Long Short Term Memory Networks, LSTM) finans, iklim çalışmaları, çevresel değişkenler gibi farklı çalışma alanları için sıklıkla kullanılmasına rağmen, kuraklık endekslerinin tahminine yönelik çalışmaların oldukça sınırlı olduğu görülmektedir [19-21]. Çift Yönlü Uzun Kısa Süreli Bellek Ağları (Bidirectional Long Short Term Memory Networks, biLSTM) ile yapılan tahmin çalışmaları incelendiğinde kuraklık tahminine yönelik bir çalışmaya rastlanmamıştır.

Gerçekleştirilen bu çalışmada SYİ'nin Derin Sinir Ağları kullanılarak tahmin performansı analiz edilmiştir. Bu amaç doğrultusunda gerçekleştirilen çalışmanın temel katkıları aşağıda maddeler halinde yer almaktadır.

1- Türkiye'de yer alan Rize, Konya ve Şanlıurfa illerine ait 3,6, 9 ve 12 aylık SYİ değerleri tahmin edilmiştir.

2- Tahmin çalışmasında LSTM katmanından oluşan bir derin sinir ağı mimarisi ve karşılaştırma amaçlı biLSTM katmanından oluşan ikinci bir derin sinir ağı mimarisi geliştirilmiştir. SYİ değerlerinin (3, 6, 9 ve 12 aylık) 1 ileri tahmini ile iki modelin performansı karşılaştırılmıştır.

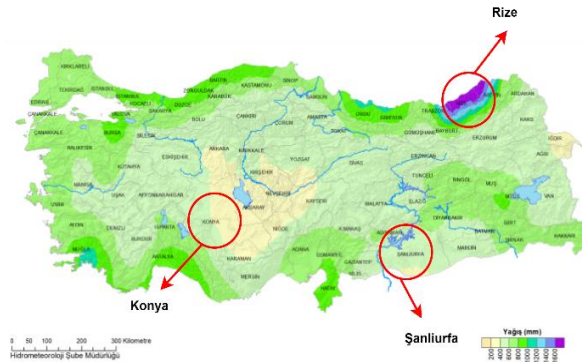
3- Daha sonra biLSTM mimarisi ile SYİ'nin 1-3 ileri tahmini gerçekleştirilmiştir.

Belirtilen amaçlar kapsamında literatürde herhangi bir çalışmaya rastlanmamış olup, derin sinir ağları ve SYİ'nin ileri tahmin performansının analizi açısından bu çalışma özgün katkılar içermektedir.

2 Materyal ve metod

2.1 Çalışma alanı

Tahmin çalışmasında Türkiye'nin iç kısımlarında yer alan ve kapalı havza karakteristiğine sahip olan Konya ili, güney doğusunda yer alan Şanlıurfa ili ve kuzey doğusunda yer alan Rize iline ait 1981-2021 yılları arası aylık yağış verileri kullanılmıştır. SYİ'ni elde etmek için kullanılan yağış verileri, NASA'nın POWER (Prediction of Worldwide Energy Resource) adlı çevrimiçi halka açık veri tabanından elde edilmiştir [22]. Bu veri tabanı, 0,5° enlem ve 0,5° boylam çözünürlüğe sahip olma avantajına sahiptir. Rasool Al-Kilani ve arkadaşlarının yaptığı çalışmada NASA/POWER veri setinin kuraklık tahmini için uygun bir veri seti olduğunu göstermiştir [23].



Şekil 1. Rize, Konya ve Şanlıurfa illerinin yıllık alansal yağış normalleri haritasındaki konumu [24]

Rize ili Türkiye yağış ortalamasının üzerinde yağış almakta olup taşkın olaylarının sıklıkla ortaya çıktığı bir şehirdir.

Konya ilinde yağış şekli çoğunlukla konvektiftir ve Türkiye ortalamasının altında yağış almaktadır. Şanlıurfa ili de Türkiye ortalamasının altında yağış almaktadır.

Rize şehrine ait verilerin en düşük aylık ortalama yağış değeri 0.27 mm/m², en yüksek aylık ortalama yağış değeri 10.90 mm/m²'dir. Konya şehrine ait verilerinin en düşük aylık ortalama yağış değeri 0.0 mm/m², en yüksek aylık ortalama yağış değeri 5.77 mm/m²'dir. Şanlıurfa şehrine ait verilerinin en düşük aylık ortalama yağış değeri 0.0 mm/m², en yüksek aylık ortalama yağış değeri 7.6 mm/m²'dir. Şekil 1 de üç farklı yağış rejimine maruz illerin 1991-2020 yıllarına sahip yıllık alansal yağış normalleri haritasında [24] konumu görülmektedir

2.2 Standardize yağış indeksi

SYİ ilk olarak McKee ve diğerleri tarafından geliştirilmiş olup, sadece yağış değişkeni kullanan bir kuraklık indeksidir [25]. SYİ kuraklığın izlenmesi ve analizinde çok yönlü bir araç olarak günümüzde tüm dünyada yaygın olarak kullanılmaktadır [26]. Kuraklık durumu aylık ve yıllık olmak üzere farklı zaman ölçeklerinde izlenebilmektedir.

SYİ hesaplanması için aşağıdaki işlemler uygulanmaktadır

i. Yağış verilerinden oluşan veri kümesi, bir olasılık yoğunluk fonksiyonuna (PDF) uyarlanır. Bu aşamada uygulanacak parametrik dağılımın seçimi, SYİ'nin doğruluğunu belirlemektedir. McKee ve arkadaşları [25] SYİ'nin hesaplanması aşamasında gamma dağılımının kullanımını önermiştir. Ancak gamma dağılımının uzun sürelerde elde edilen yağış kayıtlarından SYİ eldesinde kullanımı daha uygundur. Gamma dağılımı **Denklem 1** de verilen formül ile elde edilmektedir.

$$g(x) = \frac{1}{\beta^\alpha \tau(\alpha)} Y^{\alpha-1} e^{-Y/\beta} \quad (1)$$

Burada $\alpha > 0$; şekil parametresini, $\beta > 0$ skala parametresini, τ gamma fonksiyonunu ve $Y > 0$ yağış miktarını göstermektedir.

ii. Belirli zaman ölçeği için elde edilen sonuçlar ile bir kümülatif olasılık yoğunluk dağılımı elde edilir [27].

iii. Merkezi limit teoremine göre, 6 ayı aşan uzun zaman periyotlarına geçildiğinde, elde edilen zaman ortalamasının gözlemlenen olasılık dağılımlarını normale kaydırma eğiliminde olacaktır. Gamma dağılımı şekil olarak normale doğru yöneldiği için gamma dağılımı yerine normal olasılık dağılımını kullanmak mümkündür; bu, hesaplama açısından daha kolay ve daha doğru olabilmektedir. Bu nedenle, elde edilen kümülatif olasılık dağılımı, ortalaması sıfır ve varyansı bir olan standart bir normal dağılıma dönüştürülür [28, 29]. Böylece SYİ, **Denklem 2** den de görüleceği gibi yağış verileri kullanılarak belirlenen zaman ölçeğinde yağışın ortalamadan olan farkının standart sapmaya bölünmesi ile elde edilmektedir.

$$SYİ = \frac{Y_i - \bar{Y}_t}{\sigma_i} \quad (2)$$

SYİ genellikle 3, 6, 9, 12, 24 ve 48 aylık olmak üzere farklı zaman ölçekleri için hesaplanmaktadır. SYİ'nin doğru hesaplanması; genellikle kısa dönemlerde toprak nemi koşulları, yağış anormallikleri gibi parametrelerin tahmininde, uzun dönemlerde yeraltı suyu, akarsu akışı ve rezervuar depolaması ve daha uzun vadeli yağış anormallikleri gibi parametrelerin tahmininde önemli olmaktadır. Böylelikle, SYİ, su kaynakları üzerindeki yağış eksikliğinin etkisine dair genel olarak bir fikir vermektedir. SYİ değerinin negatif yönde büyük olması kuraklığın şiddetini göstermektedir. SYİ kuraklık sınıflandırmasına ilişkin bilgiler **Tablo 1** de görülmektedir.

