

# Çok katmanlı algılayıcı ağı, uzun-kısa süreli bellek ağı ve regresyon yöntemleri ile tarımsal kurutma tahmini

*Prediction of agricultural drying using multi-layer perceptron network, long short-term memory network and regression methods*

İlyas KACAR<sup>1,a</sup>, Cem KORKMAZ<sup>2,b</sup>

<sup>1</sup>Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, 51240, Niğde

<sup>2</sup>Çukurova Üniversitesi, Ziraat Fakültesi, Tarım Makineleri ve Teknolojileri Mühendisliği Bölümü, 01380, Adana

• Geliş tarihi / Received: 28.04.2022

• Düzeltilek geliş tarihi / Received in revised form: 17.09.2022

• Kabul tarihi / Accepted: 09.10.2022

## Öz

Tarımın önemli bir parçası olan gübrenin üretiminde kullanılan işlemlerden biri de kurutma işlemidir. Uygun kurutma parametrelerinin belirlenebilmesi, hem ürün kalitesi hem de üretim verimliliği açısından önemlidir. Kurutma işlem parametrelerinin belirlenmesinde regresyon yöntemleri sıklıkla kullanılmaktadır. Bu çalışmada regresyon yönteminin yanı sıra yapay sinir ağı, uzun-kısa süreli bellek gibi makine öğrenme teknikleri de incelenmiştir. Modeller için %5 azot, %10 fosfor karışımından oluşan ticari bir organomineral gübrenin 70°C, 75°C ve 80°C sıcaklıklarda kurutulması işleminden elde edilen veriler kullanılmıştır. Modellerden elde edilen sonuçlar ile deneysel sonuçlar kıyaslanmıştır. Her bir modelin tahmin performansları sunulmuştur. Uygun kurutma parametrelerini yakalamak, ürünün kurutma verimi açısından önemlidir. İlave olarak, kurutma simülasyonlarında, başarılı sonuçlar elde edilmesinde, model seçimi önemli rol oynamaktadır. Netice olarak, yapay sinir ağı ile oluşturulan modelin tahmin performansının diğerlerine göre daha başarılı olduğu tespit edilmiştir. Regresyonlar, mevcut verinin modellenmesinde verimli iken, ileriye yönelik tahminlerde başarılı olamamaktadırlar. Ayrıca kurutma verisi içerisindeki tepe ve çukurları tahmin etmede de yetersiz kalmaktadır.

**Anahtar kelimeler:** Çok katmanlı algılayıcı ağı, Makine öğrenmesi, Organik gübre, Regresyon, Tarımsal kurutma, Uzun-kısa süreli bellek

## Abstract

One of the processes used in the production of fertilizers, which has become an important part of agriculture, is the drying process. Determination of proper drying parameters is important both in terms of product quality and production efficiency. Regression methods are used to determine the drying process parameters frequently. In this study, in addition to the regression method, machine learning techniques are also examined such as artificial neural network, long short-term memory method. The data obtained from the drying process of a commercial organomineral fertilizer consisting of a mixture of 5% nitrogen and 10% phosphorus at 70°C, 75°C, and 80°C were used for modelling. The simulation results obtained from the models of the methods and the data obtained from the experiments were compared. The predictions and performances of each model were presented. Determination the appropriate drying parameters is important for the drying efficiency of the product. In addition, model selection plays an important role in obtaining successful results in drying simulations. As a result, it has been observed that the prediction performance of the model created with the artificial neural network is more successful than the others. While regressions are efficient in modelling existing data, they are not successful in predicting. Moreover, it is not enough to predict the peak and pits in the drying data.

**Keywords:** Multi-layer perceptron network, Machine learning, Organic fertilizer, Regression, Agricultural drying, Long short-time memory

<sup>ab</sup> Cem Korkmaz; ckorkmaz@cu.edu.tr, Tel: (0530) 3289139, orcid.org/0000-0003-1062-4581

<sup>a</sup> orcid.org/0000-0002-5887-8807

## 1. Giriş

### 1. Introduction

Kurutma işlemi; ürünün içerisindeki nemin, zaman içerisinde uçurularak uzaklaştırılması esasına dayanmaktadır. Sadece insan gıdası değil, aynı zamanda bitki besinlerinin kurutulmasında da aynı süreç takip edilmektedir. Gün geçtikçe yapay (kimyasal) gübrelerin toprağa verdiği zarar daha iyi anlaşılmış ve artık organomineral gübrelerin kullanımına başlanmıştır. Bu tür gübreler, toprakta bulunan elementlerin, bitki tarafından alınabilmesine engel olan kireci nötürleştirerek, besin emilimlerini artırmaktadırlar. Bununla birlikte, uygun kurutma parametrelerini elde etmek, ürünün verimliliği açısından çok önemlidir. İsbetli tahminler, bu alanda faaliyet gösteren firmalara hızlilik ve rekabet gücü katması açısından önemlidir. Bunun yanında simülasyonlarda başarılı sonuçlar elde etmek için uygun model seçimi önemlidir. Bir organomineral gübre üretim hattı; granülleme, kurutma, soğutma ve paketleme işlemlerinden oluşmaktadır. Aktif maddeler olarak azot, fosfor, potasyum ve leonardit organik maddelerinden oluşmaktadırlar. Kimyasal gübrelerle karşılaştırıldığında insan sağlığı için güvenlidir. Ancak birçok çeşidi olan organomineral gübrelerin, üretimi esnasında kullanılan kurutma işleminin, sahip olduğu karmaşık kuruma kinetiğinden dolayı, uygun kurutma parametrelerini yakalamak, deneme-yanılma metodu ile uzun zaman almakta, zaman-enerji ve para verimliliği açısından yetersiz kalmaktadır. Özellikle artan dünya nüfusunun beslenmesinin karşılanabilmesi için hem araştırmacılar hem de üreticiler kurutma konusunda çalışmalarına devam etmektedirler. Bu çalışmanın temel amacı ve önemi, gübre üretim endüstrisindeki kurutma işleminde, gübrenin kuruma davranışının isabetli tahmin edilebilmesinde aşılması gereken güçlüklerin belirlenmesidir.

Bu problemin çözümü için regresyon tekniği ile elde edilmiş olan hazır ampirik fonksiyonlar, uzun yıllardan beri yaygın olarak kullanılmaktadır. Üstel, polinomsal ve logaritmik regresyon fonksiyonlarının, deneysel kurutma eğrilerini, iyi bir yaklaşımla temsil edebildiği görülmüştür (Polatoğlu & Beşe, 2017). Leblebi üretimi için karabiber tohumu yağının, nohut tanesi üzerine püskürtülerek kurutulması işleminde, logaritmik fonksiyonların, polinomlara göre daha isabetli regresyona yol açtığı belirtilmiştir (Mansuroğlu vd., 2020). Zeytin çekirdeklerinin kurutulmasında ise polinomsal fonksiyonlar kullanışlı olmuştur (Nakilcioğlu-Taş & Ötleş, 2021).

Hazır fonksiyonların kullanımı kolaylık sağlıyor olsa da, farklı ürün türlerinin kuruma davranışlarındaki farklılıkları, hatta aynı ürünün kurutulmasında bile, kurutma şartlarındaki olası değişimlerinden kaynaklanan farklılıkların kuruma davranışı tahminlerinde büyük sapmalar verdiği sonuçlar ortaya çıkabilmektedir. Bu durumda da tek tek kurutma deneyi yapıp, deneysel veriye eğri uydurarak mevcut ilişkiyi tespit etmek, mantıklı bir başka seçenektir. Eğri uydurmak için regresyon tekniği kullanılmaktadır. Kurutmanın modellenmesinde de, regresyon yöntemi tercih edilmektedir. Ancak literatürde bütün kurutma işlemleri için optimum parametrelerin tespit edilmesinde kullanılan tek bir model henüz sunulmuş değildir. Ayrıca regresyonun, mevcut veri setini temsil etmede uygun olduğu görülmekle birlikte, aralık dışı, ileriye yönelik tahmin yeteneği konusunda, literatürde herhangi bir bilgiye rastlanmamıştır.

Günümüzde hem mevcut veri modellenmesinde hem de ileriye yönelik tahminler konusunda, tıptan ziraata kadar pek çok alanda, makine öğrenme yöntemleri başarılı bir şekilde kullanılmaktadır. Makine öğrenme yöntemlerinin de pek çok çeşidi vardır. Yapay sinir ağı (YSA) bu yöntemlerden biri olup, yüksek doğrulukta tahmin oluşturabilmektedir (Poonnoy vd., 2007). Besin kurutma konusunda da YSA kullanıldığı ve neticede pratik ve isabetli kurutma tahminleri elde edildiği rapor edilmiştir (Lertworasirikul & Tipsuwan, 2008). Yenilenebilir enerji kaynağı olarak biyokütle olan çimin, kalorifik değerini tahmin etmede, literatürde yaygın olarak kullanılan on iki adet deneysel bağıntı ve YSA model sonuçları karşılaştırıldığında; YSA sonuçlarının, deneysel değerler ile daha iyi uyum sağladığı tespit edilmiştir (Kılıç, 2021). YSA bir makine öğrenme türü olup sadece yazılımsal değil, aynı zamanda donanımsal olarak da pratik bir biçimde uygulanabilmektedir (Çavuşlu vd., 2012). Böylece YSA gibi metotların, mevcut endüstriyel süreçlere hızlıca uygulanabileceği anlaşılmaktadır. Ancak başarılı bir YSA elde edebilmek için öncelikle ağların yeterince eğitilebilmesi gerekmektedir. Fakat ağların eğitimi esnasında, 'aşırı öğrenme' olarak adlandırılan yanıltıcı bir başarı oluşabilmektedir. Aşırı öğrenme, modelin genelleştirme kabiliyetinin azalmasına yol açan bir ağ eğitim hatasıdır. Bu hataya yol açan etmenlerden biri, iterasyon sayısıdır. Gereğinden fazla iterasyon miktarı, aşırı öğrenmeye sebep olabilmektedir. Yeterli iterasyon sayısı, aşırı öğrenmeye engel olabilmektedir (Öğündür, 2019).

Uzun-kısa süreli bellek (LSTM) ise zaman serilerinin modellenmesinde kullanılan bir derin öğrenme yöntemidir. Kurutma süreci, ürünün bünyesindeki nemin zaman bağlı olarak uçurularak uzaklaştırılması işlemidir. LSTM ağları ile modellenebileceği mümkün görünmektedir. Biyolojik malzeme olan organik katı atığın (Perazzini vd., 2013), moringa olifera yapraklarının (Tarafdar vd., 2021), soğan dilimlerinin (Kaveh vd., 2018), cocoyam dilimlerinin (Onu vd., 2022), fındık, fasulye ve nohut gibi zirai ürünlerin (Topuz, 2010), mercimek tohumlarının (Taheri vd., 2021) kurutulmasının modellenmesinde, destek vektör makineleri (SVM), YSA, yapay zekâ (AI), uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS), LSTM yöntemlerinin tahmin amaçlı olarak başarı ile kullanıldığı görülmüştür. Sıcaklık tahmininde YSA en iyi iken, nem tahmininde SVM model en iyi olmuştur (Taheri vd., 2021). ANFIS metodu ise YSA'ya göre daha yüksek doğrulukta sonuçlar vermiştir (Zadhossein vd., 2021). Nem oranı tahmininde YSA iyiyken, kuruma zamanının tahmininde ANFIS modeli daha iyi sonuçlar vermiştir (Amini vd., 2021a). Eğitim verisinin fazla olması ile eğitilen ağ başarısının artması, LSTM ağlarında daha belirgindir.

Mevcut çalışmalardan görüldüğü gibi; yaş gıdanın kurutulması konularında çok sayıda çalışma vardır. Bununla birlikte; kimyevi gübre kurtulması konusunda oldukça sınırlı sayıda çalışma mevcut iken, organomineral gübre kuruma kinetiğinin makine ve derin öğrenme yöntemleri ile belirlenmesine ilişkin herhangi bir çalışmaya rastlanmamıştır. Yapılan literatür araştırması neticesinde; zirai ürünlerin ve yiyeceklerin kurutulmasında kurutma kinetiği, ürün kalitesi ve nem içeriği tahmininde, makine öğrenme yöntemlerinin başarılı olduğu görüldüğünden dolayı, bu yöntemlerin, gübre kurutulmasında da kullanım potansiyeline sahip olabileceği düşünülerek, incelenmesine karar verilmiştir. Bu çalışmada; çok katmanlı algılayıcı (MLP) türünde bir YSA, LSTM ağı, regresyon ve YSA esaslı regresyon yöntemlerinin, organomineral gübre kurutma tahminleri üzerindeki performansları araştırılmıştır. Yöntemlerin birbirlerine göre tahmin performansları karşılaştırılmıştır.

