

N25P5K5 Türü Yeni Nesil Bir Bitki Besininin Kuruma Kinetiğinin Regresyon ve Makine Öğrenme Yöntemleri ile Belirlenmesi

İlyas KACAR¹ ORCID 0000-0002-5887-8807
Cem KORKMAZ*² ORCID 0000-0003-1062-4581

¹Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, Niğde

²Çukurova Üniversitesi, Ziraat Fakültesi, Tarım Makineleri ve Teknolojileri Mühendisliği Bölümü, Adana

Geliş tarihi: 20.05.2022

Kabul tarihi: 27.12.2022

Atıf şekli/ How to cite: KACAR, İ., KORKMAZ, C., (2022). N25P5K5 Türü Yeni Nesil Bir Bitki Besininin Kuruma Kinetiğinin Regresyon ve Makine Öğrenme Yöntemleri ile Belirlenmesi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 37(4), 989-1003.

Öz

Gittikçe artan dünya nüfusunun gıda ihtiyacını karşılayabilmek için araştırmacılar tarımsal verimin artırılmasına yönelik yoğun bir şekilde çalışmaktadırlar. Bu çalışmaların önemli bir kısmını; zirai, katı atık vb. ürünlerin kuruma davranışının modellenmesi oluşturmaktadır. Verimli bir kurutma sayesinde kaliteli ürün ve enerji tasarrufu elde edilmektedir. Bu çalışmada yeni nesil bitki besinlerinden biri olan %25 azot, %5 fosfor ve %5 potasyum karışımının kuruma davranışı modellenmiştir. Kurumanın modellenebilmesi için sadece regresyon değil aynı zamanda makine öğrenme yöntemleri de kullanılmıştır. Makine öğrenme yöntemlerinden yapay sinir ağları ve uzun-kısa süreli bellek yöntemleri kullanılmıştır. Bu yöntemlerin hem kuruma verisini modellemede hem de ileriye yönelik verilerin tahminindeki performansları araştırılmıştır.

Kurutma deneylerinden elde edilen nem verisi kullanılmıştır. Veriler eğitim, doğrulama ve test kümelerine ayrılmıştır. Performans değerlendirme kriterleri olarak hata fonksiyonları, korelasyon ve determinasyon katsayıları kullanılmıştır. Sonuç olarak yapay sinir ağı ve uzun-kısa süreli bellek metodlarının hem eğitim hem de test verileri üzerindeki tahmin performanslarının regresyon yöntemlerine göre oldukça iyi olduğu görülmüştür. Yapay sinir ağı tahmin performansının uzun-kısa süreli bellek yönteminden daha başarılı olduğu ve en iyi tahmin performansını verdiği tespit edilmiştir.

Anahtar Kelimeler: Kurutma, Yapay sinir ağı, Uzun-kısa süreli bellek, Regresyon, Makine öğrenmesi, Yapay zekâ

*Sorumlu yazar (Corresponding author): Cem KORKMAZ, ckorkmaz@cu.edu.tr

Determination of Drying Kinetics of a N25P5K5 Type New Generation Plant Food by Regression and Machine Learning Methods

Abstract

To meet the food needs of the growing world population, researchers are working intensively on increasing agricultural productivity. An important portion of these studies are the modelling of drying behaviour of agricultural products, solid waste etc. An efficient drying leads to quality products and energy savings. In this study; the drying behaviour of a new-generation plant food consisting of a mixture of 25% nitrogen, 5% phosphorus and 5% potassium is modelled. For modelling of drying, not only regression but also machine learning methods were used. Artificial neural networks and long short-term memory methods were used as the machine learning technics. The performance of these methods was investigated on modelling the drying behaviour and forecasting the future data.

Moisture data obtained from the drying experiments were used. The data is divided into training, test, and validation sets. Error functions, correlation and determination coefficients were used as the performance evaluation criteria. As a result, it has been seen that the prediction performances of artificial neural networks and long short-term memory methods on both training and test data are quite good compared to regression methods in this study. It has been determined that the artificial neural network prediction performance is more successful than the long short-term memory method and gives the best prediction performance.

Keywords: Drying, Artificial neural network, Long short-term memory, Regression, Machine learning, Artificial intelligence

1. GİRİŞ

Gıda, tarım ürünleri, katı atıkların ayrıştırılması vb. alanlarda ürünlerin kuruma kinetiğinin belirlenmesi ile bu tür ürünleri üreten işletmelerin verimliliğine ve ürün kalitesine önemli katkılar sağlanabilmektedir. Kaliteli ürün ise sekiz milyara yaklaşan dünya nüfusuna yetecek tarım yapabilmek için gereklidir. Bu nedenle ülkemizde bu alanda faaliyet gösteren işletmelerin dünya standartlarında ürün elde edebilmeleri bir zorunluluktur.

Organik gübre üreticilerinin en büyük problemi ise her farklı gübre tipi için optimum işletme parametrelerine ihtiyaç duymalarıdır. Ancak, genellikle bünyelerinde araştırma geliştirme veya ürün geliştirme faaliyetleri bulunmayan küçük ve orta ölçekli işletmelerin deneme-yanılma yöntemi ve kişisel tecrübe ile gerçekleştirdikleri parametre tespiti süreci pahalı hatta bazen tutarsız bir yöntem olmaktadır. Bu tür işletmelerin başka bir çözüm yöntemi ise sektörde endüstriyel olarak gelişmiş firmaları taklit etmeleridir. Optimum kurutma parametrelerin belirlenmesi proses

simülasyonlarının verimliliği için de önemlidir. Zira bu tür simülasyonlar sadece ürünün kuruma davranışı değil aynı zamanda tüm sürecin fiziği hakkında bilgi verebilen yöntemlerdir.

Kurutma davranışının tespiti için kolay bir diğer yöntem ise pek çok araştırmacı tarafından literatüre kazandırılmış olan matematiksel modellerin kullanılmasıdır. Literatürde pek çok hazır matematiksel model mevcuttur [1-3]. Bu modellerin çoğu polinomsal, üstel, logaritmik vb. fonksiyonlardan elde edilen sonuçların, kurutma deneylerinden elde edilen verilere eğri uydurması ile keşfedilmiş ampirik bağıntılardır. Örneğin; nohut tanesinin leblebi üretimi için baharat kaplanmasında logaritmik modelin başarılı olduğu görülmüştür [1]. Doğada çözünebilen ambalaj ve tekstil maddesi üretiminde son yıllarda sıklıkla kullanılan zeytin çekirdeğinin kurutulmasının modellenmesinde ise polinomsal fonksiyonların başarılı olduğu bildirilmiştir [2].

Literatürdeki hazır bağıntıların kullanılması kolay olmakla birlikte farklı ürün türlerinin birbirlerinden

farklı olan kuruma davranışları, hatta aynı ürünün kurutulmasında bile kurutma şartlarındaki olası değişimlerin yol açtığı farklılıklar nedeni ile kuruma davranışı tahminlerinde büyük sapmalar meydana gelebilmektedir. Bu durumda da her bir kuruma deneyini ayrı ayrı gerçekleştirip deneysel sonuçlara eğri uydurulması ile mevcut ilişkiyi tespit etmek mantıklı bir başka seçenektir. Bu nedenle çoğunlukla regresyon yöntemi kullanılmaktadır. Ancak regresyonlar tarımdan tıba kadar her türlü deneysel veri üzerinde kullanılagelen kadim bir yöntem olsa da sadece mevcut veri kümesini temsil edebilmede kullanışlı olmuştur. Aralık ötesindeki durumların tahminindeki başarıları ile ilgili literatürde herhangi bir çalışmaya rastlanmamıştır.