Tablo 1. SYİ kuraklık sınıflandırılması

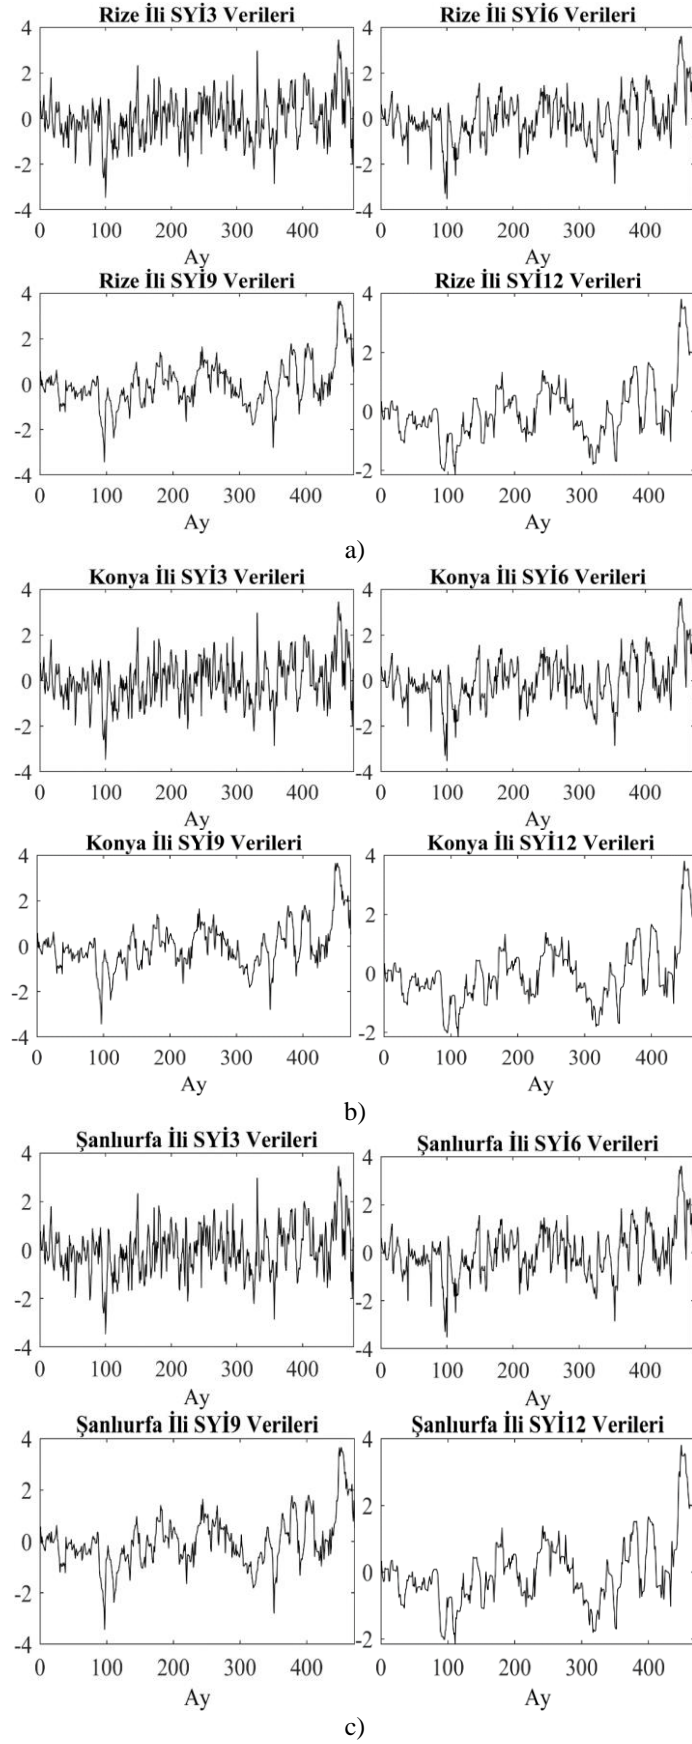
SYİ Değeri	Kuraklık Kategorisi
$SYİ \geq 2$	Olağanüstü Nemli
$1.50 \leq SYİ < 2$	Aşırı Nemli
$1.0 \leq SYİ < 1.5$	Orta Derece Nemli
$-1.0 \leq SYİ < 1.0$	Normale yakın
$-1.5 \leq SYİ < -1.0$	Orta Derece Kurak
$-2.0 \leq SYİ < -1.5$	Şiddetli Kurak
$SYİ < -2.0$	Olağanüstü Kurak

Gerçekleştirilen çalışmada 3,6, 9 ve 12 aylık SYİ'leri hesaplanmıştır. 3 aylık SYİ için SYİ₃, 6 aylık SYİ için SYİ₆, 9 aylık SYİ için SYİ₉ ve 12 aylık SYİ için SYİ₁₂ gösterimi kullanılmıştır. 3-12 aylık SYİ'lerin tahmini için uygulanan giriş ve çıkış değişkenleri **Tablo 2** de yer almaktadır. Tabloda t şuanadaki girişi, t+1 bir ileri zamanı, t+2 ise iki ileri zamanı ve t+3 ise üç ileri zamanı göstermektedir.

Tablo 2. Tahmin çalışmasında kullanılan giriş-çıkış değişkenleri

Giriş Değişkenleri	Bir-İleri Tahmin Değişkeni	İki-İleri Tahmin Değişkeni	Üç-İleri Tahmin Değişkeni
SYİ _{3,t}	SYİ _{3,t+1}	SYİ _{3,t+2}	SYİ _{3,t+3}
SYİ _{6,t}	SYİ _{6,t+1}	SYİ _{6,t+2}	SYİ _{6,t+3}
SYİ _{9,t}	SYİ _{9,t+1}	SYİ _{9,t+2}	SYİ _{9,t+3}
SYİ _{12,t}	SYİ _{12,t+1}	SYİ _{12,t+2}	SYİ _{12,t+3}

Tahmin çalışmasında kullanılan SYİ verileri **Şekil 2** de görülmektedir. **Tablo 3** te tahmin çalışmasında kullanılan Rize, Konya ve Şanlıurfa illerine ait SYİ verilerinin temel istatistiksel değerleri görülmektedir.



Şekil 2. Tahmin çalışmasında kullanılan a) Rize, b) Konya ve c) Şanlıurfa illerine ait SYİ verileri




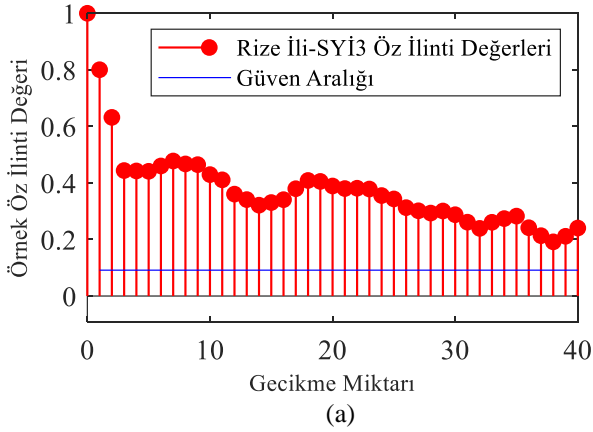
Bu çalışmada her ne kadar ülke içerisinde üç farklı yağış rejimine sahip bölgeler incelenmiş olsa da **Tablo 3** deki temel istatistiksel değerler bu üç bölgenin bir ortak özelliğini sunmaktadır. Bu özellik ise Anadolu coğrafyasına düşen yağışlardaki düzensizlik olarak yorumlanabilir. Her üç bölgeye de düşen yağışlardaki değişkenlik hem olağan üstü

kurak hemde olağanüstü nemli dönemlere sahip olduğunu göstermektedir.


Ayrıca Rize, Konya ve Şanlıurfa illerine ait SYİ'leri örnek öz ilinti (autocorrelation) fonksiyonları da 40 gecikme (lag) miktarı için hesaplanmıştır ve **Şekil 3-5** de görülmektedir.

Tablo 3. Rize, Konya ve Şanlıurfa illerine ait SYİ değerlerinin temel istatistiksel özellikleri

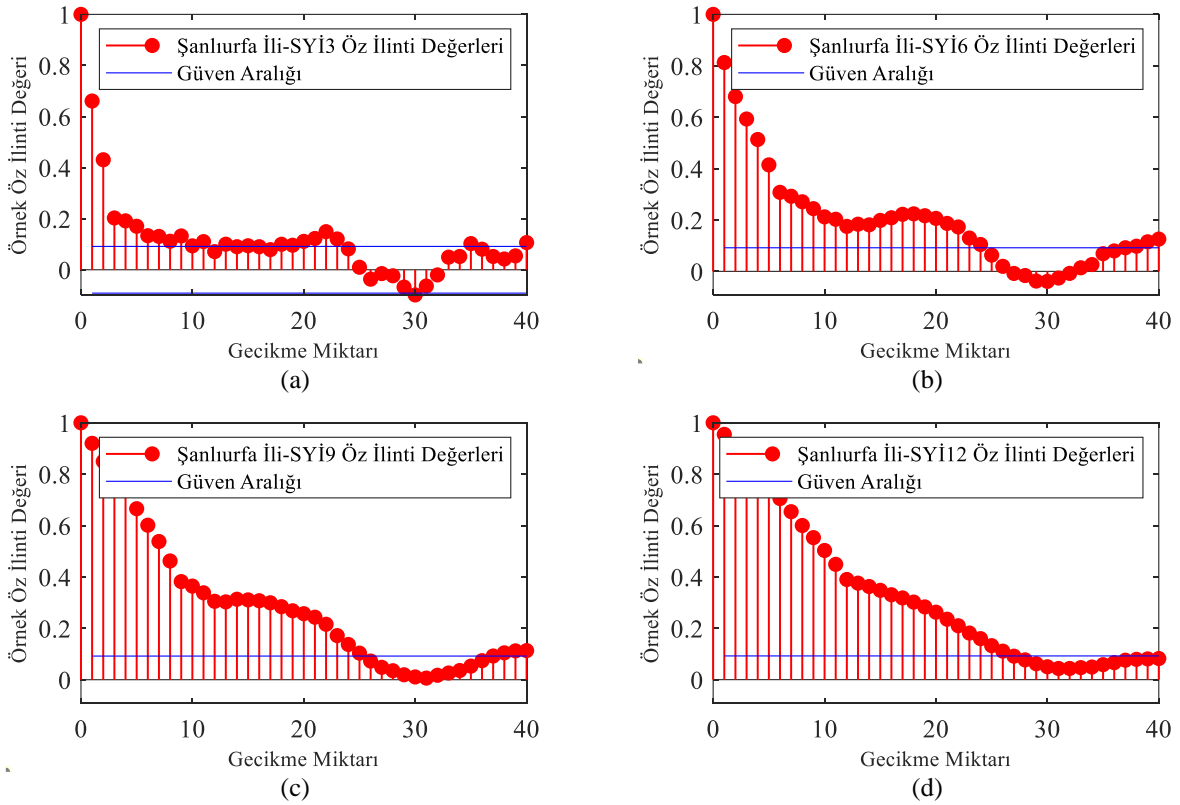
	Rize			Konya			Şanlıurfa		
	En Yüksek	En Düşük	Çarpıklık	En Yüksek	En Düşük	Çarpıklık	En Yüksek	En Düşük	Çarpıklık
SYİ3	3.105	-2.757	0.0401	3.1389	-2.960	0.1459	3.463	-3.476	0.1948
SYİ6	2.910	-2.800	0.0368	2.8280	-2.946	0.0183	3.610	-3.531	0.3023
SYİ9	2.646	-2.787	0.0278	2.6176	-3.113	0.0316	3.665	-3.437	0.7089
SYİ12	2.693	-2.738	0.0466	2.7713	-2.510	0.0429	3.808	-2.161	1.0190