## 2. Materyal ve metod

### 2.1. Material and method

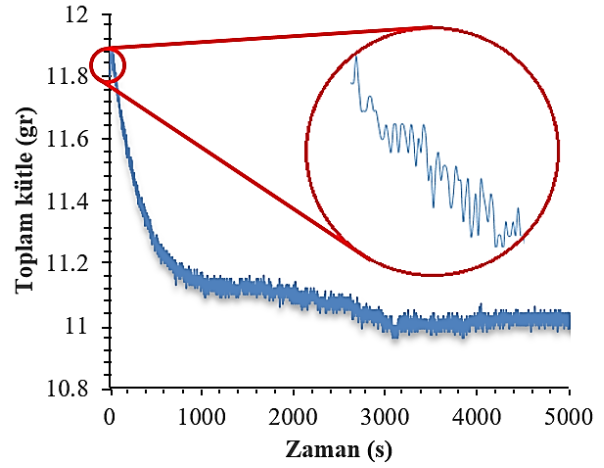
Çalışmada kullanılan MLP türündeki YSA, LSTM ağı, regresyon ve YSA ağı esaslı regresyon yöntemleri izah edilmeden önce, bu yöntemlerde

kullanılacak veri kümesini oluşturan kurutma işleminin esası da aşağıda izah edilmiştir.

## 2.1. Kuruma kinetiği

### 2.1. Drying kinetics

Kurutma işlemi, her ne kadar basitçe fırın içerisinde bekletmek olarak düşünülse de, arka planda esasen suyun buharlaşması, su buharının kuru hava içerisine difüzyonu, difüzyon katsayısının sıcaklığa ve hava hızına bağlılığı gibi pek çok etken mevcuttur. Bütün bu etkenler, kurutma kinetiği olarak adlandırılan yöntemler ile hesaplanmaktadır. İncelediğimiz organomineral gübrenin, 70°C'de kurutulması esnasındaki verilerden elde edilen ham kurutma eğrisi Şekil 1'de örnek olarak verilmiştir.



Şekil 1. Kurutma eğrisine bir örnek

Figure 1. An example of a drying curve

Bu çalışma kapsamında, sadece ürün kütlesinin zamanla azalmasından elde edilen ham veri eğrileri incelenmiştir. Eğri, genel olarak üstel bir şekle sahipmiş gibi görünse de, detaylı bakıldığında çok sık tepelik ve çukurluklar içermektedir. Kurutma olayının doğasında olan bu durumdan dolayı, genel eğri görünümüne ilaveten iniş-çıkışların da tahmin edilebilmesi gerekmektedir. Deneylerdeki ham verilerden elde edilen bu iniş çıkışlı durumun, bu çalışmada kullanılacak makine öğrenme yöntemleri ile nasıl bir tahmin performansı sergileyebileceği de önemli bir konudur.


## 2.2. Çok Katmanlı Algılayıcı Ağı ile Modelleme

### 2.2. Modelling using Multilayer Perceptron Network

YSA modelleri, insan beynindeki sinir hücrelerine benzeyen yazılımsal modellerdir. Nöronları (düğümeleri) ve bunların birbirlerine bağlantıları ile biyolojik sinir ağlarına benzemektedirler. YSA'nın

esası; hücre(ler) → hücre(ler)den oluşan katman(lar) → katman(lar)dan oluşan bir ‘ağ’ kurarak, giriş → çıkış bağıntısı, yani model, oluşturmaktır. Bu ağ; bir sinyali, girişten çıkışa doğru, bir nörondan diğerine ağırlıklandırılmış bağlantılar üzerinden ileterek, çıkış oluşturmaktadır. Bu suretle de hesaplama yapabilmektedir. Sinyal, bağlantı ağırlığına (gücüne) bağlı olarak yükseltilebilmekte veya azaltılabilmektedir. Birden fazla katman içeren ağlarda, bir katmanın çıkışları, müteakip katmanın girişleri olmaktadır. Elde mevcut bulunan ve sadece giriş, çıkış değerlerini içeren veri setine, başarı ile uyabilecek bir model (ağ) üretmek amacıyla, ağdaki hücre sayısı, katman sayısı, bağlantı ağırlıkları vb. gibi ağ parametreleri değiştirilerek, en iyi çıkış tahminini sağlayan model kurulmaktadır.

YSA modelleri, denetimli ve denetimsiz ağlar olmak üzere iki sınıfa ayrılabilir. Denetimli ağlar, bağlantı ağırlıklarını ayarlamak için bir eğitim algoritması ve bir eğitim veri kümesi gerektirirken, denetimsiz ağlar ise herhangi bir eğitim algoritması kullanmadan gerekli sonuçları elde etmek üzere, ağırlıkları kendileri ayarlayabilmektedir. Denetimli ağlar çoğunlukla sınıflandırma, tahmin ve fonksiyon yaklaşımı için kullanılmaktadırlar.



**Şekil 2.** Nem tahmini için oluşturulan ileri beslemeli, iki katmanlı, lineer olmayan, kendini tekrarlayan, harici girişi olmayan ağ topolojisi  
**Figure 2.** A feed-forward, two-layer, nonlinear, without exogenous inputs, auto regressive network topology created for moisture prediction

Şekil 2’de nem tahmini için kurulan yapay ağın, topolojisi verilmiştir. Ağırlıklar; nöronlar arasına çizilen çizgiler ile sembolize edilmiştir. Ağ, ileri beslemeli bir yapıdadır. Mühendislik uygulamalarında en sık kullanılan ağ modeli, çok katmanlı algılayıcıdır. Hızlı ve güvenilir olması,

birçok öğrenme algoritmasının bu ağ eğitmek için kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir.

$Nem_{t-1}, Nem_{t-2}, Nem_{t-3}, Nem_{t-4}, Nem_{t-5}$  olarak adlandırılan nöronlar, giriş katmanını oluştururken,  $Nem_t$  ise çıkış katmanının nöronudur. Bu ikisinin ortası ise gizli katman(lar) olarak adlandırılmaktadır. Bu ağda, durum değişkenleri; nem ve zaman olup, harici girişler bulunmamaktadır. Bu ağ yapısına, lineer olmayan, kendini tekrarlayan (Nonlinear Auto-Regressive, NAR) ağ denmektedir (Lertworasirikul & Tipsuwan, 2008). Ağ mimarisi;  $f(Nem_{t-1}, Nem_{t-2}, Nem_{t-3}, Nem_{t-4}, Nem_{t-5})$  şeklinde, geriye dönük beş adet ardışık zaman değerine bağlı bir fonksiyon olarak seçilmiştir. Böylece  $Nem_t$ ’yi hesaplamak için, kendinden önceki 5 zaman adımı kullanılmaktadır.

Bir YSA’da herhangi bir katmandaki  $j$ ’nci hücrenin girişi; önceki katmandaki hücrelerin  $y_i$  çıkışlarının, bağlantılar üzerindeki  $w_{ij}$  ağırlıkları ile çarpılarak, elde edilen ağırlıklı  $n$  adet bağlantının toplamı ile oluşturulmaktadır. Denklemi yönlendirmek için bias  $b$  eklenebilmektedir. Bu işlemlerin matematiksel ifadesi denklem (1)’de verilmiştir.

$$net_j = b + \sum_i^N y_i w_{ij} \quad (1)$$

Herhangi bir katmandaki  $j$ ’nci hücrenin çıkışı ise; toplama fonksiyonu ile elde edilmiş, ağırlıklanan girişlerin, bir eşik değerden çıkartılıp, müteakiben bir aktivasyon fonksiyonundan (transfer fonksiyonu olarak da adlandırılır,  $f_{act}$ ) geçirilmesiyle hesaplanmaktadır. Bu halde çıkış, denklem (2)’deki gibi olacaktır.

$$Çikis = f_{act}(net_j) \quad (2)$$

Aktivasyon fonksiyonu olarak; sıklıkla tanjant hiperbolik fonksiyon  $f(t)$  ve sigmoid fonksiyon  $\sigma(t)$  kullanılmaktadır. Fonksiyonlar ve türevleri, denklem (3)’te verilmiştir. Fonksiyonların eğrileri ise Şekil 3’te gösterilmiştir. Türevler, yapay sinir ağının eğitimindeki minimizasyon işlemi için gereklidir.

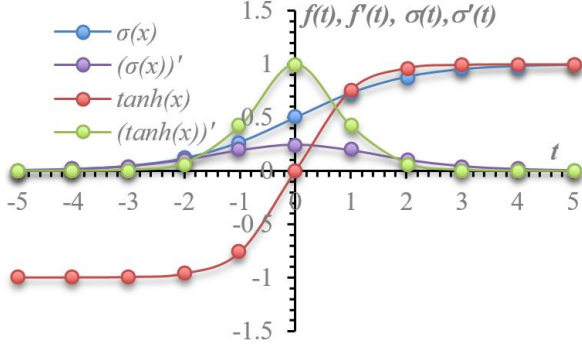
$$f(t) = \tanh = \frac{(e^t - e^{-t})}{(e^t + e^{-t})} \quad (3.a)$$

$$\frac{df(t)}{dt} = 1 - [f(t)]^2 \quad (3.b)$$



$$\sigma(t) = \frac{1}{1 + e^{(-t)}} \quad (3.c)$$

$$\frac{d\sigma(t)}{dt} = e^{(-t)} \sigma^2(t) \quad (3.d)$$



**Şekil 3.** Tanjant hiperbolik, sigmoid aktivasyon fonksiyonları ve türevleri

**Figure 3.** Tangent hyperbolic, sigmoid activation functions and their derivatives

Kurulan ağ ile isabetli tahminler yapılabilmesi için öncelikle bu ağın, eğitilmesi gerekmektedir. Ağın eğitimi için giriş ve çıkışlardan oluşan bir eğitim veri kümesi kullanılmaktadır. Esasen eğitim esnasında yapılan şey; her bir iterasyonda, ağın  $w_{ij}$  ağırlık değerlerinin, çıkışların istenen değerlerde olabilmesini sağlayacak şekilde değiştirilmesidir. Bu işleme ‘ağın eğitilmesi’ denmektedir. Her iterasyonda, gerçek çıktı (deneysel nem ölçümü) ile hesaplanan çıktı (ağın nem tahmini) arasındaki farka (hata da denmektedir) bakılmaktadır. Bu farkın, sıfır veya mümkün olduğunca sıfıra yakın olması için,  $w_{ij}$  değerleri değiştirilerek, aynı hesaplamalar sonraki iterasyonda yeniden yapılmaktadır. Bu işlem, farkın, istenen minimum değere ulaşmasına kadar iteratif olarak tekrarlanmaktadır. Bu minimizasyon işlemi, bir optimizasyon türü olup, bu amaçla çeşitli eğitim algoritmaları mevcut olmasına karşın en sık kullanılanları; Levenberg-Marquardt, Bayesian regularization ve Conjugate gradient algoritmalarıdır (Çavuşlu vd., 2012). Hatanın, YSA içerisindeki çoklu ağırlıklar arasında dağıtımının yapılarak, optimizasyonun uygulanabilmesi için de, geri yayılım (back propagation) gibi çeşitli yaklaşımlar da mevcuttur. Bu yaklaşım; tahmin, fonksiyon uydurma gibi uygulamalarda tercih edilmektedir (Anderson & McNeill, 1992). Ağın içerdiği gizli katman(lar)ın sayısı ve gizli katman(lar)daki nöron sayısı da ağ modelinin doğruluğu üzerinde etkilidir. Gizli katman sayısını ve buradaki nöron sayılarını azaltmanın, aşırı öğrenme hatasını azalttığı bildirilmiştir (Erenturk & Erenturk, 2007).