Bu gibi dezavantajları olmayan alternatif bir başka yöntem ise yapay sinir ağları (YSA), yapay zekâ (AI), uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS), uzun kısa süreli bellek (LSTM) gibi pek çok teknik içeren makine öğrenme algoritmalarıdır. Bu yöntemler kuruma davranışını tahmin etmede son yıllarda yaygın olarak kullanılmaktadır [4-6]. Biyolojik malzeme olan organik katı atığın kurutulmasında nem içeriğinin zamanla değişimini tahmin etmede YSA'nın umut verici sonuçlar verdiği belirtilmiştir [6]. YSA, insan beynindeki sinir ağlarının çalışmasını taklit eden yazılımsal bir tekniktir. İlk olarak McCulloch ve Pitts (1943) tarafından geliştirilmiş olan ve yıllardır birçok mühendislik uygulamasında kullanılan bir matematiksel araçtır [7]. Enerji santrallerinden [8-10] tıba kadar [11] pek çok alanda kullanılmaktadır. Zirai kurutma işlemlerinin modellenmesinde ise yeni yeni kullanılmaktadır. Sıcak hava ile yapılan bir sebze-meyve kurutma işlemi için sıcaklığa ve hıza bağlı olarak nem difüzyonunu, enerji tüketimini ve kurutma kinetiğini %99 doğrulukta tahmin edilebilen bir YSA modeli oluşturulabildiği görülmüştür [12]. Başka bir kurutma işleminde ise en düşük enerji tüketiminin tahmin edilmesinde YSA modelinin yüksek doğrulukta sonuçlar verdiği görülmüştür [13]. Ancak YSA kullanmada karşılaşılan bir güçlük, YSA oluşturmak için gereken parametrelerin seçiminde henüz belirli bir kuralın mevcut olmamasıdır. Parametrelerin; deneysel veri ve modelle hesaplanan değerler arasındaki korelasyonu en yüksek veya farkı en düşük yapacak şekilde,

deneme-yanılma yoluyla tespit edilmekte olduğu görülmüştür [14,15]. Ayrıca bir YSA eğitimi esnasında gerçekleştirilen iterasyonların gereğinden fazla olması halinde *aşırı öğrenme* [16] olarak adlandırılan bir ağ hatası oluşabilmektedir. Saklı katman ve nöron sayılarının azaltılması ile ağdaki aşırı öğrenme hatasının azaldığı belirtilmiştir. [17]. YSA eğitimi için kullanılan pek çok algoritma arasında Levenberg-Marquardt algoritması hız ve kararlılık sağladığı için çokça tercih edilmektedir [18].

Zaman serileri halinde veriye sahip olaylarda uzun-kısa süreli bellek (LSTM) olarak adlandırılan bir derin öğrenme ağının kullanılabildiği görülmüştür. LSTM ağları bir tür tekrarlı yapay sinir ağı olup makine öğrenmesinin bir başka türüdür [19,20]. Zirai ürünlerin ve yiyeceklerin kurutulmasında kurutma kinetiğinin yüksek doğrulukta belirlenmesi açısından LSTM ağının deneysel çalışma sonuçlarına en yakın tahmini verebildiği belirtilmiştir [21].

Mevcut çalışmalar ışığında tarım, gıda, katı atıklar vb. ürünlerin kuruma davranışının modellenmesi için açık literatürde pek çok çalışmanın olduğu, ancak %25 azot, %5 fosfor, %5 potasyum karışımından oluşan yeni nesil bitki besininin kuruma kinetiğinin belirlenmesine ilişkin çalışmaların yok denebilecek kadar az olduğu görülmüştür. Makine öğrenme yöntemleri ile oluşturulan modellerin ise deneysel sonuçlara yüksek uyum sağlayabildiği görülmüş olup bu yöntemlerin yeni nesil gübre kurutulmasında da kullanım potansiyeline sahip olabileceği hipotezi ortaya atılarak konunun incelenmesine karar verilmiştir. Bu çalışmada; mezkûr bitki besininin; regresyon, YSA ve LSTM yöntemleri ile kurutma modelleri elde edilmiştir. Uygun ağ parametrelerinin nasıl tespit edildiği izah edilmiştir. Yöntemlerin başarı yüzdeleri hata kriterleri kullanılarak karşılaştırılmıştır.

2. YÖNTEM

2.1. Model Performanslarının Ölçülmesi

Modellerin verimliliğini değerlendirmenin en pratik yolu; deneylerden ölçülen veri ile modeller

tarafından tahmin edilen veri arasındaki farka bakmaktır. Bu amaçla da hata analizi yapmak yaygın bir fark belirleme yöntemidir. En sık kullanılan hata fonksiyonları Eşitlik 1'de verilmiştir. Birden fazla veri arasındaki ilişkiyi tespit etmek için ise korelasyon veya determinasyon katsayılarını kullanmak yaygın bir başka yöntemdir. Korelasyon katsayısının hesaplandığı formül ise Eşitlik 2'de verilmiştir.

$$MSE = \frac{1}{N} \sum_{t=1}^N (p(t) - o(t))^2 \quad (1.a)$$

$$RMSE = \sqrt{MSE} \quad (1.b)$$

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

$$MAPE = \frac{100}{N} \sum_{t=1}^N \frac{|p(t) - o(t)|}{o(t)} \quad (1.d)$$

Burada MSE ifadesi hatanın karelerinin ortalaması, $RMSE$ ise MSE 'nin kareköküdür. MAE , ortalama mutlak hata ve $MAPE$ ise ortalama mutlak yüzde hatadır. $o(t)$ değeri; t zaman adımındaki deneysel olarak ölçülen veri, $p(t)$ değeri ise t adımındaki tahmin edilen veridir.

$$R = \frac{(\sum_{t=1}^N [p(t) - \bar{p}][o(t) - \bar{o}])}{\sqrt{(\sum_{t=1}^N [(p(t) - \bar{p})]^2) \sum_{t=1}^N [(o(t) - \bar{o})]^2}} \quad (2)$$

Burada \bar{p} ve \bar{o} ifadeleri sırası ile tahmin edilen ve ölçülen değerlerin ortalamasıdır. N , veri kümesindeki toplam veri sayısıdır. Korelasyon katsayısının 1'e yakın olması, iki veri kümesi (model sayesinde oluşturulan eğri ile deneysel veri) arasındaki ilişkinin yüksek olduğunu göstermektedir. Korelasyon katsayısının karesine determinasyon katsayısı R^2 , denmektedir. Korelasyona ek olarak Eşitlik 3'te verilen standart sapma e_s ve ortalama kare sapma değeri χ^2 de kullanılabilir.

$$e_s = \sqrt{\frac{\sum_{t=1}^N [(p(t) - o(t))]^2}{N}} \quad (3.a)$$

$$\chi^2 = \frac{\sum_{t=1}^N [(p(t) - o(t))]^2}{N - Prm} \quad (3.b)$$


Burada Prm , kurutma modelindeki parametre sayısıdır.

2.2. YSA ile Modelleme

Esasen bir YSA modeli oluşturulabilmesi için aşağıdaki temel ağ özelliklerinin teknik gereği bu modele katılması lâzım olup bunların türü ve sayısı deneme-yanılma yöntemi ile belirlenmektedir. Ve YSA modelinin başarısı üzerinde çok etkilidir.