Şekil 3. Rize ili a) SYİ3 b) SYİ6 c) SYİ9 d) SYİ12 örnek öz ilinti değerleri



Şekil 4. Konya ili a) SYİ3 b) SYİ6 c) SYİ9 d) SYİ12 örnek öz ilinti değerleri



Şekil 5. Şanlıurfa ili a) SYİ3 b) SYİ6 c) SYİ9 d) SYİ12 örnek öz ilinti değerleri

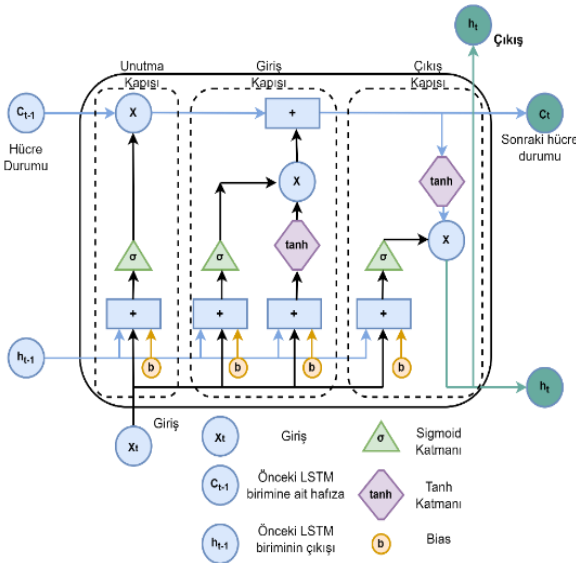
Rize ilinde genel olarak hemen hemen her mevsimde yağış görüldüğü için verinin, sonrası verilerle ilişkisi yüksektir. Bu durum Şekil 3 de görülmektedir. Ayrıca, Konya ve Urfa illerine ait SYİ3 verilerindeki öz ilintiye bakıldığında Rize iline göre daha düşük olduğu görülmektedir.

Genel olarak SYİ12 verilerine ait öz ilintinin SYİ3, SYİ6 ve SYİ9 verilerine göre daha yüksek olduğu Şekil 3-5'te görülmektedir. Bunun sebebi ise genel olarak 12 aylık gibi uzun dönemlerde yağış karakteristiklerinin periyodikleşmesi olarak yorumlanabilir.

Gerçekleştirilen çalışmada SYİ verilerin %80'i eğitim %20'si ise test işlemi için kullanılmıştır. SYİ verilerinin DrinC [30, 31] programı ile elde edilmiş olup, tahmin çalışmaları MATLAB programı aracılığıyla gerçekleştirilmiştir.

2.3 Uzun kısa süreli bellek ağları

Bir derin sinir ağı olan Uzun Kısa Süreli Bellek Ağları ilk defa Hochreiter ve Schmidhuber tarafından ortaya konmuş olup uzun vadeli bağımlılıkları öğrenebilen uzun süreler boyunca bilgileri hatırlayabilen özel bir Tekrarlayan Sinir Ağları (Recurrent neural network, RNN) türüdür. Standart bir RNN gibi tek bir sinir ağı yerine dört katmana sahiptir. LSTM sinir ağının yapısı Şekil 6'da gösterilmektedir [32].



Şekil 6. LSTM hücresi

Tipik bir LSTM ağı hücre durumu ve çeşitli kapılar ile tanımlanmaktadır. Verilerin ileriye doğru akmasına izin veren hücre durumu, ana veri akışını sağlamakta olup, ağı "hafızası" olarak görev yapmaktadır. Veriler, sigmoid kapılar aracılığıyla hücre durumuna eklenebilmekte veya hücre durumundan çıkarılabilmektedir. Kapılar, eğitim sırasında hangi bilgilerin saklanması veya unutulması gerektiğini öğrenebilmektedir. Bir LSTM hücresinde unutma kapısı, giriş kapısı ve çıkış kapısı bulunmaktadır.

Bir LSTM ağı oluşturmanın ilk adımı olan unutma kapısında hangi bilgilerin saklanacağına veya hangi

bilgilerin gerekli olmadığına karar verilir. Önceki gizli durumdan gelen bilgiler (h_{t-1}) ve mevcut girişten (x_t) gelen bilgiler sigmoid (σ) fonksiyonundan geçirilir. Unutma kapısı çıkışında 0 ile 1 arasında değerler elde edilir ve elde edilen değerlerin 0'a yaklaşması, unutma (verinin elenmesi), 1'e yaklaşması, verinin saklanması anlamına gelmektedir. Unutma kapısının çıkışı Denklem 3'te verilen ifade ile tanımlanmaktadır.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b) \quad (3)$$

Burada σ sigmoid fonksiyonunu, b bias değerini ve W_f unutma kapısının ağırlık matrisini göstermektedir.

LSTM hücresinde ikinci olarak, hücre durumunu güncellemenin yanı sıra hücre durumundaki yeni girişten (x_t) gelen bilgilerin kararlaştırılması ve saklanmasını sağlayan giriş kapısı yer almaktadır. Burada, sigmoid katman ve ikinci tanh katmanı olmak üzere iki bölüm içerir. İlk olarak, sigmoid katmanında yeni bilginin güncellenmesine veya yok sayılmasına (0 veya 1) karar verilmektedir ve ikinci olarak, tanh işlevi ile önem derecesine (-1'den 1) karar verilerek bu işlemden geçen değerlere ağırlık verilir. Yeni hücre durumunu güncellemek için elde edilen bu iki değer çarpılır. Bu yeni bellek değeri daha sonra önceki bellek çıktısına ($f_t C_{t-1}$) eklenir ve C_t ile sonuçlanır [32]. Aşağıda yer alan Denklem 4, 5 ve 6'da hücre durumu gösterilmektedir.

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (4)$$

$$N_t = \tanh(W_n[h_{t-1}, x_t] + b_n) \quad (5)$$

$$C_t = C_{t-1}f_t + N_t i_t \quad (6)$$

Çıkış kapısı olan LSTM hücresinin son katmanında, bir sigmoid katman çıkışı (O_t) hücre durumunun hangi bölümlerinin çıktığına ulaşacağına karar vermektedir ve çıkış değeri (h_t), sigmoid katman çıkışı ile hücre durumunun (C_t) tanh katmanından geçirilmesiyle elde edilen -1 ile 1 arasında değişen bir değerle çarpılması sonucu elde edilir. Çıkış kapısına ait eşitlikler aşağıda yer almaktadır.


$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (7)$$

$$h_t = O_t \tanh(C_t) \quad (8)$$

Burada W_o ve b_o , çıkış kapısının sırasıyla ağırlık matrisleri ve bias değeridir.

2.4 Çift yönlü uzun kısa süreli bellek ağları

Çift Yönlü Uzun Kısa Süreli Bellek Ağlarında ileri ve geriye doğru olmak üzere iki yönlü veri akışı olmaktadır. Bunu başarmak için mimari olarak biLSTM, Şekil 7'de gösterildiği gibi ileri ve geri LSTM katmanları içerir. İleri ve geri katmanlardan gelen girdiler, çıktı katmanı tarafından eş zamanlı olarak işlenir [33].



Şekil 7. biLSTM mimarisi

2.5 Önerilen derin sinir ağları mimarisi

Gerçekleştirilen çalışmada 3-12 aylık SYİ değerlerinin 1-3 ileri zamanlı tahmini için LSTM ve biLSTM katmanlarından oluşan derin sinir ağları mimarileri geliştirilmiştir. Birinci modelde LSTM katmanı 2. Modelde ise biLSTM katmanı kullanılmıştır. Mimarinin geliştirilmesi sırasında 32'den başlayarak 256'ya kadar farklı sayılarda hücrelerden oluşan LSTM ve biLSTM katmanları ile farklı sayı ve sıralarda tam bağlantılı katman (fully connected layer) ve seyreltme (drop out) katmanları kullanarak tahmin çalışması gerçekleştirilmiştir. Elde edilen en iyi tahmin performansına göre nihai ağ yapısı belirlenmiş ve Şekil 8.'de görülmektedir. Ayrıca ağı eğitilmesi sırasında 'adam' öğrenme algoritması kullanılmış olup başlangıç öğrenme oranı 0.002, öğrenme oranı seyreltme faktörü (learning rate drop factor) 0.1, öğrenme oranı seyreltme periyodu 100 ve maksimum döngü sayısı 100 olarak belirlenmiştir. Öğrenme sürecinde belirtilen parametreler en iyi öğrenmeyi sağlayacak şekilde deneme yanılma metoduyla tespit edilmiştir.