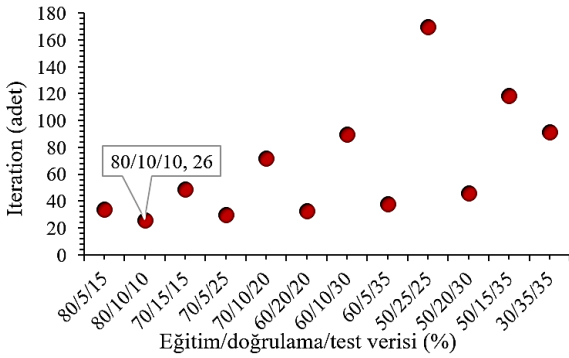
Gereğinden daha fazla artırılmasının ise ezberleme olarak adlandırılan bir diğer ağ hatasına yol açabildiği görülmüştür (Adıyaman, 2007). Katman sayısının belirlenmesinde ise deneme-yanılma metodunun sıklıkla kullanıldığı tespit edilmiştir. Eğitimi tamamlanmış ağın, tahmin performanslarının değerlendirilmesi için, test edilmesi gerekmektedir. Bu amaçla veri kümesinin, test için ayrılmış kısmı kullanılmaktadır. Eğer doğrulama için de ayrıca veri ayrılmışsa, isteğe bağlı olarak doğrulama da yaptırılabilir. Veri kümesinin bölünmesi esnasında genel yaklaşım olarak, eğitim veri kümesinin mümkün olduğunca büyük seçilmesinin, başarılı bir ağ eldesinde, en önemli etken olduğu bildirilmektedir (Bayır, 2006). Aşırı öğrenme hatasının oluşmaması için iterasyon sayısı, mümkünse düşük seçilmelidir (Öğündür, 2019). Bununla birlikte, gereğinden daha az sayıdaki iterasyonlar ise ağın eğitiminin yetersiz olmasına yol açmaktadır. Bu nedenle en uygun iterasyon sayısı da belirlenmelidir. Bu amaçla ‘erken durdurma’ olarak adlandırılan yöntemin kullanıldığı görülmüştür (Poonnoy vd., 2007). Ayrıca iterasyon sayısının gittikçe artırılarak, her seferinde eğrilerdeki uyumun gözle kontrol edilmesi yoluyla, uygun iterasyon sayısının tespit edilebildiği başka bir yöntem de mevcuttur (Estiati vd., 2016).

Bir YSA’nın başarısı; kullanılan aktivasyon fonksiyonuna, öğrenme algoritmasına, içerdiği gizli katman sayısına, gizli katmanlardaki nöron sayısına, kümedeki verinin bölünme oranına, eğitim esnasında gerçekleşen iterasyon sayısına, öğrenme hızı ve momentum parametrelerine çok bağlıdır. Ne yazık ki, bunların optimum değerlerinin belirlenmesine yönelik sabit bir kural henüz mevcut değildir. Bununla birlikte bu değerlerin, beklenen çıktı ve hesaplanan çıktı arasındaki korelasyonu en fazla veya farkı en az yapacak şekilde deneme-yanılma yoluyla tespit edilebildiği görülmüştür (Amini vd., 2021b; Beigi & Torki, 2021). Bu nedenle çalışmada tercih edilen parametreler ve nasıl seçtikleri, müteakip paragraflarda izah edilmiştir.

Aktivasyon fonksiyonu olarak öncelikle tanjant hiperbolik fonksiyonu kullanılmış ve sonuçların korelasyon ve hata yakınsama değerleri değerlendirilmiştir. Eğitim esnasında her bir iterasyonda bu kriterlerin değişimi, kararlı durumun bozulup-bozulmadığı tek tek takip edilmiştir.

Öğrenme algoritması olarak Levenberg-Marquardt algoritması, hata dağıtımı için de geri yayılım

yöntemi kullanılmıştır. Geri yayılım algoritması, çıktı katmanındaki hatanın bir önceki katmana tekrar dağıtılmasını sağlamaktadır. Bu işlem girdi katmanına ulaşıncaya kadar devam etmektedir.



**Şekil 4.** Farklı eğitim/doğrulama/test bölümlenmeleri halinde gereken iterasyon sayıları  
**Figure 4.** Number of iterations for various training/validation/test partitioning

Veri kümesi, eğitim/test/doğrulama olmak üzere üç gruba ayrılmıştır. Bölümlemenin hangi oranda yapılmasının en uygun olduğunun tespiti için, 80°C'de toplanmış olan veri, Şekil 4'te verilen farklı bölümlenmeler halinde, ağırlık eğitiminde kullanılmıştır. Her seferinde; her bir iterasyondaki hata değerleri dikkatlice takip edilmiş, hatanın kararlı bir biçimde azalarak bir minimum değere yakınsadığı görülmüş, maksimum iterasyon sayısına ulaşılması beklenmeden eğitim durdurulmuş ve neticede ulaşılan  $R$  (korelasyon katsayısı), yakınsayan hatanın son değeri ve yapılan iterasyon sayısı kaydedilmiştir. Şekil 4'te iterasyon sayıları görülmektedir. Minimum hataya, en az sayıda iterasyonla ulaştıran, aynı zamanda da hatadaki değişimin sabit veya kararlı olduğu

bölümleme oranı aranmıştır. Eğitimler esnasında algoritmanın, ihtiyaç duyulan kadar iterasyon yapılabilmesine olanak sağlamak için, maksimum iterasyon sayısının sınırı olarak 1000 verilmiş olsa da, hatanın olağan sayıda iterasyon ile (ilk 11-154 arasında) istenen değere düşürüldüğü ve bu esnada da,  $R$  değerlerinin zaman zaman 0.999'a kadar çıkabildiği gözlemlenmiştir. İterasyon sayıları düşük olduğu için; yüksek  $R$  değerinin, aşırı öğrenme hatası nedeniyle oluşmadığı anlaşılmıştır. Elde edilen eğriye bakıldığında, eğitim kümesindeki veri sayısının %50'nin altına düştüğü durumlarda, iterasyon sayısının tepe yaptığı, sonrasında da kararsız hale geldiği görülmüştür. Eğitim kümesindeki veri sayısının %50'nin üzerinde olduğu diğer aday durumlar arasından ise en az iterasyona ihtiyaç duyan bölümleme oranı olduğu için 80/10/10 (%80 eğitim ve %10 doğrulama ve %10 test) bölümlemesi seçilmiştir.

80/10/10 bölümleme değerine karşılık gelen iterasyon sayısının 26 olduğu, Şekil 4'ten tespit edilebiliyor olsa da, bu iterasyon sayısının yeterli olduğunun sağlanmasını yapmak üzere ilave bir araştırma daha yapılmıştır. Bu amaçla, iterasyon sayısı başlangıçta 10 alınmış ve her seferinde miktarı artırılarak elde edilen tahmin çıktı eğrisi ve gerçek çıktı eğrisi, birbirleri ile kıyaslanmıştır. Uyumlu eğri ve bu eğriyi veren en az iterasyon sayısı aranmıştır. Tablo 1'den görüleceği üzere iterasyon sayısı 30'dan fazla iken tahmin performansının değişmediği görülmüştür. Bu nedenle en uygun iterasyon sayısı 30 olarak seçilmiştir. Grafikte açık renkli eğriler, deneysel nem çıktısı iken, koyu renkli olanlar ise bu çalışmada kullanılan MLP ağırlığının, nem çıktısına dair tahminleridir.

**Tablo 1.** Optimum iterasyon sayısının belirlenmesi  
**Table 1.** Determination of the optimum iteration number

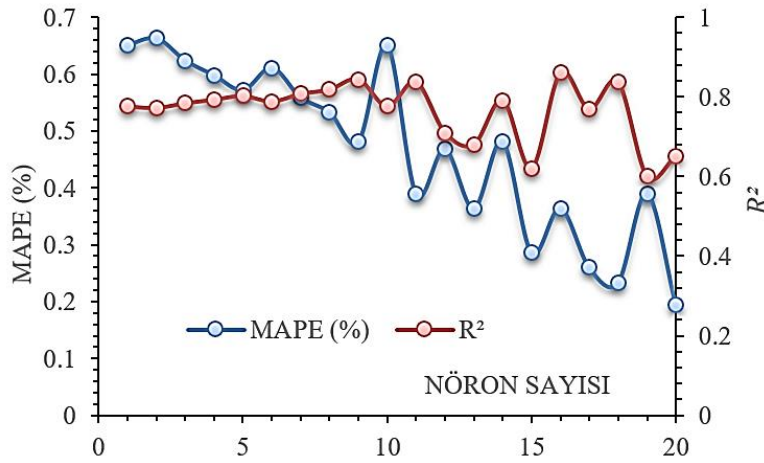
İterasyon sayısı	Deneysel ve YSA	İterasyon sayısı	Deneysel ve YSA
10		30	
20		40	

En uygun gizli katman sayısı ve her bir katmandaki en uygun nöron sayılarını belirlemek üzere, öncelikle iki katmanlı topoloji ele alınarak, nöron sayısı 1 ile 20 arasında değiştirilmiştir. Bu şekilde eğitilen ağların, nöron sayısı ile  $R^2$  (determinant katsayısı), MAPE (ortalama mutlak yüzde hata) değerleri arasındaki ilişkileri, Şekil 5'teki gibi

tespit edilmiştir. En iyi nöron sayısını belirlemek üzere; MAPE'nin düşük,  $R^2$ 'nin büyük olduğu değer aranmıştır. Her ne kadar 9 nöronlu halde MAPE daha az olsa da,  $R^2$  değerlerinin düştüğü ve hemen sonrasında ağırlık hassasiyetini yitirmeye başladığı görülmektedir. Bu nedenle nöron sayısı olarak, 6 nöron seçilmiştir. Neticede,

elde edilen ağ başarısının yüksek olması nedeni ile de katman sayısının, ne azaltılması, ne de artırılması düşünülmüştür. Ancak ebetteki ara katman sayısının etkisini belirleyebilmek için,

deneme-yanılma yaparak, tek katmandan itibaren artan sayıda katman oluşturularak, en uygun katman sayısı araştırılabilir.



**Şekil 5.** Gizli katmanlardaki nöron sayısına bağlı olarak MAPE ve  $R^2$  değerleri  
**Figure 5.** MAPE and  $R^2$  versus the number of neurons in the hidden layers

**Tablo 2.** Çalışmada kullanılan MLP ağının özellikleri  
**Table 2.** Features of the MLP network used in the study

Parametre	Değer
Eğitim esnasında hata hedefi	MAPE=8e-3
Eğitim esnasında maksimum iterasyon	1000
Gizli katman sayısı	2
Gizli katmandaki nöronlar	6
Aktivasyon fonksiyonu	tanjant hiperbolik
Eğitim algoritması	Levenberg Marquardt
Bağlı olduğu önceki veri sayısı, d	5
Giriş düğümleri	5 ( $nem_{t-1}, nem_{t-2}, nem_{t-3}, nem_{t-4}, nem_{t-5}$ )
Çıkış düğümleri	1 ( $nem_t$ )
Çıkış eşiği	0.99
Öğrenme hızı, $\eta$	0.1
Momentum, $\alpha$	0.1
Öğrenme eşiği	0.0001
Veri kümesinin bölünmesi	%80 (eğitim), %10 (doğrulama), %10 (test)

MLP ağı oluşturulurken Tablo 2’de verilen ağ değişkenleri kullanılmıştır. Tabloda verilen ‘eşik değeri’ ifadesi; 0 ile 1 arasında seçilen bir değer olup, katmanlarda bu değer altındaki düğümler hesaplamaya dâhil edilmemektedir. Bu sayede zayıf bilgilerin unutulması sağlanarak, daha başarılı bir ağ elde edilebilmesi hedeflenmektedir. Bununla birlikte, ağın eğitimi esnasında, ağırlıkların güncellenmesi için, eklenecek-çıkartılacak fark miktarlarının belirlenebilmesi amacıyla, ‘momentum’ ve ‘öğrenme hızı’ terimleri hesaba dâhil edilmektedir. Bir önceki iterasyonda hesaplanan fark teriminin başına getirilecek çarpana, ‘momentum’ denmektedir. Çıktı ve hata çarpımının başına


getirilecek çarpana ise ‘öğrenme hızı’ denmektedir. Momentum terimi; eğitim iterasyonları esnasında ağ ağırlıklarının yeni değerlerinin, bir önceki değerlerden etkilenme miktarını belirlemektedir. Bu sayede hesaplanan ağırlık değerinin, yerel bir optimuma takılıp, bunun etrafında salınım yapması nedeniyle, global optimuma ulaşamaması riskinin önüne geçilmektedir. Öğrenme hızı, ağın ne kadar süre boyunca eğitileceğini belirlemektedir. Hızlı bir öğrenme, zayıf bir ağı yol açarken, yavaş öğrenme, güçlü bir ağ oluşturmaktadır. Ancak yerel optimuma takılma riskini de beraberinde getirmektedir. 0 ve 1 arasında değer almaktadır. Katsayı arttıkça, öğrenme hızı artmaktadır. Ağların tamamı bilgisayar üzerinde simüle edilen

yazılımsal kodlardır (Eaton, 2022), herhangi bir donanım üzerinde uygulanmamıştır.