- Aktivasyon fonksiyonu
- Eğitim algoritması
- Ağın içerdiği saklı katman sayısı
- Saklı katmanlardaki nöron sayısı
- Kümedeki verinin bölünme oranı
- Eğitim esnasında gerçekleşen iterasyon sayısı
- Öğrenme hızı, momentum

Bu çalışmada Şekil 1'de şematik olarak gösterilen ileri beslemeli, çok katmanlı, lineer olmayan, kendini tekrarlayan denetimli bir ağ kullanılmıştır [22]. Bu tür ağlara çok katmanlı algılayıcı (ÇKA) ağı da denmektedir. Çıkış, t zaman adımındaki nem olup, giriş ise $t-1, t-2, \dots, t-10$ olmak üzere geriye dönük on adet ardışık zaman adımındaki nem değerleridir. Harici bir giriş yoktur. b terimi, gerektiğinde ağı yönlendirmek için hesaplamaya dahil edilen saptırma (bias) terimleri olup istatistik ve makine öğreniminde bir modelin tahmin değerlerinde iyileşme sağlayabilen özelliklerden biridir.



Şekil 1. Çalışmada kullanılan ÇKA ağ topolojisi

Optimum ağ özelliklerinin tespiti için saklı katmanlarda aktivasyon fonksiyonu olarak lineer, sigmoid ve tanjant hiperbolik kullanılmışken çıkış katmanında lineer fonksiyon kullanılmıştır. Öğrenme

algoritmaları olarak da Levenberg-Marquardt, Bayesian Regularization ve Conjugate Gradient algoritmaları denenmiştir. Saklı katman sayısı 1, 2 ve 3 olarak denenmiştir. Her saklı katmanda sırası ile 5, 10 ve 15 nöron kullanılmıştır. Veri kümesinin %80'i eğitim %10'u doğrulama ve %10'u test amaçlı ayrılmıştır. Öğrenme hızı olarak momentum için varsayılan değerler kullanılmıştır. Eğitim durdurma da maksimum iterasyon sayısı 1000 olarak belirlenmiştir. Ağlar yazılım [23] vasıtasıyla oluşturulmuştur. Bu değerler kullanıldığında elde edilen ağ performansları sırası ile Çizelge 1, 2 ve 3'te verilmiştir. Optimum parametrelerin belirlenmesinde hata değerini en az yapan veya deneysel nem değerine en yakın tahmine sahip olan model parametrelerinin seçilmesi amaçlanmıştır.

Ağların eğitiminde, Çizelge 1'de Levenberg-Marquardt, Çizelge 2'de Bayesian Regularization ve Çizelge 3'de Conjugate Gradient algoritmalarının kullanılmasında elde edilen başarı performans değerleri verilmiştir.

Çizelge 1. Levenberg-Marquardt algoritması ile eğitilen ağların özellikleri ve başarı performansları

Saklı katman sayısı	Nöron sayısı	Aktivasyon fonksiyonu	R	MSE (gr^2)	İterasyon
1	5	Lineer	0,99854	5,86E-05	16
1	5	Sigmoid	0,99868	6,17E-05	36
1	5	Hiperbolik	0,99956	6,57E-05	32
1	10	Lineer	0,9999	7,03E-05	12
1	10	Sigmoid	0,99997	2,36E-01	24
1	10	Hiperbolik	0,99821	8,08E-04	8
1	15	Lineer	0,99983	1,46E-04	20
1	15	Sigmoid	0,99741	4,17E-04	12
1	15	Hiperbolik	0,99878	1,56E-04	84
2	5	Lineer	0,99796	1,79E-04	16
2	5	Sigmoid	0,99741	6,98E-04	8
2	5	Hiperbolik	0,99979	1,60E-04	12
2	10	Lineer	0,99998	1,08E-04	12
2	10	Sigmoid	0,99971	1,57E-04	20
2	10	Hiperbolik	0,99177	8,92E-05	8
2	15	Lineer	0,99703	4,08E-04	8
2	15	Sigmoid	0,99949	1,94E-04	20
2	15	Hiperbolik	0,99704	6,68E-04	8
3	5	Lineer	0,99866	4,99E-05	8
3	5	Sigmoid	0,99987	4,47E-05	12
3	5	Hiperbolik	0,99661	1,33E-05	36
3	10	Lineer	0,99994	2,68E-04	12
3	10	Sigmoid	0,99873	3,44E-04	12
3	10	Hiperbolik	0,99851	8,83E-05	52
3	15	Lineer	0,99836	1,04E-04	16
3	15	Sigmoid	0,99952	2,24E-04	20
3	15	Hiperbolik	0,99956	3,47E-04	8

Çizelge 1 incelendiğinde tek katmanda, bütün aktivasyon fonksiyonları için 5 nöronlu ağın en az hataya sebebiyet verdiği görülmüştür. İki katmanda

bütün aktivasyon fonksiyonları için 10 nöronun en az hataya sebep olduğu görülmüştür. Üç katmanda ise bütün aktivasyon fonksiyonları için 5 nöronlu ağın en az hataya sebep olduğu görülmüştür.

Çizelge 2 incelendiğinde tek katmanda bütün aktivasyon fonksiyonları için 15 nöronlu ağın en az hataya sebep olduğu görülmüştür. İki katmanda bütün aktivasyon fonksiyonları için 15 nöronlu en az hataya sebep olduğu görülmüştür. Üç katmanda ise bütün aktivasyon fonksiyonları için 15 nöronlu ağın en az hataya sebep olduğu görülmüştür. Çizelge 2'den, Bayesian Regularization algoritmasının diğer eğitim algoritmalarına göre daha fazla iterasyon gerektirdiği görülmektedir. Ayrıca yer yer $R=1,0$ korelasyonuna ulaşmıştır. Ancak bu durum, aşırı öğrenme hatasının oluşmuş olabilmesi ihtimalini beraberinde getirmektedir. Yer yer iterasyon sayısının 1000 adet sınırına dayandığı görülmektedir. Yani, yakınsama elde edilemeden hesaplama kesilmiştir. Bu durumlar bu algoritmanın yakınsama hususunda kararlılık sağlamadığını göstermektedir. Üstelik iterasyon sayılarının fazlalığı da hesaplama hızının yavaş olmasına yol açmaktadır. Bu nedenlerle, Bayesian Regularization eğitim algoritmasının kullanılmasına karar verilmiştir.

Çizelge 2. Bayesian Regularization algoritması ile eğitilen ağların özellikleri ve başarı performansları

Saklı katman sayısı	Nöron sayısı	Aktivasyon fonksiyonu	R	MSE (gr^2)	İterasyon
1	5	Lineer	0,99891	2,3E-04	1000
1	5	Sigmoid	0,99999	4,5E-07	60
1	5	Hiperbolik	1	4,0E-07	65
1	10	Lineer	0,99429	1,3E-03	3
1	10	Sigmoid	1	3,0E-07	80
1	10	Hiperbolik	0,99999	3,0E-08	140
1	15	Lineer	0,99894	1,8E-04	1000
1	15	Sigmoid	1	3,6E-09	255
1	15	Hiperbolik	1	2,1E-08	175
2	5	Lineer	0,99429	1,3E-03	2
2	5	Sigmoid	0,99998	7,3E-09	112
2	5	Hiperbolik	0,99429	1,3E-03	2
2	10	Lineer	0,99429	1,4E-03	2
2	10	Sigmoid	0,99999	2,9E-09	122
2	10	Hiperbolik	0,99999	6,7E-09	100
2	15	Lineer	0,99888	2,7E-04	1000
2	15	Sigmoid	1	1,3E-09	114
2	15	Hiperbolik	0,99999	2,6E-13	333
3	5	Lineer	0,99429	1,3E-03	1
3	5	Sigmoid	1	4,4E-09	125
3	5	Hiperbolik	0,99429	1,2E-03	3
3	10	Lineer	0,99429	1,4E-03	2
3	10	Sigmoid	1	1,1E-09	133
3	10	Hiperbolik	0,99429	1,3E-03	2
3	15	Lineer	0,99429	1,2E-03	2
3	15	Sigmoid	1	5,2E-10	180
3	15	Hiperbolik	0,99429	1,3E-03	3

Çizelge 3'te, Conjugate Gradient algoritmasının kullanılması halinde elde edilen değerler verilmiş olup parametrelerin, aktivasyon fonksiyonu, nöron sayısı ve saklı katman sayısına göre değişimi rastgeledir. Yer yer sıfır iterasyon veya 1'e ulaşan korelasyon görülmektedir. Üstelik, parametreler arasında da tutarlı bir ilişki elde edilememiştir. Bu nedenlerle, Conjugate Gradient eğitim algoritmasının kullanılmamasına karar verilmiştir.