2.6 Tahmin çalışmasında kullanılan performans parametreleri

SYİ tahmin çalışmasında Korelasyon Katsayısı (R), Ortalama Karesel Hata (MSE), Belirlilik Katsayısı (R^2) ve Ortalama Mutlak Hata (MAE), kriterlerine göre model performansları değerlendirilmiştir.

Ortalama mutlak hata, veri kümesindeki gözlemlenen ve tahmin edilen değerler arasındaki mutlak farkın ortalamasını göstermektedir ve Denklem 9'da yer alan formül ile elde edilmektedir.

$$MAE = \frac{1}{N} \sum_{i=1}^N |X_{gözlemlenen,i} - X_{tahmin edilen,i}| \quad (9)$$

Ortalama karesel hata veri kümesindeki gözlemlenen ve tahmin edilen değerler arasındaki farkın karesinin ortalamasıyla hesaplanır ve Denklem 10 ile ifade edilmektedir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (X_{gözlemlenen,i} - X_{tahmin edilen,i})^2 \quad (10)$$

Korelasyon katsayısı, gözlemlenen ve tahmin edilen veriler arasındaki ilişkinin derecesini, yönünü ve önemini göstermekte ve -1 ile 1 arasında bir değere sahiptir. Denklem 11 ile ifade edilmektedir.

$$R = \frac{1}{N-1} \sum_{i=1}^N \left(\frac{X_{gözlemlenen,i} - \mu_X}{\sigma_X} \right) \left(\frac{X_{tahmin edilen,i} - \mu_{X_{tah}}}{\sigma_{X_{tah}}} \right) \quad (11)$$

Bu eşitlikte, μ_X gözlemlenen, $\mu_{X_{tah}}$ ise tahmin edilen zaman serisinin ortalamasıdır ve σ_X gözlemlenen, $\sigma_{X_{tah}}$ ise tahmin edilen zaman serisinin standart sapmasıdır.

Belirlilik katsayısı, modellerin tahmin yeteneğini ölçmek için yaygın olarak kullanılmaktadır. Bu istatistiksel ölçüt, $-\infty$ ile 1 arasında bir değere sahiptir. R^2 değeri 1 değerine yaklaştıkça gözlemlenen ve tahmin edilen veriler arasındaki ilişkinin arttığını göstermektedir ve R^2 değeri Denklem 12 kullanılarak hesaplanır.

$$R^2 = 1 - \frac{\sum_{i=1}^N [X_{gözlemlenen,i} - X_{tahmin edilen,i}]^2}{\sum_{i=1}^N [X_{gözlemlenen,i} - \mu_X]^2} \quad (12)$$


3 Sonuçlar ve tartışma

Bu çalışmada Rize, Konya ve Şanlıurfa illerine ait SYİ3, SY6, SY9 ve SY12'nin 1-3 ileri zamanlı tahmini için derin sinir ağları yaklaşımı içeren modeller geliştirilmiştir.

Derin sinir ağları mimarisinin geliştirilmesi aşamasında iki model kullanılmıştır. Model 1 olarak isimlendirilen LSTM katmanı içeren model ile Model 2 olarak isimlendirilen ve biLSTM katmanı içeren modellerin performansı SYİ'lerin bir ileri zamanlı tahmini ile karşılaştırılmıştır.

Elde edilen performans sonuçları Tablo 4'te görülmektedir.

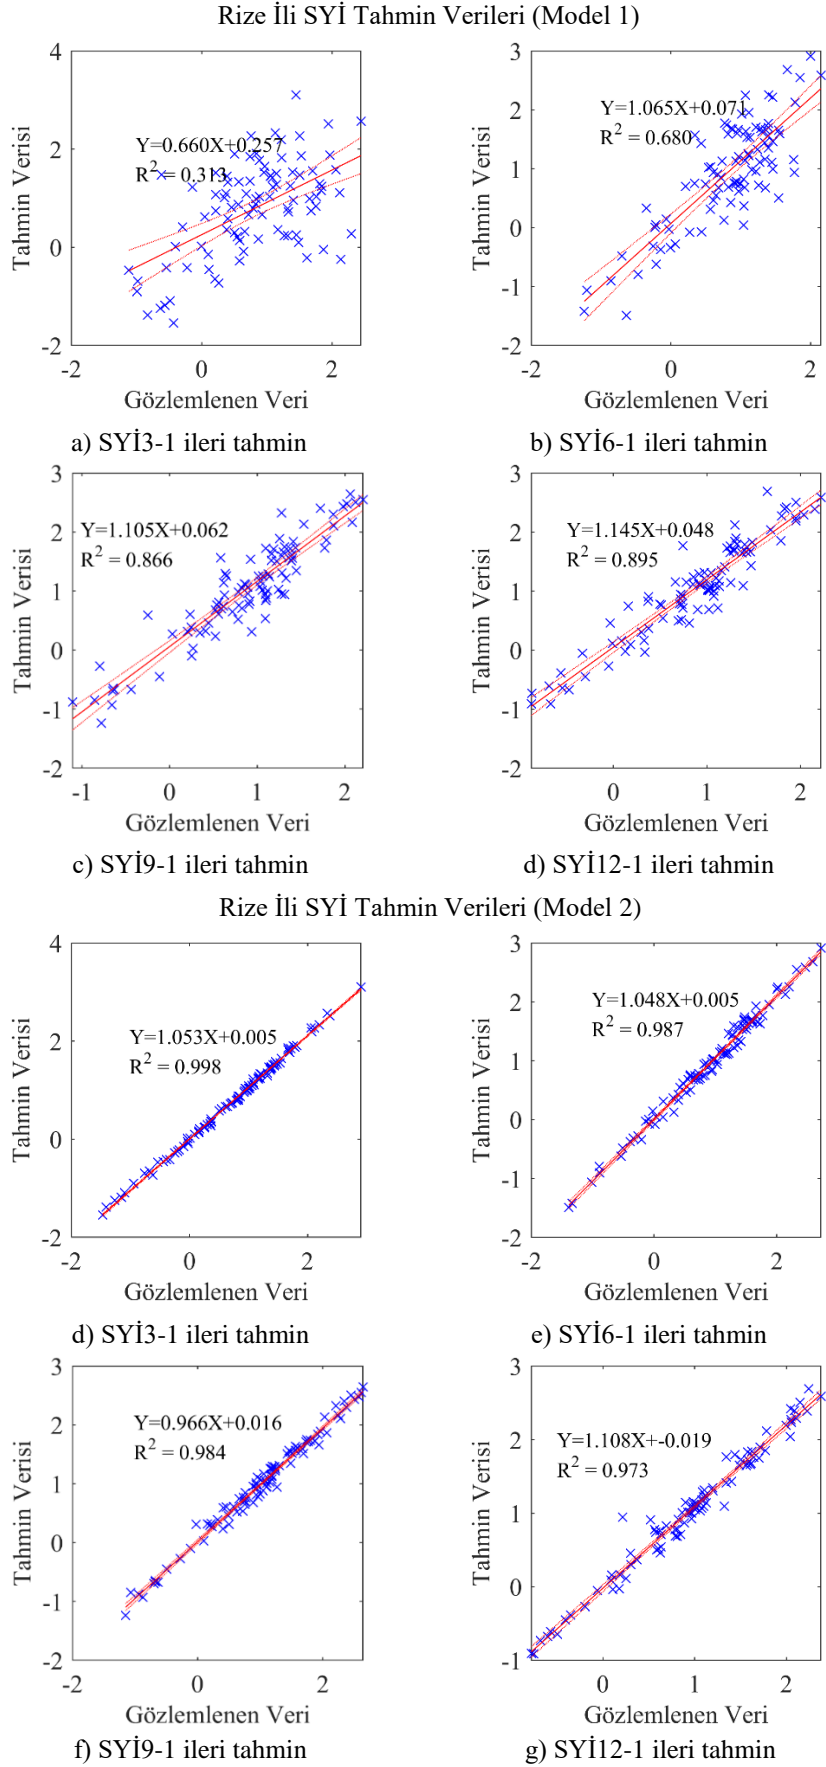
Tahmin çalışmasında elde edilen sonuçları ayrıca görsel olarak değerlendirebilmek için saçılma grafikleri çizilmiştir. Saçılma grafikleri ise Şekil 9-11'de görülmektedir.