### 2.3. LSTM ile modelleme

#### 2.3. Modelling using LSTM

LSTM ağı, derin öğrenme olarak ifade edilen bir makine öğrenme yöntemidir. Tekrarlayan sinir ağı (RNN) grubundadır (Park vd., 2019; Sekertekin vd., 2021). Bir LSTM ağ birimi, Şekil 6'da verilmiş olup  $\{x\}$  girdi değişkeni seti,  $\{h\}$  çıktı değişkeni durumunu ve  $\{c\}$  hücre durumunu içeren değişkenlerdir. Burada  $\{x\}$  girdi değişkeni 'zaman' olup,  $\{h\}$  çıktı değişkeni ise 'nem'dir.  $t$  alt indisi,  $t$  zaman adımıdaki değer' anlamına gelmektedir.



Şekil 6. Bir LSTM ağ birimi

Figure 6. An LSTM network unit

Bir LSTM ağında 'giriş kapısı', 'unutma kapısı' ve 'çıkış kapısı' olarak adlandırılan üç kapı mevcuttur. Giriş kapısı, bellek hücresinde, hata sabitinin nasıl korunacağını öğrenmektedir. Bunu, alakasız girişlerin seçimini kaldırarak yapmaktadır. Çıkış kapısı, diğer LSTM birimlerini korumak için, alakasız bellek içeriğinin nasıl hariç tutulacağını öğrenmektedir. Unutma kapısının görevi, bilginin hafızada ne kadar süre kaldığını öğrenmektir. Bu amaçla denklem (4)'te verilen  $h_t$  kullanılmaktadır.

$$h_t = o_t \odot \tanh(c_t) \quad (4)$$

Denklemdaki  $\odot$  sembolü, Hadamard çarpımı olup (Million, 2007), vektörlerin eleman-eleman çarpımını sağlamaktadır.  $o_t$  çıkış kapısı olup,  $h_t$  için hücre durumunu ayarlamaktadır.  $c_t$ , denklem (5) kullanılarak hesaplanmaktadır.

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t \quad (5)$$

Burada  $i_t$  giriş kapısıdır. Hücre durumunun güncelleme seviyesini belirlemektedir.  $f_t$  unutma kapısıdır. Hücre durumunun sıfırlama seviyesini kontrol etmektedir.  $g_t$  hücre adaydır. Hücre durumuna bilgi sağlamaktadır. Bu değişkenler denklem (6) kullanılarak hesaplanmaktadır.

$$i_t = \sigma(W_t x_t + R_i h_{t-1} + b_i) \quad (6.a)$$

$$f_t = \sigma(W_f x_t + R_f h_{t-1} + b_f) \quad (6.b)$$

$$o_t = \sigma(W_o x_t + R_o h_{t-1} + b_o) \quad (6.c)$$

$$g_t = \tanh(W_g x_t + R_g h_{t-1} + b_g) \quad (6.d)$$

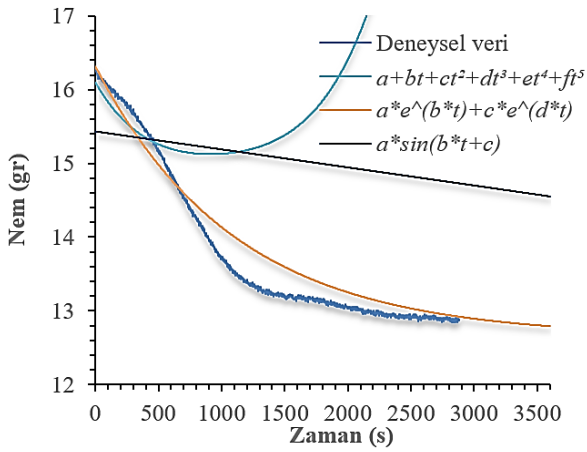
Burada  $\sigma(x)$ , kapıların aktivasyon fonksiyonu olup, sigmoid fonksiyonudur.  $W$  ve  $R$  sırasıyla girdi ağırlıkları ve tekrarlayan ağırlıklardır.  $b$  ise bias'tır. LSTM ağlarının eğitimi için toplam veri setinin ilk %80'i eğitim amaçlı kullanılırken, geriye kalan %20'lik kısım ise test amaçlı kullanılmıştır. Doğrulama kullanılmamıştır. Test için son %20'lik kısmın seçilmesinin nedeni, ileriye yönelik tahmin performansının değerlendirilebilmesini sağlamaktır. LSTM ağları yazılımsal kodlar ile oluşturulmuş (Heris, 2015), herhangi bir donanım üzerinde uygulanmamıştır.

### 2.4. Regresyon ile modelleme

#### 2.4. Modelling using regression

Tarımsal kurutma amacıyla tespit edilmiş ve halen yaygın olarak kullanılmakta olan pek çok türde regresyon fonksiyonu mevcut olduğu için, hangisinin kullanışlı olabileceğinin belirlenmesi amacıyla, öncelikle bir ön analiz yapılmıştır. Bu amaçla polinomsal  $a + b * t + c * t^2 + d * t^3 + e * t^4 + f * t^5$ , üstel  $a * e^{b*t} + c * e^{d*t}$  ve trigonometrik  $a * \sin(b * t + c) + d * \sin(e * t + f)$  fonksiyonlar denenmiştir. Burada  $a - f$  değerleri, regresyon parametreleridir. Fonksiyonlarda bağımsız değişken zaman  $t$ , bağımlı değişken ise  $nem(t)$ 'dir. Regresyonların tüm veri üzerindeki performanslarının görülebilmesi için ön analizde, tüm veri seti kullanılmıştır. Grafikler, veri toplama sırasına göre çizdirilmiştir. Şekil 7 incelendiğinde, bu çalışma için, deneysel veriye en uygun olabilecek doğrusal olmayan fonksiyonun, önerilen türdeki üstel fonksiyon olabileceği görülmüştür. Polinomsal fonksiyonların uygun olmadığı da anlaşılmıştır. Bunun yanı sıra, son zamanlarda kullanılmaya başlanan, 'YSA esaslı regresyon'ların da performansları değerlendirilmiştir.





**Şekil 7.** Deneysel veri ve farklı regresyon fonksiyonların kıyaslanması

**Figure 7.** Comparison of experimental data and regressions

Her ne kadar regresyonlardan, veri kümesi içerisinde isabetli tahminlerde bulunması beklense de, bu çalışmada hem veri kümesindeki, hem de veri kümesinin ilerisindeki değerlerin de tahmin performansı araştırılmıştır. Bu nedenle, veri kümesinin tamamı, regresyon için kullanılmamıştır. Hem doğrusal olmayan regresyon, hem de YSA regresyonda kullanılmak üzere, veri kümesindeki toplam verinin ilk %80'i alınmıştır. Elde edilen regresyon fonksiyonları, geri kalan %20 veri kullanılarak uydurulan eğrinin, tahmin performansını test etmek için kullanılmıştır (Eaton, 2022).

#### 2.4.1. Doğrusal olmayan regresyon

##### 2.4.1. Nonlinear regression

Ön analiz neticesinde, kullanılmasına karar verilen üstel fonksiyonun genel hali, denklem (7)'de gösterilmiştir.

$$nem(t) = C_0 + C_1 e^{(C_2 t)} \quad (7)$$

Bağımsız değişken zaman  $t$ , bağımlı değişken ise  $nem(t)$ 'dir.  $C_0$ ,  $C_1$  ve  $C_2$  ise fonksiyon parametreleri olup, regresyon ile bu katsayılar tespit edilmiştir.

#### 2.4.2. YSA esaslı regresyon

##### 2.4.2. ANN based regression

YSA esaslı regresyonun, doğrusal olmayan regresyondan farkı, parçalı olmasıdır (MathWorks, 2022b), yani fonksiyonel bir forma sahip olmayıp, her bir veri için ayrı ayrı hesaplanmaktadır. Bununla birlikte çekirdek fonksiyonu olarak adlandırılan genel bir biçime de sahiptirler. Bu çalışmada, Bayesian bir yaklaşım olan, Gauss

regresyonu (Gaussian process regression, GPR) metodu kullanılmıştır. GPR;  $i = 1, 2, \dots, n$  olmak üzere  $f(x_i)$  şeklinde gizli değişkenler kullanılmaktadır. Kümedeki toplam veri sayısı  $n$ 'dir. İşlem, Gauss esaslı gerçekleştirildiğinden dolayı da, bir regresyon fonksiyonu yerine, denklem (8)'de genel hali verilen şekliyle tanımlanmaktadır (MathWorks, 2022a).

$$f(x_i) \sim GP(m(x_i), k(x_i, x_j)) \quad (8)$$

Burada  $m(x_i)$  terimi, ortalama fonksiyon,  $k(x_i, x_j)$  ise kovaryans çekirdek fonksiyonu olarak adlandırılmaktadır.  $x_i$  ve  $y_i$ 'ler;  $i \neq j = 1, 2, \dots, n$  olmak üzere, eğitim veri kümesindeki değerlerdir.  $x_i$ , giriş olup  $y_i$  ise cevaptır (hedef). Ortalama fonksiyonu, sıfır alınmıştır. Kovaryans çekirdek fonksiyonu için pek çok seçenek mevcut olup, bu çalışmada, denklem (9) ile verilen üstel kovaryans fonksiyonu kullanılmıştır.

$$k(x_i, x_j) = \sigma_f^2 e^{-\frac{r}{\sigma_l}} \quad (9)$$

Burada  $r$ ;  $x_i$  ve  $y_i$  arasındaki Öklit mesafesi olup,  $r = \sqrt{(x_i - x_j)^T (x_i - x_j)}$  ile hesaplanmaktadır.  $T$  üst indisi, transpoze anlamındadır. Bu çekirdek fonksiyon, iki parametreye sahip olup, bunlar;  $\sigma_l$  uzunluk ölçeği,  $\sigma_f$  sinyalin standart sapmasıdır. Uzunluk ölçeği;  $x_i$  giriş değişkeninin, cevap ile olan ilişkisinin bittiği uzaklığı tanımlamaktadır (Sit, 2019). GPR modellerinin parametrik olmadığı düşünülse de;  $\sigma_l$ ,  $\sigma_f$  gibi hiperparametreler, bu yöntemin tahmin yeteneklerini önemli ölçüde etkilemektedir. Kovaryans çekirdek fonksiyonu; kısıtlamasız parametre olarak adlandırılan bir dizi  $\theta$  ile parametreleştirilmektedir ve  $\sigma_l = e^{(\theta_l)}$  ve  $\sigma_f = e^{(\theta_f)}$  olarak tanımlanmaktadır. Genellikle kovaryans fonksiyonunu;  $\theta$ 'ya olan bağımlılığını açıkça belirtmek için,  $k(x_i, x_j | \theta)$  olarak da ifade etmek mümkündür.