Çizelge 3. Conjugate Gradient algoritması ile eğitilen ağların özellikleri ve başarı performansları

Saklı katman sayısı	Nöron sayısı	Aktivasyon fonksiyonu	R	MSE (gr ²)	İterasyon
1	5	Lineer	0,9984	1,0E-04	2
1	5	Sigmoid	0,9995	8,8E-05	21
1	5	Hiperbolik	0,9993	3,5E-05	13
1	10	Lineer	0,9999	2,0E-04	6
1	10	Sigmoid	0,9994	5,8E-04	13
1	10	Hiperbolik	0,9999	5,7E-05	17
1	15	Lineer	1,0000	8,7E-05	3
1	15	Sigmoid	0,9996	2,7E-04	3
1	15	Hiperbolik	0,9987	2,9E-04	14
2	5	Lineer	0,9992	2,9E-04	2
2	5	Sigmoid	0,9999	2,3E-05	5
2	5	Hiperbolik	0,9993	2,6E-05	11
2	10	Lineer	0,9977	3,6E-04	5
2	10	Sigmoid	0,9983	9,8E-05	4
2	10	Hiperbolik	0,9972	4,5E-04	32
2	15	Lineer	0,9999	1,2E-04	10
2	15	Sigmoid	0,9970	4,0E-05	7
2	15	Hiperbolik	0,9979	5,8E-05	45
3	5	Lineer	0,9999	3,6E-05	11
3	5	Sigmoid	0,9899	1,8E-03	0
3	5	Hiperbolik	0,9990	5,0E-05	20
3	10	Lineer	0,9995	4,2E-04	7
3	10	Sigmoid	0,9995	1,6E-04	12
3	10	Hiperbolik	0,9993	1,5E-03	5
3	15	Lineer	0,9999	1,4E-04	15
3	15	Sigmoid	0,9984	4,5E-04	5
3	15	Hiperbolik	0,99188	8,6E-04	0

Netice itibarıyla; eğitim algoritması olarak Levenberg-Marquardt algoritmasının diğer iki algoritmaya göre daha tercih edilebilir olduğu görülmüştür. Ağın, her katmanında 5'er adet nöron bulunan, 3 adet saklı katmanlı ve tanjant hiperbolik aktivasyon fonksiyonlu özellikle olmasına karar verilmiştir. Seçilen ÇKA ağı ve eğitimine dair parametreler Çizelge 4'te verilmiştir.


Çizelge 4. Seçilen ÇKA ağının özellikleri

Parametre	Değer
Öğrenme işleminde hata ölçütü	MSE=0,008 gr ²
Maksimum iterasyon sayısı	1000
Saklı katman sayısı	3
Saklı katmandaki nöronların sayısı	5

Saklı katman(lar)daki aktivasyon fonksiyonu	Tanjant hiperbolik
Eğitim algoritması	Levenberg-Marquardt
Bağlı olduğu önceki veri sayısı, <i>d</i>	10 (nem)
Giriş düğümleri	10
Çıkış düğümleri	1 (nem)
Çıkış eşliği	0,99
Öğrenme hızı, η	0,1
Momentum, α	0,1
Öğrenme eşliği	0,0001
Veri kümesi bölümlenmesi	Eğitim 2882 adet, test 720 adet

2.3. LSTM ile Modelleme

Bir LSTM ağ katmanı şematik olarak Şekil 2'de verilmiş olup $\{x\}$ girdi değişkeni kümesi, $\{h\}$ çıktı değişkeni kümesi ve $\{c\}$ hücre durumunu içeren değişkenlerdir.



Şekil 2. Bir LSTM ağ katmanı

h_t , Eşitlik 4 kullanılarak hesaplanmaktadır.

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

\odot sembolü Hadamard çarpımını [24] temsil etmektedir. o_t çıkış kapısı olup h_t için hücre durumunu ayarlamaktadır. c_t Eşitlik 5 kullanılarak hesaplanmaktadır.

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

Burada i_t giriş kapısı sayesinde hücre durumunun güncelleme seviyesi belirlenmektedir. f_t unutma kapısı olup hücre durumunun sıfırlama seviyesi kontrol edilebilmektedir. g_t hücre adayı olup hücre durumuna bilgi sağlar. Bu değişkenler Eşitlik 6'da verilen bağıntılar ile hesaplanmaktadır.

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

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

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

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

Burada $f(t)$ ile verilen fonksiyon sigmoid aktivasyon fonksiyonudur. W ve R sırasıyla girdi ve tekrarlayan birimin ağırlıklardır. b ise bias'tır.

Tıpkı ÇKA ağında olduğu gibi LSTM ağında da toplam veri kümesinin ilk %80'i eğitim verisi olarak kullanılmış ve geriye kalan %20'lik kısım ise test amaçlı kullanılmıştır. LSTM ağırları yazılımsal kodlar [25] ile oluşturulmuştur.

2.4. Regresyon ile Modelleme





Nem bağımlı, *zaman* ise bağımsız değişkenlerdir. Regresyon için pek çok türde fonksiyon mevcut olup yazarların önceki çalışmasında kullandıkları fonksiyonların [26] burada da uygun olup-olmadığının tespiti amacıyla bir ön inceleme yapılmıştır. Ön incelemede kullanılan fonksiyonların verdiği eğriler Şekil 3'te ve bu fonksiyonların parametreleri, korelasyon ve hata değerleri Çizelge 5 ve 6'da verilmiştir. Regresyonların performanslarının görülebilmesi için ön incelemede bütün deneysel veriler kullanılmıştır. Şekil 3'teki grafikler, verilerin elde edildiği sıraya göre çizdirilmiştir. Şekil 3-b'den görüleceği üzere deneysel veriye en uygun olabilecek fonksiyon türü çok terimli eksponansiyel fonksiyondur. Regresyonlar için güven düzeyi %95 olarak ayarlanmıştır. Maksimum iterasyon limiti 400 olarak belirlenmiş olmasına rağmen tüm modellerin en fazla 11 iterasyonda yakınsadığı görülmüştür. Parametrelerin başlangıç değerleri olarak sıfır kullanılmıştır.

Regresyonda kullanılacak olan eksponansiyel fonksiyonun genel ifadesi Eşitlik 7'de verilmiştir.

$$f(t) = \sum_{i=0}^1 C_i e^{(A_i * t)} \quad (7)$$

Burada, C_i katsayıları ve A_i üsleri fonksiyon parametreleri olup regresyon ile tespit edilmiştir. t zamandır. $f(t)$ zamana bağlı değişen nem fonksiyonudur. Aşırı öğrenmeye engel olmak için de K kez çapraz doğrulama ($K=5$) uygulanmıştır

[17,27]. Regresyonlar yazılım ile gerçekleştirilmiştir [28].