Şekil 8. Tahmin çalışmasında kullanılan mimari

Tablo 4. Rize, Konya ve Şanlıurfa illeri 1 ileri zamanlı SYİ tahmin değerleri

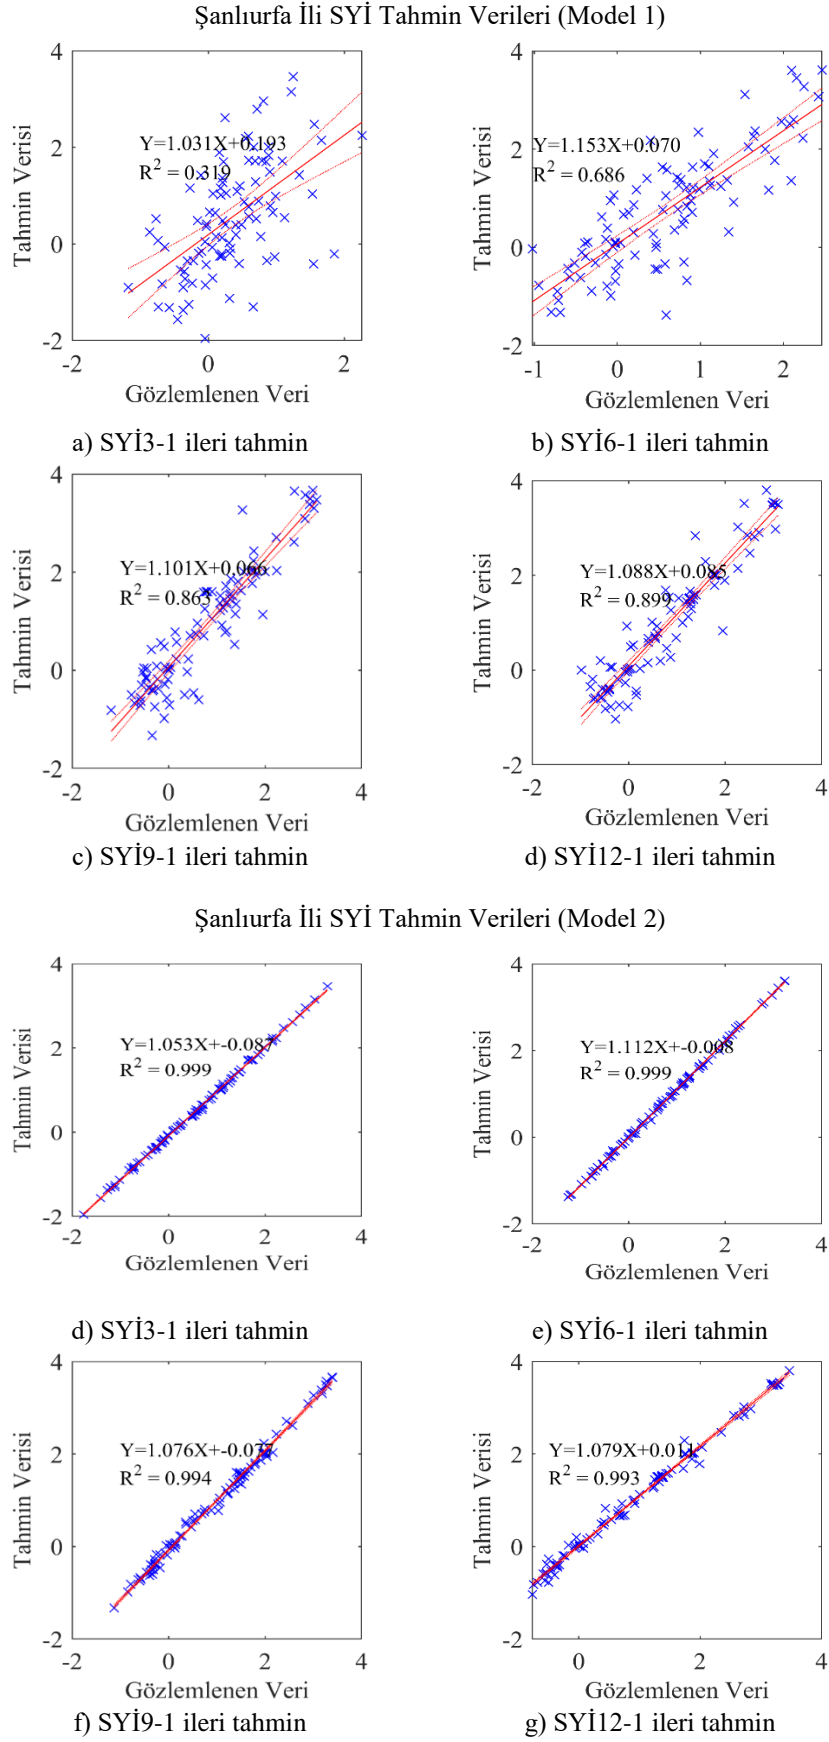
Rize İli								
	Model 1 Performans Sonuçları				Model 2 Performans Sonuçları			
	MSE	MAE	R	R ²	MSE	MAE	R	R ²
SYİ3-1ileri	0.6966	0.6647	0.5590	0.3125	0.0065	0.0628	0.9988	0.9976
SYİ6-1ileri	0.2715	0.4228	0.8249	0.6804	0.0140	0.0968	0.9936	0.9873
SYİ9-1ileri	0.1279	0.2837	0.9304	0.8657	0.0129	0.0909	0.9920	0.9841
SYİ12-1ileri	0.1141	0.2662	0.9462	0.8952	0.0323	0.1365	0.9866	0.9735
Konya İli								
	Model 1 Performans Sonuçları				Model 2 Performans Sonuçları			
	MSE	MAE	R	R ²	MSE	MAE	R	R ²
SYİ3-1ileri	0.5025	0.5585	0.6655	0.4429	0.0334	0.0790	0.9848	0.9697
SYİ6-1ileri	0.2979	0.4219	0.8429	0.7104	0.0383	0.0741	0.9832	0.9667
SYİ9-1ileri	0.2180	0.3675	0.8891	0.7905	0.0288	0.0771	0.9866	0.9734
SYİ12-1ileri	0.1345	0.2786	0.9275	0.8603	0.0147	0.0856	0.9935	0.9870
Şanlıurfa İli								
	Model 1 Performans Sonuçları				Model 2 Performans Sonuçları			
	MSE	MAE	R	R ²	MSE	MAE	R	R ²
SYİ3-1ileri	0.9537	0.7650	0.5650	0.3192	0.0080	0.0773	0.9994	0.9988
SYİ6-1ileri	0.4940	0.5559	0.8280	0.6855	0.0204	0.1125	0.9996	0.9992
SYİ9-1ileri	0.2475	0.3848	0.9289	0.8629	0.0168	0.1019	0.9971	0.9942
SYİ12-1ileri	0.2033	0.3365	0.9483	0.8992	0.0281	0.1321	0.9964	0.9928



Şekil 9. Rize iline ait SYİlerin 1 ileri zamanlı tahminine ait saçılma grafikleri



Şekil 10. Konya iline ait SYİlerin 1 ileri zamanlı tahminine ait saçılma grafikleri



Şekil 11. Şanlıurfa iline ait SYİlerin 1 ileri zamanlı tahminine ait saçılma grafikleri

Tablo 4’te verilen sonuçlar incelendiğinde biLSTM katmanı kullanılan Derin Sinir Ağı mimarisinin tahmin başarısının LSTM katmanı kullanan mimariye göre oldukça iyi olduğu görülmüştür.

Tahmin çalışmasının ikinci aşamasında Model 2 kullanılarak 2 ve 3 ileri zamanlı SYİ’lerin tahmini gerçekleştirilmiştir. Tahmin çalışmasına ait performans parametre değerleri ve tahmin sonuçlarını gösteren saçılma grafikleri Tablo 5 ve Şekil 12-15’te görülmektedir. Ayrıca örnek olarak SY3 2 ve 3 ileri test ve tahmin verileri Şekil 15-17’de görülmektedir

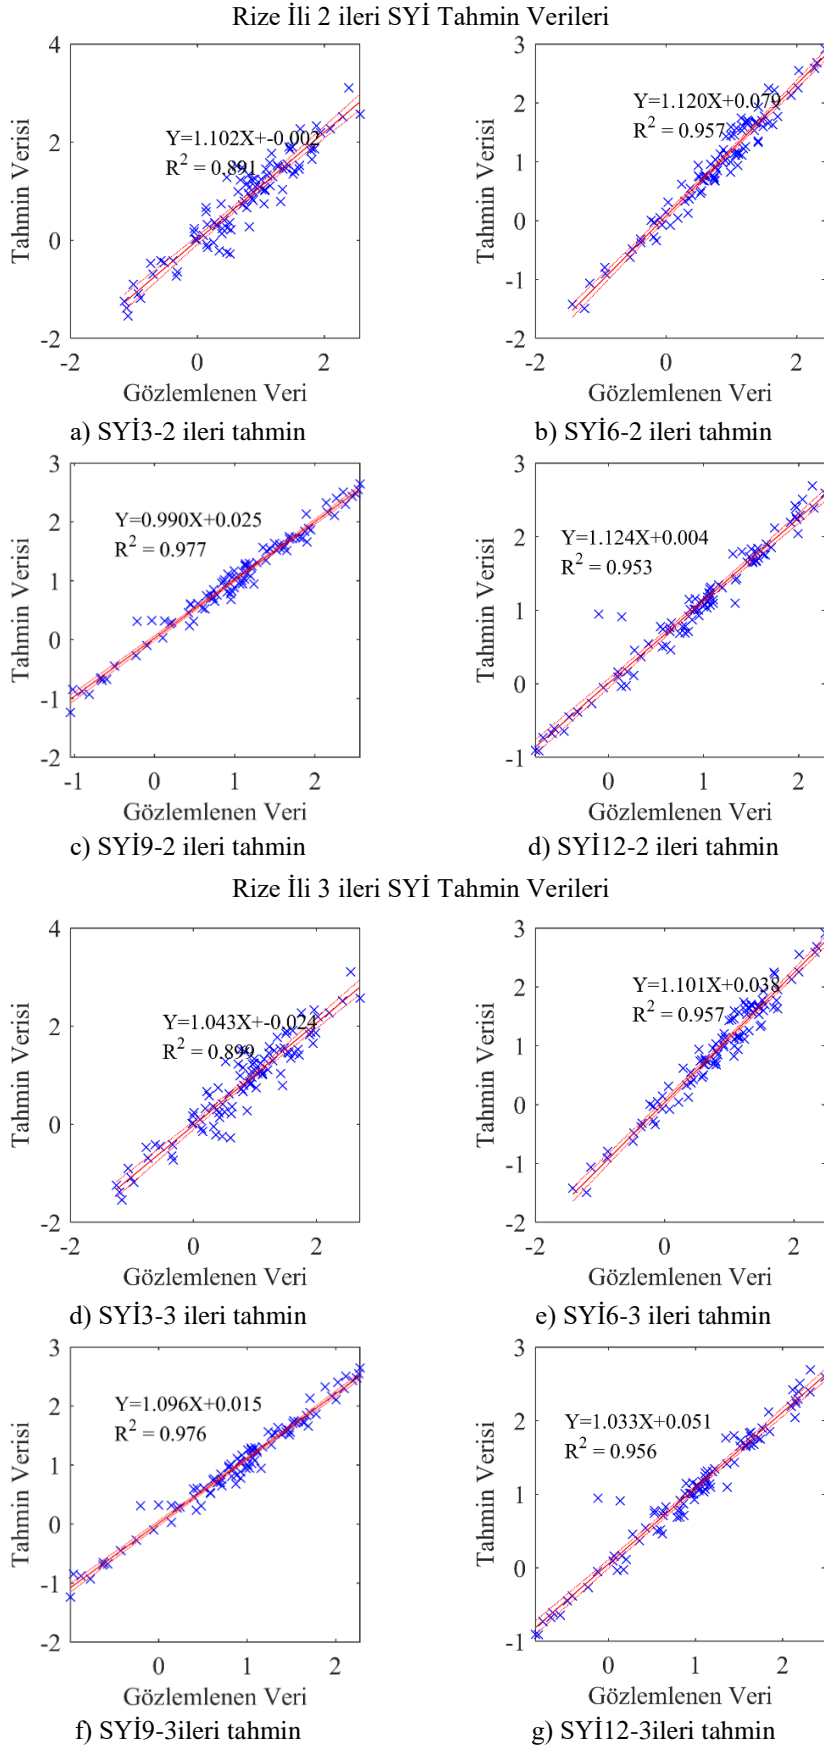
Tablo 5 incelendiğinde 1 giriş 2 ve 3 ileri zamanlı tahmin çalışmasında biLSTM mimarisinin tahmin performansının oldukça iyi olduğu görülmektedir.