#### 2.5. Modellerin performansı

##### 2.5. Performance of models

Modellerin tahmin verimliliklerini ifade etmenin en iyi yolu, deneylerden ölçülen nem verileri ile model tarafından tahmin edilen nem verileri arasındaki farkı karşılaştırmaktır. Hata analizi, bu amaçla sıklıkla kullanılan, karşılaştırma yöntemlerindedir. Bu çalışmada, denklem (10)'da verildiği gibi beş farklı hata fonksiyonu kullanılmıştır. Oransal sapma (margin of deviation), hata hesaplamasında sıkça kullanılan denklemlerdendir (Bidgoli vd., 2016).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (p(i) - o(i))^2} \quad (10.a)$$

$$MSE = \frac{1}{N} \sum_{i=1}^n (p(i) - o(i))^2 \quad (10.b)$$

$$MAE = \frac{1}{N} \sum_{i=1}^n |p(i) - o(i)| \quad (10.c)$$

$$MAPE = \frac{1}{N} \left[ \sum_{i=1}^n \left| \frac{(p(i) - o(i))^2}{o(i)} \right| \right] \times 100 \quad (10.d)$$

$$\text{Oransal sapma (\%)} = 100 * \frac{o(i) - p(i)}{o(i)} \quad (10.e)$$

Burada; RMSE hatanın karesinin ortalamasının karekökü, MAE ortalama mutlak hata, MSE hatanın karesinin ortalaması ve MAPE ise ortalama mutlak yüzde hatadır.  $i$  alt indisi, veri kümesindeki  $i$ 'nci veriyi göstermektedir. Bu çalışmada; her bir veri, zamana bağlı olarak elde edildiğinden dolayı,  $i$  olarak, zaman adımı düşünülebilmektedir.  $o(i)$  değeri,  $i$  anındaki deneysel olarak ölçülen veri,  $p(i)$  değeri ise  $i$  anındaki tahmin değeridir.  $\bar{p}$  ve  $\bar{o}$  terimleri ise sırası ile tahmin edilen ve ölçülen değerlerin ortalamasıdır.  $n$ , veri kümesindeki toplam veri sayısıdır. Ayrıca  $R$  korelasyon katsayısı ise denklem (11) de verilmiş olup,  $o(i)$  ve  $p(i)$  arasındaki karşılıklı ilişkiyi elde etmek için kullanılmıştır. Korelasyonu ifade etmek üzere ayrıca,  $R^2$  değeri de ('determinant katsayısı' olarak adlandırılmaktadır) sıklıkla kullanılmaktadır.

$$R = \frac{\sum_{i=1}^n [p(i) - \bar{p}][o(i) - \bar{o}]}{\left( \sqrt{\sum_{i=1}^n [p(i) - \bar{p}]^2} \sqrt{\sum_{i=1}^n [o(i) - \bar{o}]^2} \right)} \quad (11)$$

Korelasyon katsayısına ek olarak, standart sapma ( $e_s$ ) ve ortalama kare sapma ( $\chi^2$ ) denklem (12, 13)'te verildiği gibi, bu amaç için kullanılabilir.

$$e_s = \sqrt{\frac{\sum_{i=1}^n [(p(i) - o(i))]^2}{n}} \quad (12)$$

$$\chi_s = \sqrt{\frac{\sum_{i=1}^n [(p(i) - o(i))]^2}{n - Prm}} \quad (13)$$

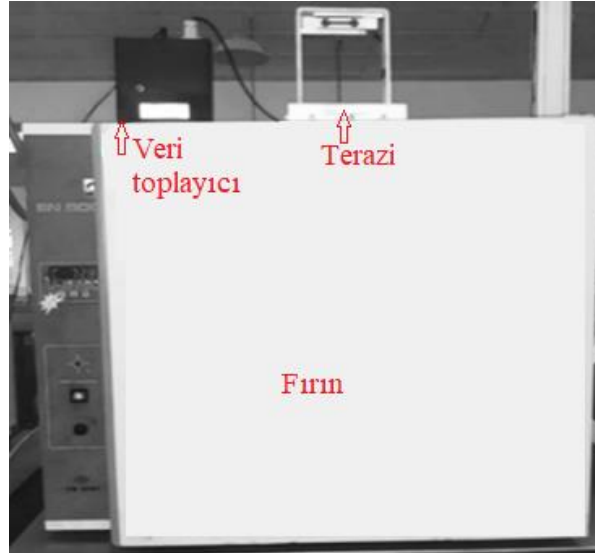
Burada  $Prm$ , modeldeki parametre sayısıdır. Ağların tahminlerinde en sık kullanılan başarı performans göstergeleri; RMSE, MSE, MAE, MAPE,  $R$ ,  $R^2$  değerleridir.  $R$  ve  $R^2$  birimsiz iken, RMSE ve MAE değerleri, verilerle aynı birime sahiptir. MSE, verinin karesi birimindedir. MAPE ise, yüzde birimindedir. Genel bir kural olarak; 1'e en yakın  $R^2$  değeri ve 0'a en yakın MSE, MAE, MAPE, RMSE değerleri hedeflenmektedir.  $R$  için; 0.01-0.29 arasındaki değerler, düşük düzeyde ilişki, 0.3-0.7 arası orta düzeyde ilişki, 0.71-0.99 arası ise yüksek düzeyde ilişki anlamına gelmektedir. Sıfır değeri, ilişki olmadığını gösterirken, negatif değerler, ters bir ilişki anlamına gelmektedir (Köklü vd., 2006). Mutlak değerce  $R$ 'nin artması, ilişkinin daha belirgin hale geldiğini göstermektedir. MAPE için değerlendirme kriteri ise şu şekildedir (Moreno vd., 2013): MAPE<0.10 (yüksek doğrulukta tahmin), 0.10-0.20 (iyi tahmin), 0.20-0.50 (makul tahmin), >0.50 (doğruluğu olmayan tahmin). YSA, LSTM ve regresyonlarda aşırı öğrenmeye engel olmak için,  $K$  kere çapraz doğrulama ( $K$  fold cross validation) yöntemi uygulanmıştır (Brownlee, 2018; Erenturk & Erenturk, 2007).  $K$  olarak 5 seçilmiştir. Bu yöntemin özü, veri kümesini  $K$  adet alt kümeye bölmek ve her seferinde farklı bir alt kümeyi hariç tutarak, toplamda  $K$  adet tekrar yapmaktır. Her tekrar esnasında, hariç tutulan alt kümeler test için kullanılırken, geri kalan veri ise eğitim için kullanılmaktadır. Toplam hata; her bir tekrardaki hatanın, aritmetik ortalamasıdır.

## 2.6. Nem belirleme deneyleri

### 2.6. Moisture determination experiments

Deneyin esası; sıcaklık kontrollü bir fırın içerisine yerleştirilen nemli numunelerden, belirli zaman adımlarında kütle ölçümüdür (Şekil 8). Kurutma, doğal taşınım yoluyla yapılmaktadır. Başlangıç kütlesi ile son kütle arasındaki fark, uçurulan nem miktarını vermektedir.

Deneyler 70°C, 75°C, 80°C olmak üzere üç farklı sıcaklıklarda uygulanmıştır. Nem verisi, hassas terazi ile birer saniye aralıklarla, bir saat boyunca toplanmıştır. Her bir deney, üçer tekrarlı yapılmıştır. Tekrarlara ilişkin; ortalama başlangıç kütlesi, ortalama son kütle, nem oranı ve standart sapma değerleri, Tablo 3'te verilmiştir. Tablodaki ortalama son kütle değeri, kuru kütle değeridir. Değerlerin tamamı ise veri sayısının çokluğu nedeni ile tablo halinde değil, bulgular ve tartışma bölümünde, grafik halinde verilmiştir. Her bir deneyde, toplam 3602 adet veri toplanmış, bunun ilk 2881 âdeti eğitim/test/doğrulama ve son 721 âdeti ise ileriye yönelik tahmin için kullanılmıştır.



**Şekil 8.** Kurutma deneylerinin yapıldığı ve nem verisinin toplandığı düzenek  
**Figure 8.** The experimental rig where drying experiments are carried out and moisture data are collected

**Tablo 3.** Kurutma deneyi ile elde edilen nem  
**Table 3.** Moisture from drying experiments

Deneyler	Ort. ilk kütle (gr)	Ort. son kütle (gr)	Nem oranı (g <sub>nem</sub> /g <sub>kuru madde</sub> ,%)	Standart sapma (gr)
80 °C	16.19	13.76	17.65	0.0308215
75 °C	15.64	13.98	11.87	0.015607
70 °C	11.82	10.60	11.5	0.0147212

Ort.: Ortalama

%5 azot, %10 fosfor karışımından oluşan organomineral nemli numunenin, boyutsal ve fiziksel özellikleri Tablo 4'te verilmiştir. Değerler,

yüz adet tane üzerinde yapılan ölçümlerin ortalama değerleridir.

**Tablo 4.** Nemli numunenin boyutsal ve fiziksel özellikleri  
**Table 4.** Dimensional and physical properties of the moist sample

İçerik	En küçük	Ort.	En büyük
Uzunluk (En büyük eksen) (mm)	3.60	5.90	12.0
Genişlik (Orta eksen) (mm)	3.15	5.25	10.0
Kalınlık (En küçük eksen) (mm)	2.80	5.00	7.50
Ortalama geometrik çap (mm)	3.30	5.00	9.00
Ortalama aritmetik çap (mm)	3.40	5.10	9.30
Yüzey alanı (mm <sup>2</sup> )	34.00	82.00	250
Hacim (mm <sup>3</sup> )	19.00	76.00	380.00
Küresellik (%)	67.40	86.00	98.30
Kütle (gr)	0.054	0.062	0.078
Tane yoğunluğu (kg/m <sup>3</sup> )	2161	2200	2286
Yığın yoğunluğu (kg/m <sup>3</sup> )	996	1080	1104
Gözeneklilik (%)	62	63	64

Deneysel belirsizlik analizi, denklem (14) kullanılarak gerçekleştirilmiştir (Khanlari, 2020). Bu analiz sayesinde; deneysel ölçümler veya hesaplamalar esnasında, ölçüm veya hesaplama cihazlarının çözünürlüklerinden veya

hassasiyetlerinden ortaya çıkan, mevcut, kaçınılmayan ve veriye karışan hataların sebebiyet verdiği, bağıl belirsizlikler tespit edilmektedir.

$$U_R = \sqrt{\left(\frac{\partial M}{\partial x_1} U_1\right)^2 + \left(\frac{\partial M}{\partial x_2} U_2\right)^2 + \dots + \left(\frac{\partial M}{\partial x_n} U_n\right)^2} \quad (14)$$

Burada  $U_R$  terimi, toplam belirsizlik,  $M$  terimi, ölçümü yapılan boyut (nemin kütlesi) olup, bu ölçülen boyut üzerinde etkisi olan  $n$  adet bağımsız değişken ise  $x_n$ 'dir (zaman, sıcaklık). Bağımsız değişkenleri ölçen cihazların her birinin ölçme hatası  $U_n$ 'dir. Ölçüm cihazlarına ait hata aralıkları ve hesaplanan belirsizlikler Tablo 5'te verilmiştir.

**Tablo 5.** Kurutma esnasında yapılan ölçümlerdeki hatalar ve sebep olduğu belirsizliklerin hesaplanması

**Table 5.** Errors in the measurements performed during drying and calculating their uncertainties

Ölçüm cihazları	Birim	Hata
Fırın içi sıcaklık	°C	±0.19
Veri toplayıcının zaman sayacı	sn	±0.1e-9
Tartı	gr	±0.18
Belirsizlikler	Birim	Değer
Sıcaklık ölçümündeki bağıl belirsizlik	%	±0.0027
Süre ölçümündeki bağıl belirsizlik	%	±3.3E-11
Tartıdaki bağıl belirsizlik	%	±0.017

### 3. Bulgular ve tartışma

#### 3. Results & discussion

##### 3.1. Tahmin eğrileri

###### 3.1. Prediction Curves


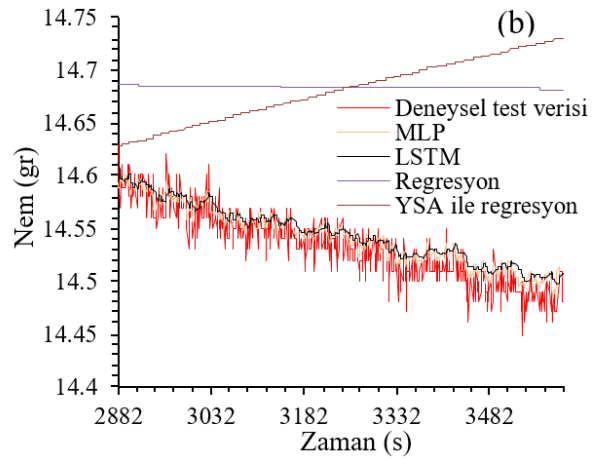
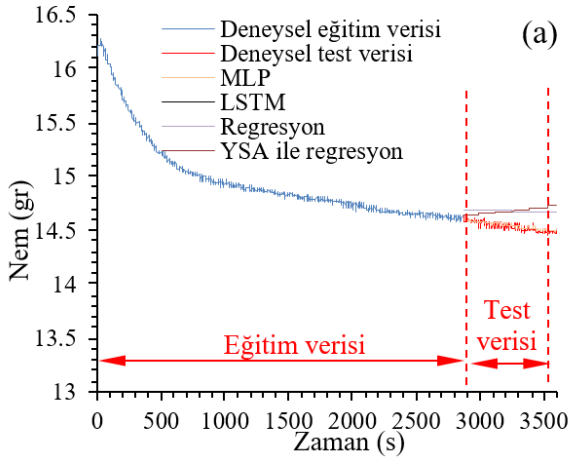
Gübrenin, üç farklı sıcaklık değerlerindeki nem verisi ve bu veri içerisinde alınan eğitim,

doğrulama, test bölümleri kullanılarak oluşturulan modellerin performanslarını gösteren eğriler, Şekil 9-11'de verilmiştir. Şekillerde modellerin hem eğitim verisi, hem de test verisi üzerindeki performansları ayrı ayrı gösterilmiştir. Alt şekiller sayesinde, modellerin eğitim ve test performansları detaylıca görülebilmektedir. Veri bölümlemesini ilk bakışta kolayca görebilmek için, ayrımlar şekil üzerinde gösterilmiştir.