Şekil 3. Deneysel veri ve farklı regresyon fonksiyonların kıyaslandığı ön analiz; (a) polinom, (b) eksponansiyel, (c) üstel, (d) trigonometrik

Çizelge 5. Regresyon fonksiyonlarının katsayıları

Denklem	a	b	c	d
$a+bt$	15,45	-2,47E-04		
$a+bt+ct^2$	15,64	-5,54E-04	8,54E-08	
$a+bt+ct^2+dt^3$	15,81	-1,15E-03	4,98E-07	-7,63E-11
$a+bt+ct^2+dt^3+et^4$	15,98	-2,05E-03	1,62E-06	-5,63E-10
$a+bt+ct^2+dt^3+et^4+ft^5$	16,10	-2,98E-03	3,41E-06	-1,89E-09
$a*e^{(b*t)}$	15,46	-1,65E-05		
$a*e^{(b*t)}+c*e^{(d*t)}$	15,25	-1,10E-05	0,912	-4,52E-03
$a*b^t$	17,11	-1,83E-02		
$a*b^t+c$	0,94	1,31E-01	17,4	
$a*\sin(b*t+c)$	42,2	6,21E-06	2,77	
$a*\sin(b*t+c)+d*\sin(e*t+f)$	86,2	5,07E-04	0,811	71,3

Çizelge 6. Regresyon fonksiyonlarının katsayıları (devam)

Denklem	e	f	R ²	RMSE (gr)
$a+bt$			0,805	0,126
$a+bt+ct^2$			0,889	0,095
$a+bt+ct^2+dt^3$			0,944	0,068
$a+bt+ct^2+dt^3+et^4$	6,75E-14		0,998	0,014
$a+bt+ct^2+dt^3+et^4+ft^5$	4,82E-13		1,000	0,006
$a*e^{(b*t)}$			0,809	0,125
$a*e^{(b*t)}+c*e^{(d*t)}$			0,992	0,026
$a*b^t$			0,9515	0,0629
$a*b^t+c$			0,969	0,050
$a*\sin(b*t+c)$			0,8044	0,1263
$a*\sin(b*t+c)+d*\sin(e*t+f)$	5,60E-04	3,8	0,4786	0,2062

İlave olarak YSA esaslı regresyon da uygulanmıştır. Tür olarak parametrik olmayan ve Bayesian bir yaklaşım olan Gauss regresyonu (GPR) yöntemi kullanılmıştır [29]. GPR yöntemi $i = 1, 2, \dots, n$ olmak üzere $f(x_i)$ şeklinde saklı değişkenler kullanılmaktadır. İşlem, Gauss esaslı gerçekleştirildiğinden dolayı da bir regresyon fonksiyonu yerine her bir veri için ayrı ayrı Eşitlik 8’de genel formda tanımlanmaktadır [30].

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

Burada $m(x_i)$ ortalama fonksiyon, $k(x_i, x_j)$ ’ler ise kovaryans çekirdek fonksiyonu olarak adlandırılmaktadır. x_i, x_j ’ler ($i \neq j = 1, 2, \dots, n$) eğitim veri kümesindeki veridir. x_i giriş olup y_i ise cevaptır. N kümedeki toplam veri sayısıdır. Bu çalışmada ortalama fonksiyon sıfır alınmıştır. Kovaryans çekirdek fonksiyonunun pek çok çeşidi mevcut olup bu çalışmada Eşitlik 9 ile verilen karesel eksponansiyel türünde bir kovaryans çekirdek fonksiyonu kullanılmıştır.

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

Burada r değeri x_i ve x_j arasındaki Öklid mesafesi olup $r = \sqrt{(x_i - x_j)^T(x_i - x_j)}$ eşitliği ile hesaplanmaktadır. Bu kovaryans çekirdek fonksiyonunun hiperparametre olarak adlandırılan iki adet parametresi olup bunlar σ_l uzunluk ölçeği ve σ_f sinyalin standart sapmasıdır [31]. GPR modellerinin parametrik olmadığı düşünülse de σ_l , σ_f gibi hiperparametreler bu yöntemin tahmin yeteneklerini önemli ölçüde etkilemektedir. Kovaryans çekirdek fonksiyonu kısıtsız parametre olarak adlandırılan bir dizi θ ile parametreleştirilmektedir. Hiperparametreler ile olan ilişkisi ise $\sigma_l = e^{\theta_l}$ ve $\sigma_f = e^{\theta_f}$ olarak verilmektedir. Genellikle kovaryans çekirdek fonksiyonunun θ ’ya bağımlılığını açıkça belirtmek için $k(x_i, x_j | \theta)$ şeklinde ifade etmek de mümkündür.

Tıpkı ÇKA ve LSTM’de olduğu gibi regresyon metodunda da modellerin aralık dışındaki tahmin performansını elde edebilmek amacıyla verinin ilk %80’i regresyon ile eğri uydurmada kullanılmışken geri kalanı ise uydurulan eğrinin tahmin performansını belirlemeye ayrılmıştır.


2.5. Nem Tayini Deneyleri

Bu çalışmada numune olarak yeni nesil N25P5K5 bitki besini kullanılmış olup malzemenin nominal içeriği Çizelge 7’de verilmiştir.

Çizelge 7. N25P5K5 malzemesinin içeriği

İçerik	Ağırlık (%)
Azot (NO ₃)	14,5
Azot (NH ₄ NO ₃)	10,5
Fostat (P ₂ O ₅)	5
Potasyum oksit (K ₂ O)	5
Demir üç oksit (Fe ₂ O ₃)	3,02
Alüminyum üç oksit (Al ₂ O ₃)	1,64
Mangan oksit (MnO)	0,05
Magnezyum oksit (MgO)	0,25
Kalsiyum oksit (CaO)	6,18
Sodyum oksit (Na ₂ O)	1,84
Hidrat (H ₂ O ⁻)	0,7
Nem (H ₂ O ⁺)	33,32
Kükürt trioksit (SO ₃)	8
Organik madde	10

Kurutma deneylerinin yapıldığı ve nem verisinin toplandığı ünite, Şekil 4'te verilmiştir.



Şekil 4. Kurutma deneylerinin yapıldığı ve nem verisinin toplandığı ünite

Sıcaklığı değiştirilerek ayarlanabilen bir ETÜV' de, veri toplama cihazı ile terazideki numunenin üç saniyede bir kütle ölçümü yapılmıştır. Başlangıç kütlesi ile son kütle arasındaki fark uçurulan nem miktarını vermektedir. Deneyler 70°C, 75°C, 80°C sıcaklıklarda uygulanmıştır. Nem ölçümü üç saat boyunca gerçekleştirilmiştir. Her bir deneyde toplam 3602 adet veri toplanmıştır. Grafikler çizileceği zaman veri âdetine göre değil geçen zamana göre çizildiği için zaman eksenini 10806 saniyeye kadar ilerlemektedir.

Her bir deney üç kez tekrar edilmiştir. Tekrarlar arasındaki standart sapma, e_s değeri, başlangıç ve son kütle için Çizelge 8'de verilmiştir.