Şekil 12-14 te verilen saçılma grafikleri ve Şekil 15-17 de verilen zaman serisi verilerinden de görüleceği üzere tahmin verilerinin gerçek verileri yakından izlemektedir.

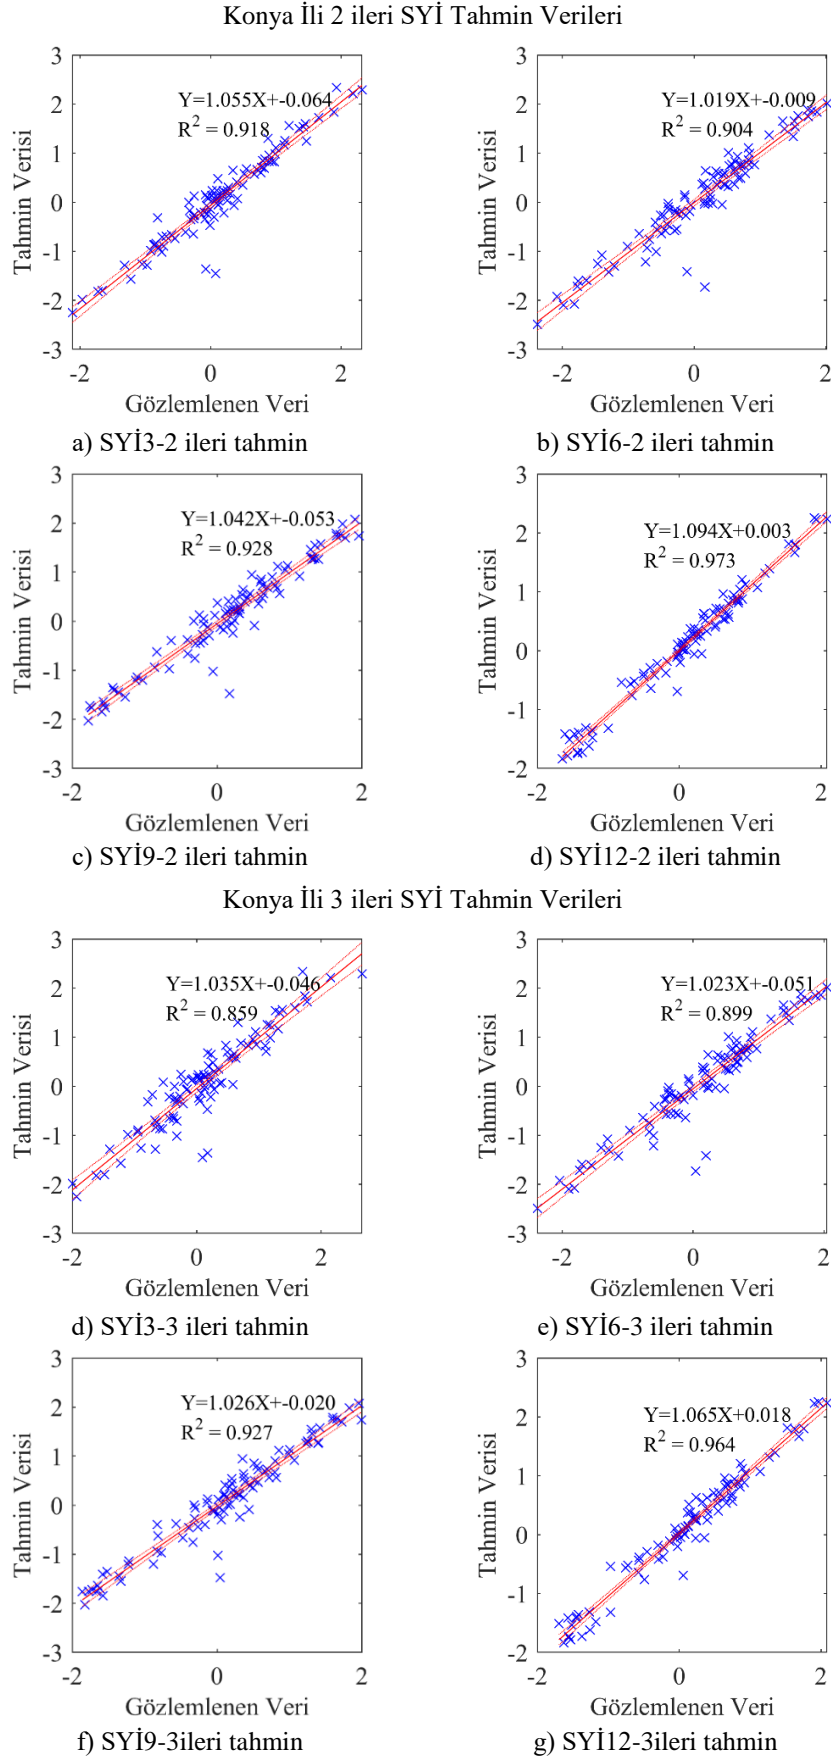
Literatürde kuraklık indekslerine yönelik yapılan tahmin çalışmaları incelendiğinde SYİ tahminine yönelik YSA, Destek vektör makineleri (DVM) ve Dalgacık sinir ağıları kullan bir çalışmada 0.95 değerine ulaşan R^2 değerinin elde edildiği görülmüştür [16]. Ayrıca akış kuraklık indeksinin (Streamflow Drought Index) tahmine yönelik gerçekleştirilen bir çalışmada Dalgacık Dönüşümü ve Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi kullanılmış olup 0.94 R^2 değeri elde edilmiştir [17]. Kuraklık tahminine yönelik kullanılan indeksler ve tahmin yöntemleri hakkında yazılan bir derleme çalışmasından da görüleceği üzere kuraklık tahminine yönelik YSA, ANFIS, DVM, Rastgele Orman ve derin öğrenme modellerinden LSTM mimarilerinin kullanıldığı görülmüştür [18]. Kuraklık tahminine yönelik kullanılan derin öğrenme modellerinin sınırlı sayıda olduğu ve tahmin amacıyla genellikle LSTM mimarilerinin kullanıldığı görülmüştür.