Şekil 9'da modellerin 80°C'de kurutma verisi üzerindeki performansları kıyaslanmıştır. Şekil 9-a hem eğitim hem test verisini içermektedir. Şekil 9-b ise sadece test veri kümesini, detaylı bir biçimde göstermektedir. Benzer olarak; Şekil 9-c ise sadece eğitim veri kümesini detaylı bir biçimde göstermektedir. Şekil 9-c incelendiğinde; eğitim verisi üzerinde bütün modellerin tahminlerinin, genel eğri şeklini sağladığı, ancak üstel regresyon eğrisinin, belirgin olarak diğerlerine kıyasla en büyük sapmaya sahip olduğu görülmektedir. Bütün modellerin eğitildiği kümede, kümeyi çok iyi temsil etmesi zaten beklenen bir durumdur. Bununla birlikte, modellerin test kümesi üzerindeki tahmin performanslarını değerlendirmek üzere Şekil 9-b incelendiğinde, regresyonların (üstel, YSA esaslı) ne denli sapma gösterdiği daha iyi görülecektir.

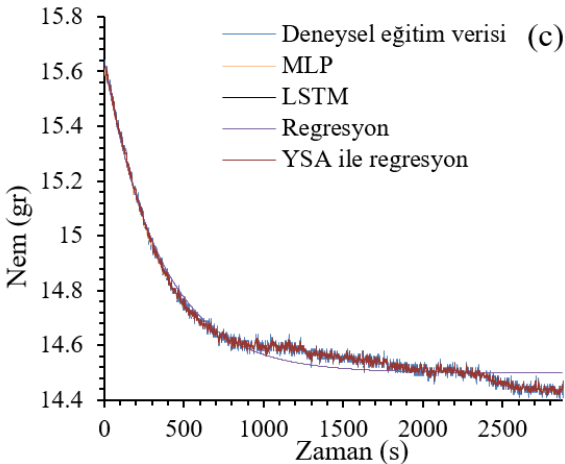

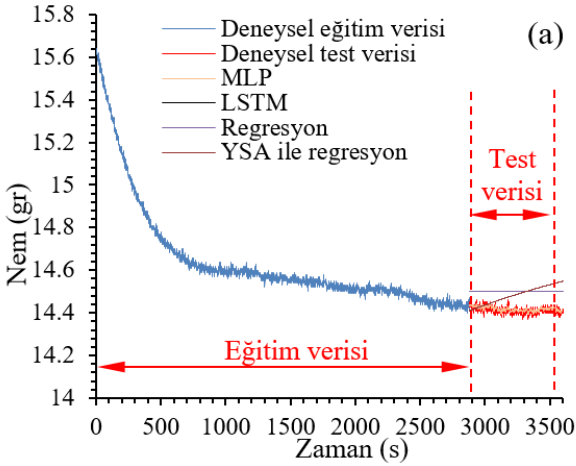
Regresyon teknikleri ile eğitim kümesi üzerinde ne kadar başarı ile eğri uydurulmuş olurlarsa olursun, küme dışı değerlerin tahmininde en kötü uyumu verdikleri açıkça görülmüştür. Kurutma kinetiğinin yol açtığı çokça tepeliklere sahip olan eğri şeklini, MLP ve LSTM ağları sağlayabilmiştir. Tepelikleri temsil etmede MLP ağının, LSTM ağından daha başarılı olduğu görülmektedir.





**Şekil 9.** 80°C’ de kurutma deneyinden elde edilen (a) eğitim ve test verisi, (b) modellerin test verisini temsil edebilme performansları, (c) modellerin eğitim verisini tahmin edebilme performansları

**Figure 9.** For the sample dried at 80°C, (a) the training and test data, (b) models’ performance to represent the test data, (c) models’ prediction performance on the training data

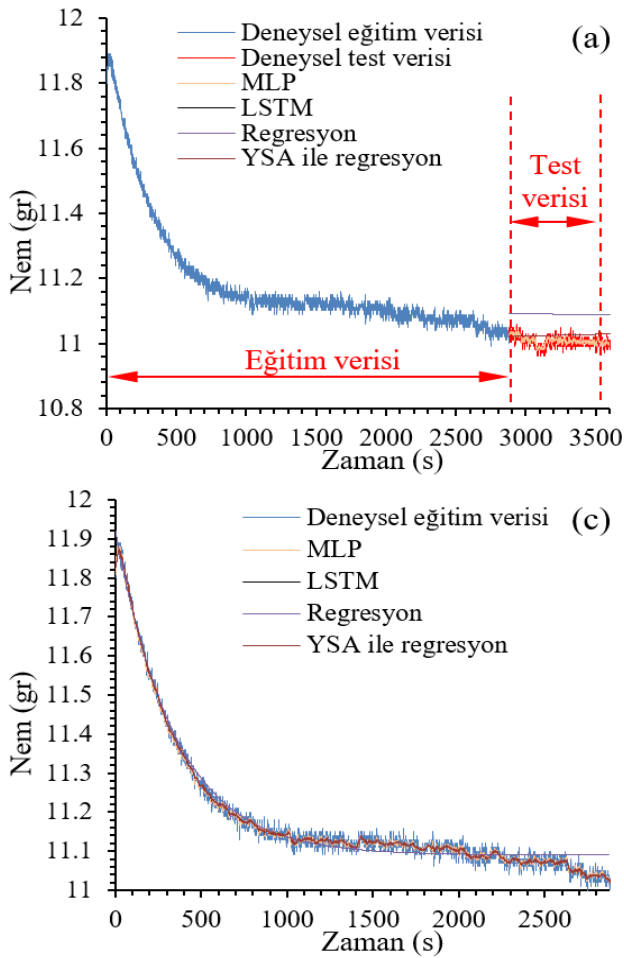


**Şekil 10.** 75°C’ de kurutma deneyinden elde edilen (a) eğitim ve test verisi, (b) modellerin test verisini temsil edebilme performansları, (c) modellerin eğitim verisini tahmin edebilme performansları

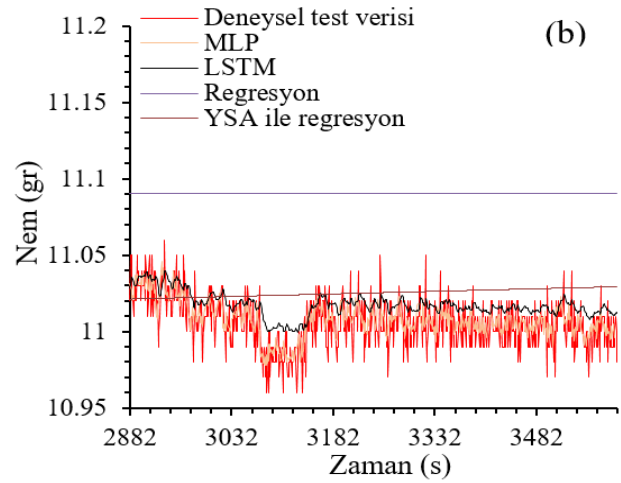
**Figure 10.** For the sample dried at 75°C, (a) the training and test data, (b) models’ performance to represent the test data, (c) models’ prediction performance on the training data

Şekil 10'da modellerin 75°C sıcaklıktaki kurutma verisi üzerindeki performansları gösterilmiştir. Şekil 10-c incelendiğinde; eğitim verisi üzerinde bütün model tahminlerinin, genel eğri şeklini sağladığı görülmektedir. Modellerin test kümesi üzerindeki tahmin performanslarını değerlendirmek üzere Şekil 10-b incelendiğinde, üstel regresyonun sabit bir değer verdiği, bununla birlikte YSA regresyonun da en sapmalı eğriyi verdiği görülmüştür.

Şekil 11'deki modellerin 70°C sıcaklıktaki kurutma verisi üzerindeki performansları



gösterilmiştir. Şekil 11-c incelendiğinde; eğitim verisi üzerinde bütün model tahminlerinin genel eğri şeklini sağladığı görülmektedir. Modellerin tahmin performansları Şekil 11-b'de görülmektedir. Üstel regresyonun en sapmalı olan eğriyi verdiği ancak YSA regresyonunun genel durumu tahmin edebildiği görülmüştür. Kurutma genel eğrisinin sabit bir değerde kalmış olmasından kaynaklı bu sonuca ulaşıldığı düşünülmektedir. MLP ve LSTM ağlarının hem eğitim, hem de test verileri üzerindeki tahmin performansları, diğerleri ile kıyaslandığında en iyi olmakla birlikte, MLP ağının tahmin performansının LSTM'den daha iyi olduğu, test verileri üzerinden anlaşılmaktadır.



**Şekil 11.** 70°C' de kurutma deneyinden elde edilen (a) eğitim ve test verisi, (b) modellerin test verisini temsil edebilme performansları, (c) modellerin eğitim verisini tahmin edebilme performansları

**Figure 11.** For the sample dried at 70°C, (a) the training and test data, (b) models' performance to represent the test data, (c) models' prediction performance on the training data

Sıcaklıkların, modellerin tahmin performansı üzerine etkisi araştırıldığında; 75°C'de, MLP ve LSTM eğrilerinin deneysel eğriyi temsil edebilme özelliğinin, diğer sıcaklıklara göre daha iyi olduğu görülmüştür. 80°C'de ve 75°C'de, sapmalar da artmaktadır. Sapma, eğrinin bir bütün halinde, yukarı doğru kayması şeklinde oluşmuştur. Üstel ve YSA esaslı regresyon eğrilerinde ise, düşük sıcaklıkta daha yüksek uyum görülmüştür. Bunun sebebinin; bu sıcaklıkta kurutma sonuna doğru, kuruma eğrisinin bir kararlı hale ulaşmış olması ve

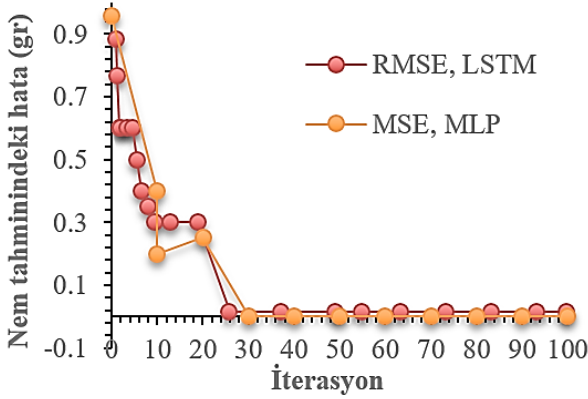
böylesi kararlı bir eğriyi temsil edebilmenin ise nispeten daha kolay olduğu anlaşılmaktadır.

### 3.2 Doğrulamalar

#### 3.2. Validations

Her ne kadar eğitilen MLP ve LSTM ağları, test verileri ile doğrulanmış ise de, ilave olarak, eğitim boyunca RMSE ve MSE değerlerinin nasıl değiştiğini, yakınsayıp-yakınsamadığını, kararlılığını yitirip-yitirmediğini görmek üzere,

Şekil 12'deki gibi hata yakınsama eğrileri elde edilmiştir. Eğrilerden anlaşılacağı üzere, hata değerleri azalarak, sifıra doğru yakınsamıştır. 30 iterasyondan sonra hata değeri en düşük değerinde olup değişmemektedir. Böylelikle, iterasyon sınırının isabetli seçilmiş olduğu anlaşılmaktadır.