Çizelge 8. Deney tekrarlarına ilişkin değerler

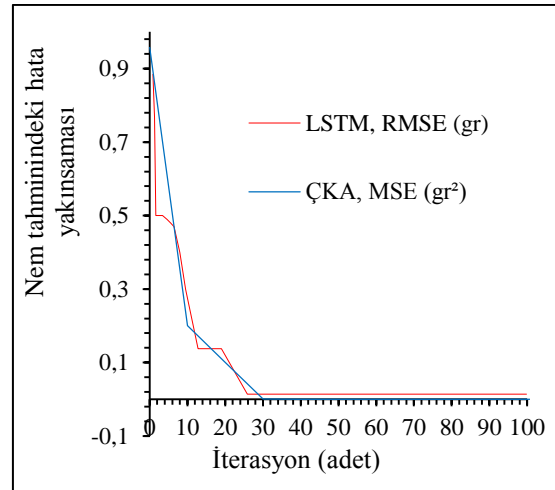
Sıcaklık (°C)	Ortalama nemli kütle (gr)	Ortalama kuru kütle (gr)	e_s (gr)
80	15,81	14,26	0,0156
75	16,58	15,53	0,0195
70	13,66	12,54	0,0134

3. ARAŞTIRMA BULGULARI

3.1. Doğrulamalar

Eğitilen ÇKA ve LSTM ağırları test verileri ile doğrulanmış olsa bile ilaveten eğitim süresince hataların değişimi izlenerek Şekil 5'te

gösterilmiştir. Bu şekilde de anlaşılacağı üzere; hata değeri 36 iterasyondan sonra daha da düşmemekte ve kararlılığını korumaktadır. Sonuç olarak, optimum iterasyon sayısı sayesinde aşırı öğrenme hatasının önüne geçilmesinin yanında gereksiz hesaplama maliyeti ve süresinden de kaçınılmıştır.



Şekil 5. Ağların eğitimi esnasında hatanın değişimi

Bu doğrulamalara ilave olarak Çizelge 9'da ÇKA ağırlarının hem eğitim hem de test esnasındaki performans göstergeleri verilmiştir. ÇKA ağırlarının en fazla 0,201 mg hata ile tahminde bulunduğu görülmüştür. Ayrıca, eğitim esnasında yaptığı tahminin, test esnasında yaptığı tahminden daha başarılı olduğu görülmektedir.

Çizelge 9. ÇKA'nın tahmin ve eğitim performansı

Sıcaklık (°C)	Tahmin		Eğitim	
	RMSE (gr)	R	RMSE (gr)	R
80	0,000195	0,919	0,000187	0,992
75	0,000206	0,491	0,000201	0,997
70	0,000208	0,411	0,000186	0,996

Çizelge 10'da LSTM'nin test esnasındaki performans göstergeleri verilmiştir. LSTM'nin kullanılması ile hatanın 14 mg olabildiği görülmüştür.

Çizelge 10. LSTM ağının tahmin performans göstergeleri

Sıcaklık (°C)	RMSE (gr)	MAE (gr)	MAPE (%)	R
80	0,027	0,023	0,153	0,926
75	0,014	0,011	0,071	0,509
70	0,014	0,011	0,085	0,444

Çizelge 11’de; YSA ile yapılan regresyondan elde edilen hiperparametreler ve RMSE değeri görülmektedir. En az 13 mg hata ile tahmin elde edilmiştir. Bütün yöntemler arasında en iyi korelasyonun elde edildiği metot budur. Zira korelasyon katsayısı 1,0’a ulaşabilmiştir.

Çizelge 11. YSA ile yapılan regresyona ait hiperparametreler ve eğitim verisi üzerindeki performans göstergesi

Sıcaklık (°C)	σ_l	σ_f	R^2	RMSE (gr)
80	0,51791	0,01786	1,00	0,015932
75	0,849	0,0382	1,00	0,013400
70	1,583	0,00931	0,99	0,013035

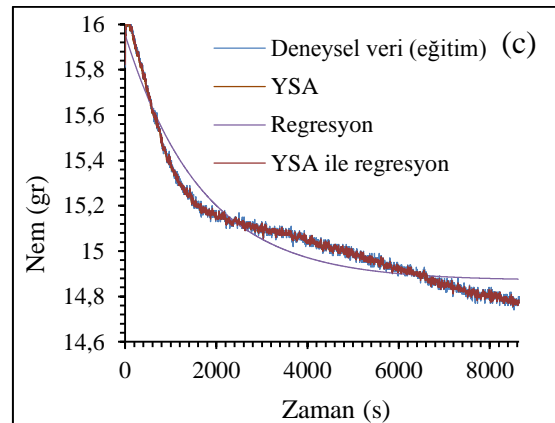
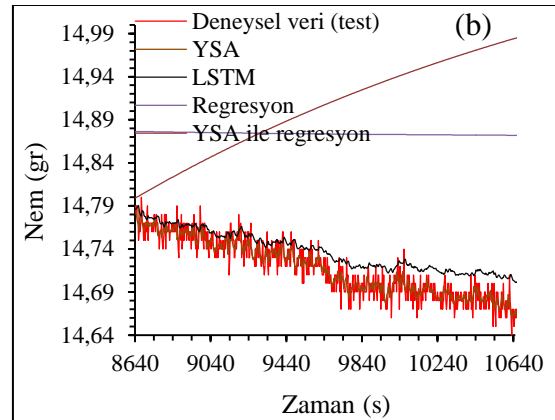
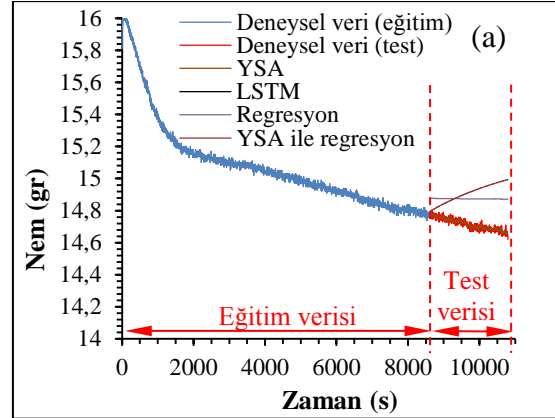
Çizelge 12. Ekspansiyel regresyona ait parametreler ve eğitim verisi üzerindeki performans göstergesi

Sıcaklık (°C)	C_0	C_1	A_1	R^2	RMSE (gr)
80	14,87	1,08400	-0,0005928	0,945	0,064
75	15,79	0,92656	-0,0009295	0,987	0,022
70	12,99	0,79000	-0,0035880	0,973	0,026

Çizelge 12’de ise ekspansiyel regresyondan elde edilen fonksiyon parametreleri ve hata değerleri görülmektedir. Bütün sıcaklıklar için $A_0 = 0$ olmuştur. En az 22 mg hata ile tahmin elde edilmiştir.

3.2. Tahmin Verileri

Deneylerden elde edilen nem değerleri, bu veri üzerinden alınan eğitim, test bölümleri ve modellerin tahmin performanslarını gösteren eğriler Şekil 6-8’de verilmiştir. Şekillerdeki alt şekiller vasıtası ile modellerin performansları gösterilmiştir. LSTM yönteminin performansı sadece test verisi üzerinden elde edilebilmiş olduğundan dolayı eğitim verisi üzerindeki tahmin değerleri verilememiştir.