Tablo 5. Rize, Konya ve Şanlıurfa illeri 2-3 ileri zamanlı SYİ tahmin değerleri

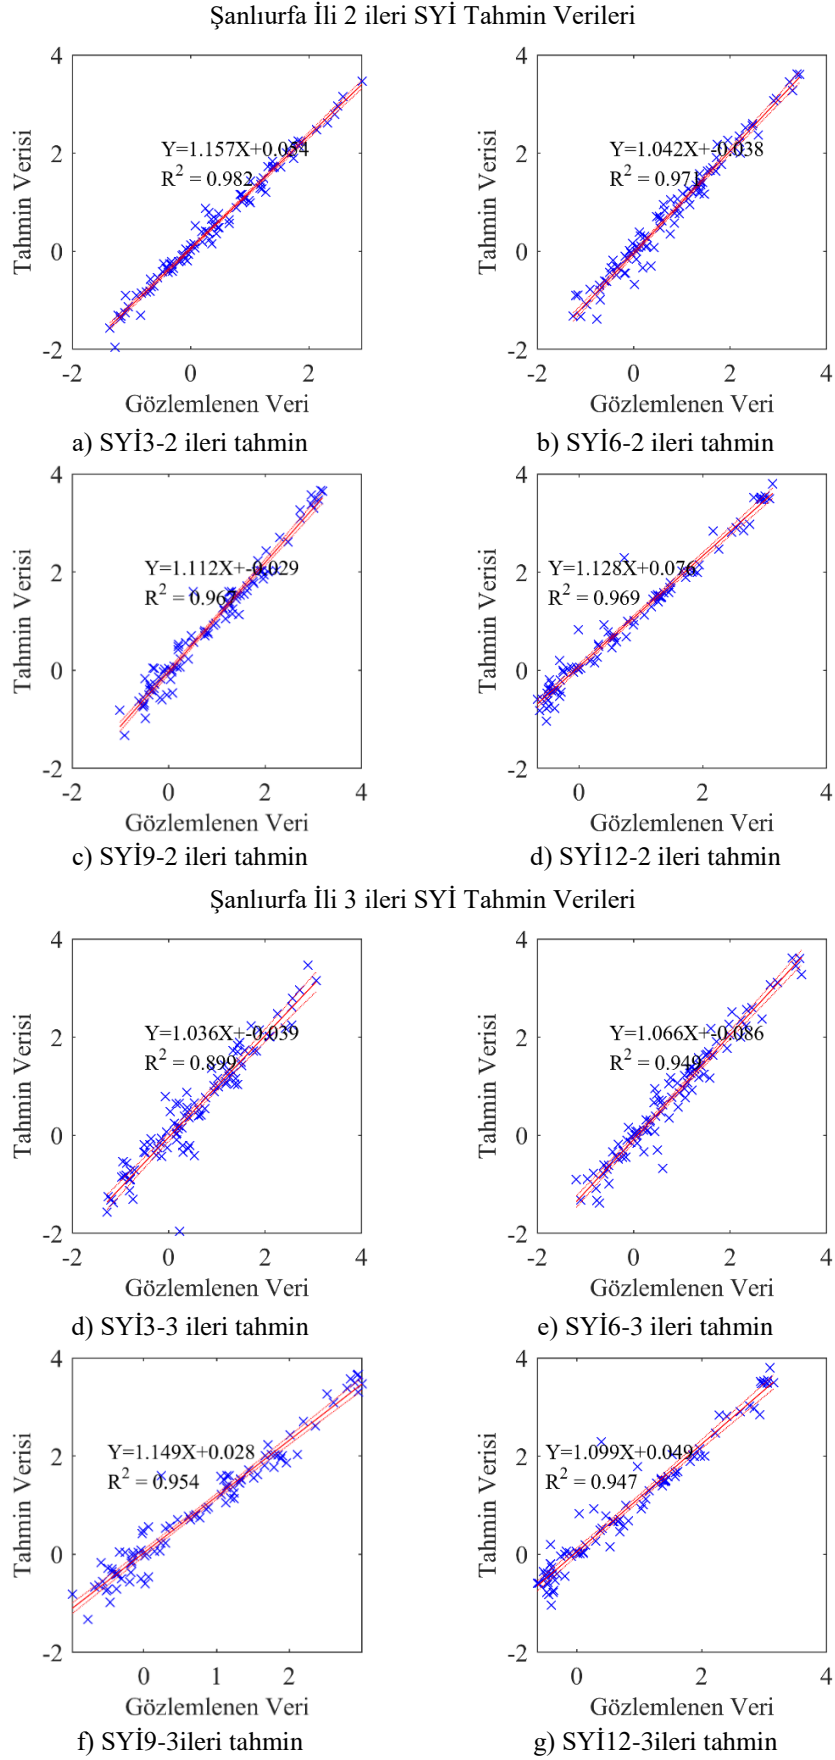
Rize İli								
	İki İleri Tahmin Sonuçları				Üç İleri Tahmin Sonuçları			
	MSE	MAE	R	R^2	MSE	MAE	R	R^2
SYİ3	0.1119	0.2571	0.9438	0.8907	0.0933	0.2355	0.9484	0.8994
SYİ6	0.0729	0.2110	0.9782	0.9568	0.0554	0.1871	0.9784	0.9573
SYİ9	0.0260	0.1315	0.9883	0.9774	0.0337	0.1499	0.9880	0.9762
SYİ12	0.0558	0.1723	0.9760	0.9526	0.0387	0.1291	0.9776	0.9557
Konya İli								
	İki İleri Tahmin Sonuçları				Üç İleri Tahmin Sonuçları			
	MSE	MAE	R	R^2	MSE	MAE	R	R^2
SYİ3	0.0798	0.1737	0.9580	0.9178	0.1314	0.2548	0.9267	0.8588
SYİ6	0.0977	0.1989	0.9506	0.9037	0.1062	0.2064	0.9479	0.8986
SYİ9	0.0778	0.1855	0.9636	0.9285	0.0775	0.1898	0.9628	0.9269
SYİ12	0.0327	0.1415	0.9864	0.9730	0.0390	0.1507	0.9816	0.9635
Şanlıurfa İli								
	İki İleri Tahmin Sonuçları				Üç İleri Tahmin Sonuçları			
	MSE	MAE	R	R^2	MSE	MAE	R	R^2
SYİ3	0.0617	0.1895	0.9911	0.9824	0.1387	0.2469	0.9481	0.8989
SYİ6	0.0449	0.1582	0.9851	0.9705	0.0802	0.2059	0.9743	0.9493
SYİ9	0.0718	0.1954	0.9835	0.9673	0.1196	0.2552	0.9768	0.9541
SYİ12	0.1059	0.2354	0.9845	0.9692	0.1210	0.2281	0.9732	0.9471



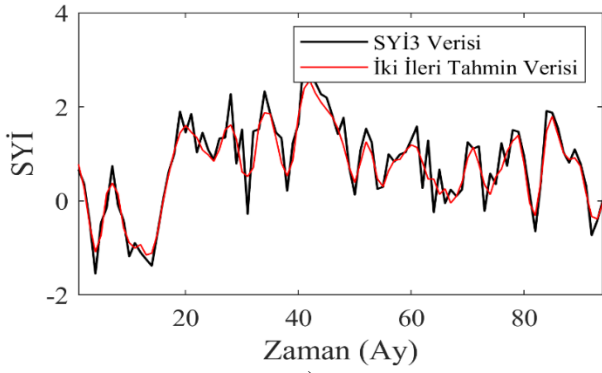
Şekil 12. Rize iline ait SYİlerin 2-3 ileri zamanlı tahminine ait saçılma grafikleri




Şekil 13. Konya iline ait SYİlerin 2-3 ileri zamanlı tahminine ait saçılma grafikleri



Şekil 14. Şanlıurfa iline ait SYİlerin 2-3 ileri zamanlı tahminine ait saçılma grafikleri

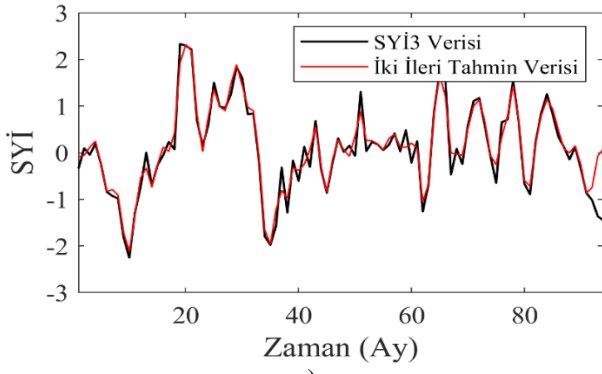


a)




b)

Şekil 15. Rize ili SY3 a) iki ileri b) üç ileri tahmin verileri




a)

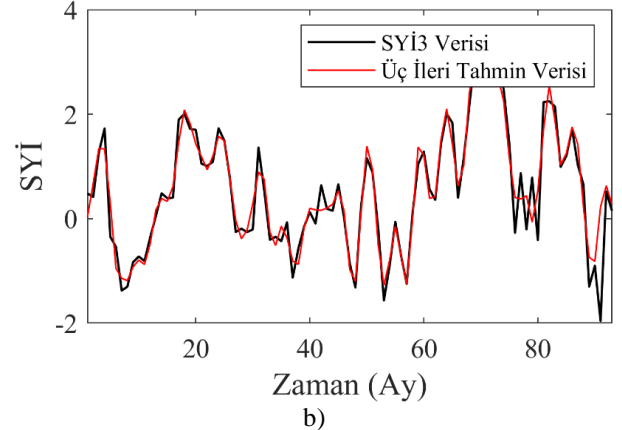


b)

Şekil 16. Konya ili SY3 a) iki ileri b) üç ileri tahmin verileri



a)



b)

Şekil 17. Şanlıurfa ili SY3 a) iki ileri b) üç ileri tahmin verileri

Bu çalışmada ise SYİ tahmini için LSTM ve biLSTM katmanlarından oluşan bir Derin Sinir Ağları mimarisi geliştirilmiştir. Geliştirilen mimarilerin performansı SYİ3, SYİ6, SYİ9 ve SYİ12 verilerinin bir ileri zamanlı tahmini sonuçları ile karşılaştırılmıştır. Elde edilen MSE, MAE, R ve R^2 performans parametrelerine bağlı sonuçlara göre, biLSTM modelinin performansının LSTM modelinin performansına göre çok daha iyi olduğu görülmüştür. Ayrıca biLSTM modeli ile SYİ3, SYİ6, SYİ9 ve SYİ12 verilerinin 2,3 ileri zamanlı tahmini gerçekleştirilmiş olup, performans parametreleri ve saçılma grafikleri ile değerlendirilmiştir. Ayrıca biLSTM modelinin tahmin yeteneğini test etmek için illerdeki SYİ3, SYİ6, SYİ9 ve SYİ12 verilerinin 4-14 ileri zamanlı tahmin performansı da analiz edilmiştir. Önerilen modelin 13 ve daha ileri tahmin performansı incelendiğinde R^2 parametresinin 0.50 değerinin altına düştüğü, yani tahmin yeteneğini kaybettiği görülmüştür. Buradan biLSTM modelinin 12 ileri aya kadar tahmin yeteneğine sahip olduğu ve gürbüz bir yöntem olduğu görülmektedir. Elde edilen sonuçlara göre biLSTM içeren derin sinir ağlarının SYİ verilerinin tahmininde kullanılabileceği ve önemli bir araç olabileceği ortaya konmuştur.