**Şekil 12.** Ağların eğitimi esnasında hatanın yakınsaması

**Figure 12.** Error convergence during training of networks

MLP ağının performans göstergeleri Tablo 6'da ve LSTM performans değerleri ise Tablo 7'de verilmiştir. MLP ağının 0.2 mg ve LSTM ağının ise 19 mg hata ile tahminlerde bulunduğu görülmüştür. MLP ağının, LSTM ağına göre daha isabetli tahminlerde bulunduğu tespit edilmiştir. MLP ağının eğitim esnasındaki performansından elde edilen korelasyon, test performansındakinden daha yüksek çıkmıştır.

**Tablo 6.** MLP ağının eğitimi ve testi esnasındaki tahmin performansları

**Table 6.** Test and training performance of MLP network

Sıcaklık °C	Tahmin		Eğitim	
	RMSE (gr)	R	RMSE (gr)	R
80	0.000298	0.904	0.000207	0.999
75	0.000197	0.490	0.000208	0.998
70	0.000204	0.542	0.000203	0.997

**Tablo 7.** LSTM ağının tahmin performansı

**Table 7.** Prediction performance of LSTM network

Sıcaklık °C	RMSE (gr)	MAE (gr)	MAPE (%)	R
80	0.019	0.015	0.104	0.912
75	0.015	0.012	0.082	0.531
70	0.018	0.015	0.136	0.567

Hem üstel regresyon hem de YSA ile yapılan regresyonların, eğitim verisi üzerindeki performansları sırasıyla Tablo 8 ve Tablo 9'da verilmiştir. Hata ve korelasyon değerleri, eğitim verisi kullanılarak yapılan eğri uydurma işlemine ait performans değerleridir. Korelasyon, özellikle YSA esaslı regresyonda 1'e eşit veya çok yakın çıkmış ve hata değerleri ise 15 mgr olmuştur. Ancak bu değerlerin, regresyonların, eğitim veri kümesi üzerindeki performansı olduğu unutulmamalıdır. Bu nedenle bu değerler, Tablo 6 ve 7'de verilmiş olan tahmin değerleri ile kıyaslanmamalıdır. Regresyonların test verisi üzerindeki performansları ise korelasyon ve hata değerleri yerine tahmin eğrilerinin, deneysel eğriye uygunluğunun kıyaslanması sureti ile belirlenmiştir.

**Tablo 8.** Üstel regresyona ait parametreler

**Table 8.** Parameters of exponential regression

Sıcaklık °C	$C_0$	$C_1$	$C_2$	$R^2$	RMSE (gr)
80	14.68	1.5610	-0.001941	0.983	0.049
75	14.50	1.1330	-0.002830	0.980	0.035
70	11.09	0.8327	-0.002887	0.982	0.024

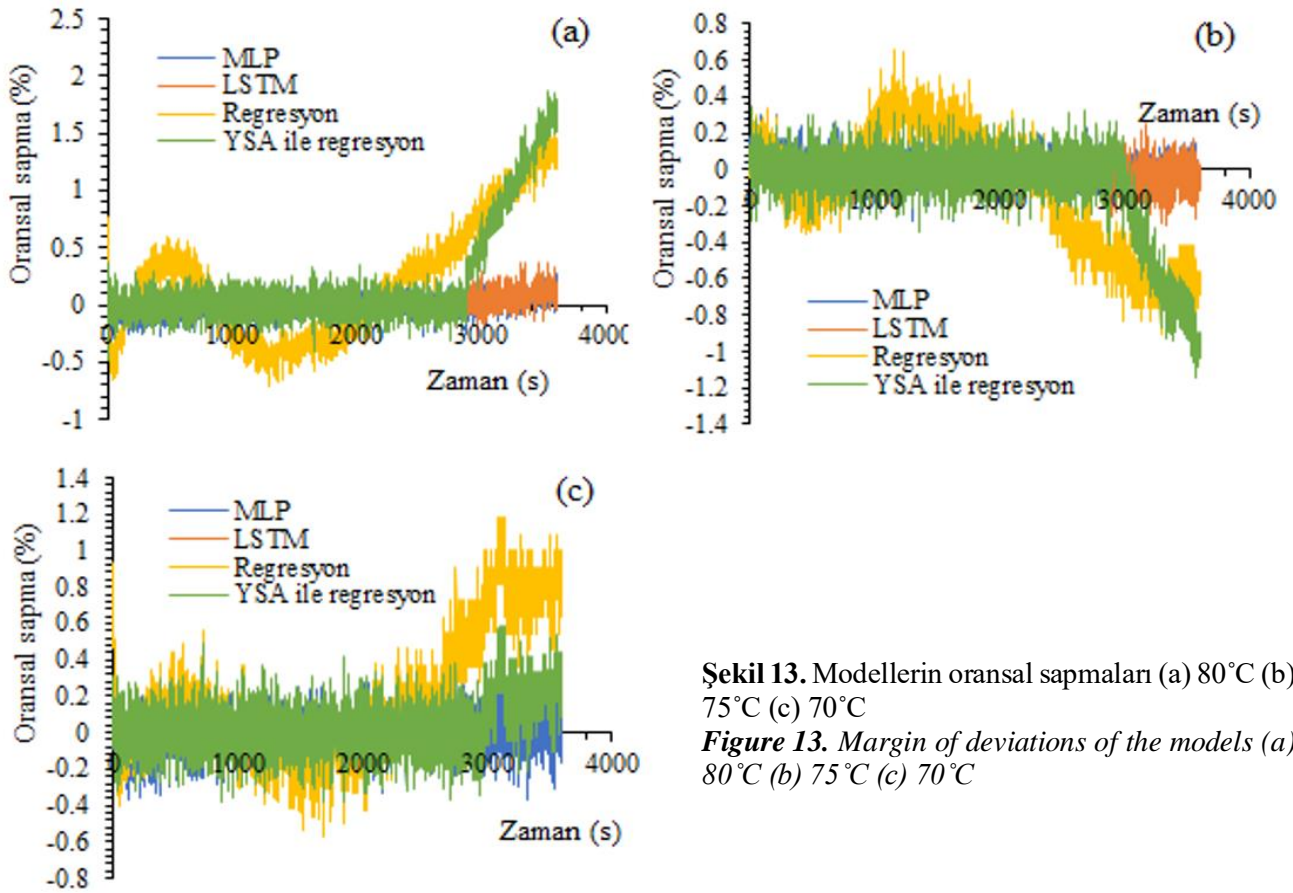
**Tablo 9.** YSA ile yapılan regresyona ait parametreler

**Table 9.** Parameters of the ANN regression

Sıcaklık °C	$\sigma_i$	$\sigma_f$	$R^2$	RMSE (gr)
80	5.223	0.688	1.00	0.015299
75	2.365	0.478	1.00	0.015264
70	41.670	0.393	0.99	0.013474

Sıcaklıkların modellerin, tahmin performansı üzerine etkisi tablolardan da, grafiklerden elde edilen bulgularla paralel olduğu görülmektedir. 75°C'de, MLP ve LSTM hata değerlerinin, diğerlerine göre en az olduğu görülmüştür. 80°C'de ve 75°C'de, sapmalar da artmaktadır. Üstel ve YSA esaslı regresyon eğrilerinde ise, düşük sıcaklıkta daha düşük hata görülmüştür.  $R$  ve  $R^2$  incelendiğinde ise, iki çıktı (deneysel, model) arasında güçlü bir ilişkinin var olduğu anlaşılmaktadır.

Şekil 13'te ise modellerin oransal sapma eğrileri verilmiştir. MLP ağı, YSA ile regresyon ve LSTM modelleri en fazla  $\pm 0.5\%$  arasında sapma göstermişken, regresyon modelindeki sapma  $\pm 2\%$ 'ye kadar çıkmıştır. YSA esaslı regresyon modeli ise tahmin esnasında yüksek sapmalar vermiştir. Bu da tahmin eğrilerinden elde edilen sonuçları doğrular niteliktedir.



Şekil 13. Modellerin oransal sapmaları (a) 80°C (b) 75°C (c) 70°C

Figure 13. Margin of deviations of the models (a) 80°C (b) 75°C (c) 70°C

### 3.3 Tartışma

#### 3.3. Discussion

Tarımsal kurutma işlemlerinin modellenmesi çalışmalarında, genellikle regresyon analizinin kullanıldığı görülmektedir. Regresyon ile RMSE değerinin en az 0.0271 gr'a kadar düşürülebildiği bildirilmiştir (Karacabey vd., 2020). Bu çalışmadaki regresyon analizlerinden en fazla 0.015932 gr RMSE değeri elde edilmiştir. Bu durum bu alanda yapılan çalışmalardan daha iyi bir sonuç elde edildiğini göstermektedir. Kurutma modellerinin regresyon ile üretildiği bir başka

çalışmada ise karşılaştırılan on iki adet model arasında sadece bir adetinde 0.007 gr. bir hata ile tahmin elde edilebildiği, diğerlerinde ise en az 0.011 gr olduğu görülmüştür (Çelen vd., 2016). Bu çalışmada, tahmin performansı 0.000208 gr olarak elde edilen MLP ağının kullanımının, çok daha başarılı olduğu anlaşılmaktadır. LSTM' nin MLP ağına kıyasla yetersiz kalmasının nedeni, eğitimi için çokça veri gerektirmesidir. Kurutma işleminde ise çokça veri bulunmadığından dolayı LSTM' nin başarısını yeterince gösteremediği düşünülmüştür. Farklı kurutma çalışmalarından bildirilen sonuçlar Tablo 10'da kıyaslanmıştır.

Tablo 10. Mevcut ve literatürdeki kurutma çalışmalarının kıyaslanması

Table 10. Comparison of proposed and drying studies in the literature

Kaynak	Kurutma türü	Model	Performans (RMSE, gr)
Mevcut çalışma	Organomineral bitki besini	MLP	0.000207
		LSTM	0.019
		Regresyon	0.049
		YSA Reg.	0.152
(Perazzini vd., 2013)	Katı atık	MLP	0.255
(Estiati vd., 2016)	Biyokütle	Regresyon	0.3728
		MLP	0.9727
(Omari vd., 2018)	Mantar	HHV	0.9027
(Sun vd., 2016)	Katı atık	MLP	0.2179
(Naqvi vd., 2018)	Küllü çamur	MLP	0.401
		MLP	0.852



## 4 Sonuç

### 4. Conclusion

Endüstriyel kurutma işlemlerinde, ürün kalitesi ve işlem verimliliği için optimum kurutma parametrelerin kullanılması gerekmektedir. Bu parametreler, ürün türüne göre farklı değerler alabilmektedirler. Parametrelerin tespiti için pek çok yöntem denenmektedir. Bu çalışma kapsamında, tarım endüstrisinde önemli problemlerin başında gelen organomineral bir gübrenin kuruma davranışının modellenmesi amaçlanmıştır. Sadece regresyon değil, aynı zamanda MLP ve LSTM modellerinin performansları da araştırılmıştır. Regresyon yöntemi olarak, üstel fonksiyon kullanılmıştır. Bununla birlikte kovaryans çekirdek fonksiyonuna sahip, YSA esaslı Gauss regresyonu da incelenmiştir. Modellerin sadece mevcut veri üzerindeki performansları değil, aynı zamanda veri kümesi dışındaki tahmin performansları da kıyaslanmıştır. İsaletli tahminler, bu alanda faaliyet gösteren firmalara hızlilik ve rekabet gücü katması açısından öneme sahiptir. Çalışma sonunda elde edilmiş olan temel çıkarımlar aşağıda maddeler halinde sıralanmıştır.