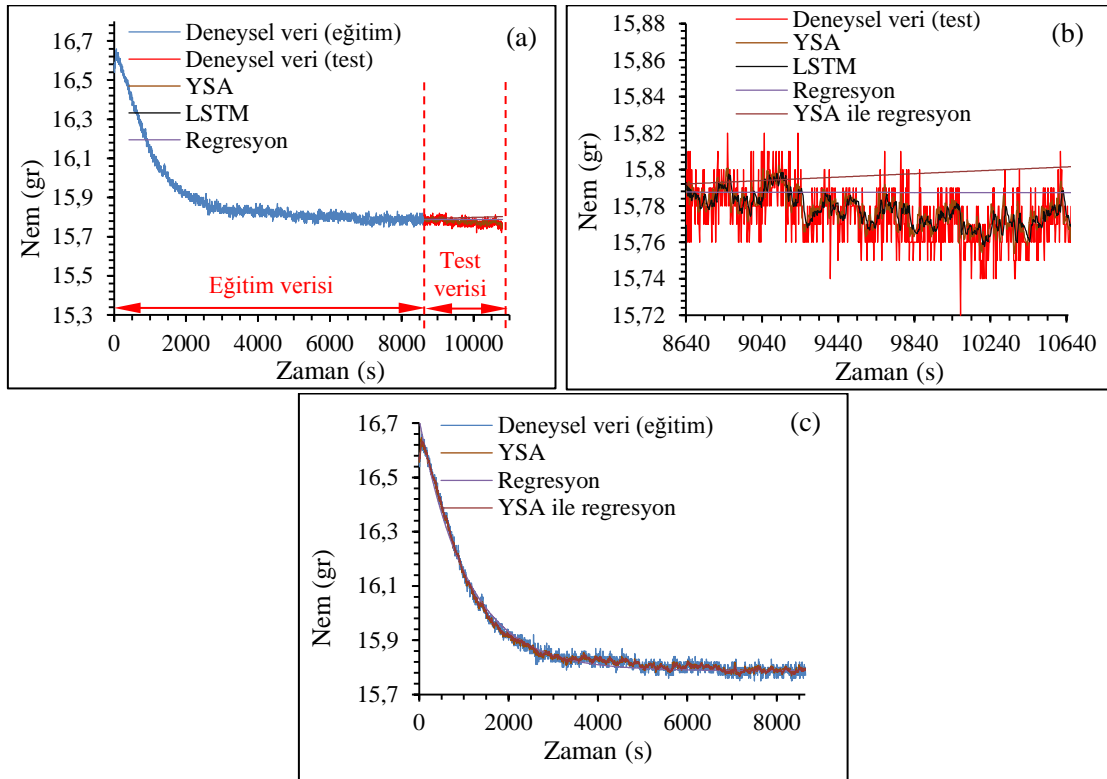


Şekil 6. 80°C’de kurutulan numune için oluşturulan modellerin (a) veri kümesinin bölümlenmesi, (b) test verisini tahmin performansları, (c) eğitim verisini temsil edebilme performansları

80 °C’de kurutulan numune için deneysel ve modellerden elde edilen eğriler Şekil 6’da gösterilmiştir. Eğitim verisi üzerinde eksponansiyel regresyon hariç tüm modellerin eğrilerinin deneysel veri ile uyumlu olduğu görülmüştür. Test verisinin tahmininde; ÇKA ve LSTM açısından elde edilen eğrilerin, deneysel veriye iyi uyduğu, eksponansiyel ve YSA regresyonlarından elde edilen eğrilerin ise en kötü uyuma sahip olduğu görülmüştür.

75 °C’de kurutulan numune için deneysel ve modellerden elde edilen eğriler Şekil 7’de


gösterilmiştir. Eğitim verisi için tüm modellerin eğrilerinin deneysel veri ile uyumlu olduğu görülmüştür. Bütün modellerin test verisi üzerindeki performanslarının ise deneysel veriyi tahmin etmede iyi olduğu, ÇKA ve LSTM açısından elde edilen eğrilerin en iyi uyuma sahip olduğu görülmüştür. Regresyonların uyumlu olmasının nedeninin, kurutma eğrisinin sabit bir davranışta olduğu düz bir hale gelmiş olmasından kaynaklandığı düşünülmektedir. Zira regresyonlar hâlâ düz davranışlarını muhafaza etmektedirler.



Şekil 7. 75 °C’de kurutulan numune için oluşturulan modellerin (a) veri kümesinin bölümlenmesi, (b) test verisini tahmin performansları, (c) eğitim verisini temsil edebilme performansları

70 °C’de kurutulan numune için deneysel ve modellerden elde edilen eğriler Şekil 8’de gösterilmiştir. Eğitim verisi üzerinde tüm model eğrilerinin deneysel veri ile uyumlu olduğu görülmüştür. Bütün modellerin test verisi üzerindeki performanslarının, deneysel veriyi tahmin etmede iyi olduğu, ÇKA ve LSTM açısından

elde edilen eğrilerin ise en iyi eğriyi verdiği görülmüştür. Regresyonların uyumlu olmasının nedeninin kurutma eğrisinin sabit bir davranışta olması, düz bir hale gelmiş olmasından kaynaklandığı düşünülmektedir. Zira regresyonlar hâlâ düz davranışlarını muhafaza etmektedirler.



Şekil 8. 70 °C’de kurutulan numune için oluşturulan modellerin (a) veri kümesinin bölümlenmesi, (b) test verisini tahmin performansları, (c) eğitim verisini temsil edebilme performansları

3.3. Tartışma

ÇKA, LSTM, regresyon modellerinin tamamının eğitim verisini tahmin etmede başarılı olduğu görülmüştür. Exponansiyel regresyon eğrilerinde ise diğerlerine göre büyük sapmalar görülmüştür. YSA esaslı regresyon modelinin, eğitim verisini tahmin etmede yüksek performans gösterirken, test verisi üzerindeki performansı daha düşük olmuştur. ÇKA ve LSTM ağlarının eğitim ve test verilerindeki tahmin başarısının diğerlerine göre en iyi olduğu, ÇKA ağının tahmin başarısının da LSTM’den daha iyi olduğu, test verileri üzerinde ortaya çıkmıştır.

Literatürde kurutma modelleme çalışmalarının genellikle regresyon kullanılarak yapılmış olduğu görülmüştür. Bunun nedeni makine öğrenme metodlarının kurutma alanında yeni yeni kullanılmaya başlanmasıdır. Regresyonlarda korelasyon katsayısının 0,981 olarak elde edildiği belirtilmiştir [32]. Çalışmamızda test verisi üzerine uyguladığımız regresyonlarda 0,444-1,0 arasında korelasyon katsayısı elde edilirken eğitim verisi üzerine uyguladığımız regresyonlarda ise 0,992-1,000 arasında korelasyon katsayısı elde edilmiştir. Elbette ki regresyonların veri ötesindeki tahmin performanslarının düşük olması şaşırtıcı olmayan bir durumdur. YSA regresyonunun uygulanması ile 0,99-1,00 aralığında korelasyon tespit edilmiştir. Bu durum, ÇKA ağının tahmin performansının diğer regresyon türlerinden daha üstün olduğu sonucunu ortaya koymaktadır. Böylece doğasında ileriye yönelik tahmin amacı barındırmayan regresyon işlemleri YSA sayesinde daha isabetli tahminlerde bulunabilir hale gelebilmektedir. ÇKA modelleri kullanılarak 0,255 gr. tahmin başarısı elde edilebildiği raporlanmıştır [6]. Yazarlar önceki çalışmalarında kurutma sıcaklığının da, modellerin tahmin performansı üzerinde etkili olduğunu bildirmişlerdir [26]. Ancak mevcut çalışmada incelenen ürünün türünün, kurutma sürelerinin ve ağ parametrelerinin (bias, gecikme vb...) farklı olması nedeni ile kıyaslanabilir bir ilişki tespit edilememiştir. Mevcut çalışmada kullanılan ÇKA ağı sayesinde 0,000201 gr’lık tahmin hatasına ulaşılabilmektedir. Bu değer ÇKA ağının tahmin

gücünün diğer yöntemlere göre en iyi olduğunu ortaya koymaktadır.