Çıkar çatışması

Yazar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %14

Kaynaklar

- [1] A. Dai, Drought under global warming: a review, Wiley Interdisciplinary Reviews: Climate Change, 2, 45-65, 2011. <https://doi.org/10.1002/wcc.81>.
- [2] T. D. Delbiso, C. Altare, J. M. Rodriguez-Llanes, S. Doocy, and D. Guha-Sapir, Drought and child mortality: a meta-analysis of small-scale surveys from Ethiopia, Scientific reports, 7(1), 1-8, 2017. <https://doi.org/10.1038/s41598-017-02271-5>
- [3] S. E. Nicholson, C. J. Tucker, and M. B. Ba, Desertification, drought, and surface vegetation: An example from the West African Sahel, Bulletin of the American Meteorological Society, 79(5), 815-830, 1998. [https://doi.org/10.1175/15200477\(1998\)079<0815:DDASVA>2.0.CO;2](https://doi.org/10.1175/15200477(1998)079<0815:DDASVA>2.0.CO;2)
- [4] A. Grainger, S. Smith, V. R. Squires, and E. P. Glenn, Desertification, and climate change: the case for greater convergence, Mitigation and Adaptation Strategies for Global Change, 5(4), 361-377, 2000. <https://doi.org/10.3354/cr011051>
- [5] C. H. Chung and J. D. Salas, Drought occurrence probabilities and risks of dependent hydrologic processes. Journal of Hydrologic Engineering, 5(3), 259-268, 2000. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2000\)5:3\(259\)](https://doi.org/10.1061/(ASCE)1084-0699(2000)5:3(259))
- [6] J. H. Stage, L. M. Tallaksen, C. Y. Xu and H. A. Van Lanen, Standardized precipitation-evapotranspiration index (SPEI): Sensitivity to potential evapotranspiration model and parameters. In Hydrology in a changing world, 363, 367-373, 2014.
- [7] W. M. Alley, The Palmer drought severity index: limitations and assumptions. Journal of Applied Meteorology and Climatology, 23(7), 1100-1109, 1984. [https://doi.org/10.1175/15200450\(1984\)023<1100:TPDSIL>2.0.CO;2](https://doi.org/10.1175/15200450(1984)023<1100:TPDSIL>2.0.CO;2)
- [8] D. W. Kim, H.R. Byun, ve K. S. Choi, Evaluation, modification, and application of the Effective Drought Index to 200-Year drought climatology of Seoul, Korea. Journal of hydrology, 378(1-2), 1-12, 2009. <https://doi.org/10.1016/j.jhydrol.2009.08.021>
- [9] G. Tsakiris, D. Pangalou ve H. Vangelis, Regional drought assessment based on the Reconnaissance Drought Index (RDI), Water resources management, 21(5), 821-833, 2007. <https://doi.org/10.1007/s11269-006-9105-4>
- [10] N. B. Guttman, Comparing the palmer drought index and the standardized precipitation index 1, JAWRA Journal of the American Water Resources Association, 34(1), 113-121, 1998. <https://doi.org/10.1111/j.1752-1688.1998.tb05964.x>
- [11] M. Svoboda, M. Hayes, and D. Wood, Standardized precipitation index: user guide, 2012.
- [12] S. Sırdaş, Z. Sen, Spatio-temporal drought analysis in the Trakya region, Turkey, Hydrological Sciences Journal, 48(5), 809-820, 2003. <https://doi.org/10.1623/hysj.48.5.809.51458>
- [13] N. B. Guttman, Accepting the standardized precipitation index: a calculation algorithm 1. JAWRA Journal of the American Water Resources Association, 35(2), 311-322, 1999. <https://doi.org/10.1111/j.1752-1688.1999.tb03592.x>
- [14] A. Ahani, M. Shourian, ve P. Rahimi Rad, Performance assessment of the linear, nonlinear and nonparametric data driven models in river flow forecasting. Water resources management, 32(2), 383-399, 2018. <https://doi.org/10.1007/s11269-017-1792-5>
- [15] D. P. Solomatine and A. Ostfeld, Data-driven modelling: some past experiences and new approaches, Journal of hydroinformatics, 10(1), 3-22, 2008. <https://doi.org/10.2166/hydro.2008.015>
- [16] A. Belayneh, J. Adamowski, Standard precipitation index drought forecasting using neural networks, wavelet neural networks, and support vector regression. Applied computational intelligence and soft computing, 6, 6, 2012. <https://doi.org/10.1155/2012/794061>
- [17] H. Citakoglu, Y. Ozeren, ve O. Coskun, Short Time Drought Estimation of Sakarya Basin Station With Wavelet Model-Adaptive Neuro-Fuzzy Inference System, IWW'2019: International Conference on Image Processing, Wavelet and Applications, sayfa 190-197, Kocaeli, Türkiye, 18 - 20 Ekim 2019.
- [18] A. Dikshit, B. Pradhan, ve M. Santosh, Artificial neural networks in drought prediction in the 21st century-A scientometric analysis, Applied Soft Computing, 114, 2022. <https://doi.org/10.1016/j.asoc.2021.108080>
- [19] T. Fischer ve C. Krauss, Deep learning with long short-term memory networks for financial market predictions. European journal of operational research, 270(2), 654-669, 2018. <https://doi.org/10.1016/j.ejor.2017.11.054>
- [20] D. K. Roy, Long short-term memory networks to predict one-step ahead reference evapotranspiration in a subtropical climatic zone, Environmental Processes, 8(2), 911-941, 2021. <https://doi.org/10.1007/s40710-021-00512-4>
- [21] S. Ghimire, R.C. Deo, N. Raj, ve J. Mi, Deep solar radiation forecasting with convolutional neural network and long short-term memory network algorithms. Applied Energy, 253, 2019. <https://doi.org/10.1016/j.apenergy.2019.113541>
- [22] NASA, 2020b, National Aeronautics and Space Administration (NASA), Langley Research Center (LaRC), POWER Data Access Viewer, Single Point Data Access (2020) online resource, <https://power.larc.nasa.gov/data-access-viewer>, Accessed 01 May 2022
- [23] M. R. Al-Kilani, M. Rahbeh, J. Al-Bakri, T. Tadesse, ve C. Knutson, Evaluation of Remotely Sensed Precipitation Estimates from the NASA POWER Project for Drought Detection over Jordan. Earth Systems and Environment, 5(3), 561-573, 2021. <https://doi.org/10.1007/s41748-021-00245-2>

- [24] Turkish State Meteorological Service, TURKIYE, <https://mgm.gov.tr/veridegerlendirme/aylik-normal-yagis-dagilimi.aspx>, Accessed 21 September 2022
- [25] T. B. McKee, N. J. Doesken ve J. Kleist, The relationship of drought frequency and duration to time scales, In Proceedings of the 8th Conference on Applied Climatology, 17(22), 179-183, 1993.
- [26] G. Tsakiris, H. Vangelis, Towards a drought watch system based on spatial SPI. Water resources management, 18(1), 1-12, 2004. <https://doi.org/10.1023/B:WARM.0000015410.47014.a4>
- [27] D.C. Edwards, ve T. B. McKee, Characteristics of 20th Century Drought in the United States at Multiple Times Scales. Atmospheric Science Paper, 634, 1-30, 1997.
- [28] F.K. Sönmez, A. U. Koemuescue, A. Erkan ve E. Turgu, An analysis of spatial and temporal dimension of drought vulnerability in Turkey using the standardized precipitation index, Natural Hazards, 35(2), 243-264, 2005. <https://doi.org/10.1007/s11069-004-5704-7>
- [29] P. Angelidis, F. Maris, N. Kotsovinos, ve V. Hrissanthou, Computation of drought index SPI with alternative distribution functions. Water resources management, 26(9), 2453-2473, 2012. <https://doi.org/10.1007/s11269-012-0026-0>
- [30] D. Tigkas, H. Vangelis, G. Tsakiris, DrinC: Ga software for drought analysis based on drought indices. Earth Science Informatics, 8(3), 697-709, 2015. <http://dx.doi.org/10.1007/s12145-014-0178-y>
- [31] D. Tigkas, H. Vangelis, N. Proutsos, G. Tsakiris, Incorporating aSPI and eRDI in Drought Indices Calculator (DrinC) software for agricultural drought characterisation and monitoring. Hydrology, 9(6), 100, 2022. <https://doi.org/10.3390/hydrology9060100>
- [32] S. Hochreiter ve J. Schmidhuber, Long short-term memory. Neural computation, 9(8), 1735-1780, 1997. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [33] S. Zhang, D. Zheng, X. Hu ve M. Yang, Bidirectional long short-term memory networks for relation classification, In Proceedings of the 29th Pacific Asia conference on language, information and computation, 73-78, 2015.