- Gübre kurutma işleminde, YSA esaslı regresyonlar da dâhil tüm regresyonlar, sadece mevcut veriyi modellemede kullanışlı iken, ileriye yönelik tahminler için kullanışlı değildirler. YSA esaslı regresyonun, kurutma eğrilerinin sahip olduğu tepe ve çukurlukları temsil edebilme yeteneği, doğrusal olmayan regresyona göre daha yüksektir.
- MLP ağının eğitimlerinde kullanılan veri kümesinin bölümlenmesi, ağ başarısı üzerinde etkilidir. %80 eğitim, %10 doğrulama ve %10 test bölümlenmesi, en başarılı ağı oluşturmuştur. Gizli katmandaki nöron sayılarının optimum değeri 6 olarak belirlenmiştir.
- MLP ve LSTM ağları, hem mevcut veriyi modellemede hem de ileriye yönelik tahminlemelerde regresyon denklemlerinden daha başarılı performans sergilemektedirler. MLP ve LSTM kendi içerisinde kıyaslandığında, gübre kurutma tahminleri için, MLP'nin performansının daha yüksek olduğu görülmüştür. Mevcut veriyi modellemede, MLP ile yapılan regresyonda korelasyon 1'e eşit veya çok yakın çıkmış ve hata değerleri ise 15 mgr olmuştur. MLP, LSTM yöntemlerinin, kurutma eğrilerinin sahip olduğu tepe ve çukurlukları temsil

edebilme yeteneği, regresyonlara göre daha yüksektir.

- Sıcaklıklar, modellerin tahmin performansı üzerinde etkilidir. MLP ve LSTM eğrileri, deneysel eğriyi en iyi, 75°C'deki kurutma işleminde temsil edebilmişlerdir.

## Teşekkür

### Acknowledgement

Bu çalışmanın inceleme ve değerlendirme aşamasında yapmış oldukları değerli katkılardan dolayı; derginin editör, hakem ve emeği geçenlerine içten teşekkür ederiz.

## Yazar katkısı

### Author contribution

Yazarlar araştırmaya eşit oranda katkı sağlamışlardır.

## Etik beyanı

### Declaration of ethical code

Bu çalışmada kullanılan materyal ve yöntemler, etik kurul izni ve/veya yasal-özel izin gerektirmemektedir.

## Çıkar çatışması beyanı

### Conflicts of interest

Yazarlar herhangi bir çıkar çatışması olmadığını beyan eder.

## Kaynaklar

### References

- Adıyaman, F. (2007). *Talep Tahmininde Yapay Sinir Ağlarının Kullanılması*. [Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü].
- Amini, G., Salehi F., & Rasouli M. (2021). Drying kinetics of basil seed mucilage in an infrared dryer: Application of GA-ANN and ANFIS for the prediction of drying time and moisture ratio. *Journal of Food Processing and Preservation*, 45(3), e15258. <https://doi.org/10.1111/jfpp.15258>
- Anderson, D., & McNeill, G. (1992). *Artificial neural networks technology*. Rome Laboratory. A011.
- Bayır, F. (2006). *Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama*. [Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü].

- Beigi, M., & Torki, M. (2021). Experimental and ANN modelling study on microwave dried onion slices. *Heat and Mass Transfer*, 57, 787–796. <https://doi.org/10.1007/s00231-020-02997-5>
- Bidgoli, M.R., Kolahchi R., & Karimi M.S. (2016). An experimental study and new correlations of viscosity of ethylene glycol-water based nanofluid at various temperatures and different solid concentrations. *Structural Engineering and Mechanics*, 58(1), 93-102. <https://doi.org/10.12989/sem.2016.58.1.093>
- Brownlee, J. (2018, 12 Aralık). *A gentle introduction to K-fold cross-validation*. Machine Learning Mastery. <https://machinelearningmastery.com/k-fold-cross-validation/>
- Çavuşlu, M.A., Becerikli, Y., & Karakuzu, C. (2012). Levenberg-Marquardt algoritması ile YSA eğitiminin donanımsal gerçekleşmesi. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5(1).
- Çelen, S., Buluş, H. N. Moralar, A., Haksever, A., & Özsoy, E. (2016). Availability and Modelling of Microwave Belt Dryer in Food Drying. *Journal of Tekirdag Agricultural Faculty*, 13(04), 71-83.
- Eaton J. W. (2022). *GNU Octave*. Free Software Foundation. Association of volunteers.
- Erenturk, S., & Erenturk, K. (2007). Comparison of genetic algorithm and neural network approaches for the drying process of carrot. *Journal of Food Engineering*, 78, 905-912. <https://doi.org/10.1016/j.jfoodeng.2005.11.031>
- Estiati, I., Freire, F. B., Freire, J. T., Aguado, R., & Olazar, M. (2016). Fitting performance of artificial neural networks and empirical correlations to estimate higher heating values of biomass. *Fuel*, 180, 377-383. <https://doi.org/10.1016/j.fuel.2016.04.051>
- Heris, S.M.K. (2015). *Time-series prediction using ANFIS*. Yarpiz©.
- Karacabey, E., Aktaş, T., Taşeri, L., & Seçkin, G. U. (2020). Sultani çekirdeksiz üzüm çeşidinde farklı kurutma yöntemlerinin kurutma kinetiği, enerji tüketimi ve ürün kalitesi açısından incelenmesi. *Journal of Tekirdag Agricultural Faculty*, 17(1), 53-65. <https://doi.org/10.33462/jotaf.578962>
- Kaveh, M., Sharabiani, V. R., Chayjan, R. A., Taghinezhad, E., Abbaspour-Gilaneh, Y., & Golpour, I. (2018). ANFIS and ANNs model for prediction of moisture diffusivity and specific energy consumption potato, garlic and cantaloupe drying under a convective hot air dryer. *Information Processing in Agriculture*, 18(1), 45. <https://doi.org/10.1016/j.inpa.2018.05.003>
- Khanlari, A., Güler, H.O., Tuncer, A.D., Sirin, C., Bilge, Y.C., Yılmaz, Y., & Güngör, A. (2020). Experimental and numerical study of the effect of integrating plusshaped perforated baffles to solar air collector in drying application. *Renew. Energy*, 145, 1677–1692. <https://doi.org/10.1016/j.renene.2019.07.076>
- Kılıç, F. (2021). Effects of three drying methods on kinetics and energy consumption of carrot drying process and modelling with artificial neural networks. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 43(12), 1468-1485. <https://doi.org/10.1080/15567036.2020.1832163>
- Köklü, N., Büyüköztürk, Ş., & Çokluk-Bökeoğlu Ö. (2006). *Sosyal bilimler için istatistik* (25. baskı), Ankara: Pegem Yayıncılık.
- Lertworasirikul, S., & Tipsuwan, Y. (2008). Moisture content and water activity prediction of semi-finished cassava crackers from drying process with artificial neural network. *Journal of Food Engineering*, 84, 65-74. <https://doi.org/10.1016/j.jfoodeng.2007.04.019>
- Mansuroğlu, N.P., Yazıcı, E., Önder, S., & Karaç, A.C. (2020). Maltodekstrin-nohut proteini izolati matrisinde karabiber tohumu yağının püskürtmeli kurutma metodu ile enkapsülasyonu. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 9(2), 877-882. <https://doi.org/10.28948/ngmuh.649969>
- MathWorks. (2022, July 30). *Kernel (Covariance) Function Options*. <https://www.mathworks.com/help/stats/kernel-covariance-function-options.html>.
- MathWorks. (2022, July 30). *Statistics and Machine Learning Toolbox*. [https://www.mathworks.com/help/stats/index.html?s\\_tid=CRUX\\_lftnav](https://www.mathworks.com/help/stats/index.html?s_tid=CRUX_lftnav).
- Million, E. (2022, April 12). *The Hadamard Product. Linear Algebra*. <https://buzzard.ups.edu>.
- Moreno, J.J.M., Pol, A.P., Abad, A.S., & Blasco, B.C., (2013). Using the R-MAPE index as a resistant measure of forecast accuracy. *Psicothema*, 25(4), 500-506. <https://doi.org/10.7334/psicothema2013.23>
- Nakilcioğlu-Taş, E., & Ötleş S. (2021). Zeytin çekirdeği antioksidanlarının dondurarak kurutma tekniği ile mikroenkapsülasyonu: Toz ürünün fiziksel ve kimyasal karakterizasyonu. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 10(1), 140-149. <https://doi.org/10.28948/ngmuh.740797>

- Naqvi, S.R., Rumaisa, T., Zeeshan, H., Imtiaz A., Syed A. T., Muhammad N., Niazi, M. B. K., Tayyaba N., & Wasif F., (2018). Pyrolysis of high-ash sewage sludge: Thermo-kinetic study using TGA and artificial neural networks. *Fuel*, 233, 529-538. <https://doi.org/10.1016/j.fuel.2018.06.089>
- Omari, A., N. Behrooz-Khazaei, & F. Sharifian, (2018). Drying kinetic and artificial neural network modelling of mushroom drying process in microwave-hot air dryer. *Journal of Food Process Engineering*, e12849. <https://doi.org/10.1111/jfpe.12849>
- Onu, C. E., Igbokwe, P. K., Nwabanne, J. T., & Ohale, P.E. (2022). ANFIS, ANN, and RSM modelling of moisture content reduction of cocoyam slices. *Journal of Food Processing and Preservation*, 46(1), e16032. <https://doi.org/10.1111/jfpp.16032>
- Öğündür, G., (2019, April 08). *Overfitting (aşırı öğrenme), underfitting (eksik öğrenme) ve bias-variance çelişkisi*. Medium. <https://medium.com/@gulcanogundur/overfitting-aşırı-öğrenme-underfitting-eksik-öğrenme-ve-bias-variance-çelişkisi-b92bef2f770d>
- Park I., Kim, H. S., Lee J., Kim, J. H., Song, C. H., & Kim, H. K. (2019). Temperature prediction using the missing data refinement model based on a long short-term memory neural network. *Atmosphere (Basel)*, 10, 1-16. <https://doi.org/10.3390/atmos10110718>
- Perazzini, H., Freire, F., & Freire, J. (2013). Drying kinetics prediction of solid waste using semi-empirical and artificial neural network models. *Chemical Engineering & Technology*, 36(7), 1193-1201. <https://doi.org/10.1002/ceat.201200593>
- Polatoğlu, B., & Beşe, A.V. (2017). Kızılcık meyvesinin (cornus mas. L) konvektif kurutulması: kuruma kinetiği ve c vitamini bozulması. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 6(2), 406-414. <https://doi.org/10.28948/ngumuh.341200>
- Poonnoy, P., Tansakul, A., & M. Chinnan, (2007). Artificial neural network modelling for temperature and moisture content prediction in tomato slices undergoing microwave-vacuum drying. *JFS E: Food Engineering and Physical Properties*, 72(1), 42-47. <https://doi.org/10.1111/j.1750-3841.2006.00220.x>
- Sekertekin, A., Bilgili, M., Arslan, N., Yildirim, A., Celebi, K., & Ozbek, A. (2021). Short-term air temperature prediction by adaptive neuro-fuzzy inference system (ANFIS) and long short-term memory (LSTM) network. *Meteorology and Atmospheric Physics*, 133(3), 943-959. <https://doi.org/10.1007/s00703-021-00791-4>
- Sit, H., (2019, January 18). *Quick start to Gaussian process regression*. Towards data science. <https://towardsdatascience.com/quick-start-to-gaussian-process-regression-36d838810319>
- Taheri, S., Brodie, G., & Gupta, D. (2021). Optimised ANN and SVR models for online prediction of moisture content and temperature of lentil seeds in a microwave fluidised bed dryer. *Computers and Electronics in Agriculture*, 182, 106003. <https://doi.org/10.1016/j.compag.2021.106003>
- Tarafdar, A., Jothi, N., & Kaur, B. (2021). Mathematical and artificial neural network modeling for vacuum drying kinetics of moringa olifera leaves followed by determination of energy consumption and mass transfer parameters. *Journal of Applied Research on Medicinal and Aromatic Plants*, 24, (100306). <https://doi.org/10.1016/j.jarmap.2021.100306>
- Topuz, A., (2010). Predicting moisture content of agricultural products using artificial neural networks. *Advances in Engineering Software*, 41(3), 464-470. <https://doi.org/10.1016/j.advengsoft.2009.10.003>
- Yifei, S., Lina, L., Qiang, W., Xiaoyi, Y., & Xin, T., (2016). Pyrolysis products from industrial waste biomass based on a neural network model. *Journal of Analytical and Applied Pyrolysis*, 120, 94-102. <https://doi.org/10.1016/j.jaap.2016.04.013>
- Zadhossein, S., Abbaspour-Gilandeh, Y., Kaveh, M., Szymank, M., Khalife, E., Samuel, O. D., Amiri M., & Dziwulski, J. (2021). Exergy and energy analyses of microwave dryer for cantaloupe slice and prediction of thermodynamic parameters using ANN and ANFIS algorithms. *Energies*, 14(16), 4838. <https://doi.org/10.3390/en14164838>