4. SONUÇLAR

Tarım endüstrisinde önemli yere sahip olan N25P5K5 bitki besininin kuruma davranışının tahmin edilmesinde makine öğrenme, YSA ve regresyon modellerinin tahmin performansları araştırılmıştır. Aşağıdaki temel çıkarımlar elde edilmiştir.

- Regresyonlar; sadece mevcut veriyi modellemede kullanışlı iken, ileriye yönelik tahminler için kullanışlı değildir. YSA destekli regresyonlar diğer regresyonlardan daha üstün tahmin yeteneklerine sahiptirler.
- Her katmanında 5'er adet nöron bulunan, 3 adet saklı katmanlı ve tanjant hiperbolik aktivasyon fonksiyonlu ÇKA ağı yüksek performans göstermektedir. Eğitimde kullanılan Levenberg-Marquardt algoritması da hız ve kararlılık sağlamaktadır.
- ÇKA ve LSTM ağları ile mevcut verinin modellenmesi ve ileriye yönelik tahminlerde regresyon denklemlerinden daha başarılı olmuşlardır.
- ÇKA ve LSTM yöntemleri ile 0,99-1,00 arasında korelasyon elde edilmiş, 0,201 mg'lık RMSE değeri ise YSA ile elde edilmiştir. ÇKA ve LSTM kendi içerisinde kıyaslandığında, bitki besini kurutma tahminleri için, ÇKA ağının performansının daha yüksek olduğu görülmüştür. LSTM ağları, veri sayısı fazla olduğunda daha verimli hale gelmektedir.

5. TEŞEKKÜR

Deneysel çalışma için sağladığı altyapı desteklerinden dolayı Çukurova Üniversitesi Ziraat Fakültesi Tarım Makineleri ve Teknolojileri Mühendisliği Bölümü ve Atölyesi çalışanlarına teşekkür ederiz. Çalışmada kullanılan malzemelerin teminini sağlayan Agrotime Gübre

firmasına desteklerinden dolayı teşekkürlerimizi sunarız. Bilgi desteği ve sabrından dolayı Prof. Dr. Mehmet BİLGİLİ' ye teşekkür ederiz. Hassas teraziden veri toplanması yazılımını kodlayan Arş. Gör. Mustafa ŞEHİRİ'ye teşekkür ederiz. Bu çalışmanın incelenmesi esnasında, zaman ayırıp önerilerde bulunarak desteklerini esirgemeyenlere teşekkür ederiz.

6. KAYNAKLAR

1. Mansuroğlu, N.P., Yazıcı, E., Önder, S., Karaça, A.C., 2020. Maltodekstrin-Nohut Proteini İzolati Matrisinde Karabiber Tohumu Yağının Püskürtmeli Kurutma Metodu ile Enkapsülasyonu. Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 9(2), 877-882.
2. 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.
3. 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.
4. Das, M., Alic, E., Akpınar, E.K., 2021. Detailed Analysis of Mass Transfer in Solar Food Dryer with Different Methods. International Communications in Heat and Mass Transfer, 128, 105600.
5. Onu, C.E., Igbokwe, P.K., Nwabanne, J.T., Ohale, P.E., 2022. Anfis, Ann, and Rsm Modeling of Moisture Content Reduction of Cocoyam Slices. Journal of Food Processing and Preservation, 46(1), e16032.
6. 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. McCulloch, W.S., Pitts, W., 1943. A Logical Calculus of the Ideas Immanent in Nervous

- Activity. The Bulletin of Mathematical Biophysics, 5, 115–133.
8. Altan, A.D., Diken, B., Kayışođlu, B., 2021. Prediction of Photovoltaic Panel Power Outputs Using Time Series and Artificial Neural Network Methods. Journal of Tekirdag Agricultural Faculty, 18(3), 457-469.
 9. Hamzaçebi, C., Kutay, F., 2004. Electric Consumption Forecasting of Turkey Using Artificial Neural Networks up to Year 2010. Journal of the Faculty of Engineering and Architecture of Gazi University, 19(3), 227-233.
 10. Şenkal, O., 2016. Yapay Sinir Ağları ile Atmosferik Parametreler Kullanılarak Türkiye için Güneş Radyasyonu Modellemesi. Çukurova Üniversitesi, Mühendislik-Mimarlık Fakültesi Dergisi, 31(2), 179-186.
 11. Aydın, E.A., 2014. Meme Kanseri Tespitinde Mikrodalgaların Önemi ve Kanserli/Sađlıklı Meme Dokularının Yapay Zeka Algoritmaları ile Tanımlanabilmesi. Çukurova Üniversitesi, Mühendislik-Mimarlık Fakültesi Dergisi, 29(2), 27-38.
 12. Kaveh, M., Sharabiani, V.R., Chayjan, R.A., Taghinezhad, E., Abbaspour-Gilandeh, Y., Golpour, I., 2018. Anfis and Anns Model for Prediction of Moisture Diffusivity and Specific Energy Consumption Potato, Garlic and Cantaloupe Drying under Convective Hot Air Dryer. Information Processing in Agriculture, 18(1), 45.
 13. Omari, A., Behrooz-Khazaei, N., Sharifian, F., 2018. Drying Kinetic and Artificial Neural Network Modeling of Mushroom Drying Process in Microwave-Hot Air Dryer. Journal of Food Process Engineering, e12849.
 14. 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.
 15. Beigi, M., Torki, M., 2021. Experimental and Ann Modeling Study on Microwave Dried Onion Slices. Heat and Mass Transfer, 57, 787–796.
 16. Öğündür, G., 2019. Overfitting, Underfitting and Bias-Variance Contradiction. <https://medium.com>, Yayın tarihi: 2019. Erişim tarihi: 12.12.2020.
 17. 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.
 18. Çavuşlu, M.A., Becerikli, Y., Karakuzu, C., 2012. Hardware Implementation of Neural Network Training with Levenberg-Marquardt Algorithm. TBV Journal of Computer Science and Engineering, 5(1), 1-7.
 19. 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(11), 718.
 20. 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, 943–959.
 21. Zhou, H., Huang, M., Zhu, Q., Zhang, M., 2021. Developing C-Lstm Model for Evaluating Moisture Content of Carrot Slices During Drying. Drying Technology, 40(14), 1-11.
 22. 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.
 23. Eaton, J.W., 2022. Gnu Octave. <https://octave.org/about>, Yayın tarihi: 2022. Erişim tarihi: 12.12.2021.
 24. Million, E., 2007. The Hadamard Product, in Linear Algebra. Editör: Beezer R.A., buzzard.ups.edu, Rob Beezer's Home Page, 1-7.
 25. Heris, M.K., 2015. Time-Series Prediction Using Anfis in MATLAB. The Yarpiz Project, Fuzzy Systems.
 26. Kacar, İ., Korkmaz, C., 2022. Prediction of Agricultural Drying Using Multi-Layer Perceptron Network, Long Short-Term Memory Network and Regression Methods.

- Gümüşhane University Journal of Science and Technology, 12(4), 1188-1206.
27. Brownlee, J., 2018. A Gentle Introduction to K-Fold Cross-Validation. <https://machinelearningmastery.com/k-fold-cross-validation/>, Yayın tarihi: 2018. Erişim tarihi: May 23, 2018
 28. Origin, 2019. Originpro 2019b (64-Bit), Copyright © 1991-2019 OriginLab Corporation, OriginLab Corporation, Northampton, MA, USA.
 29. MathWorks, 2022. Statistics and Machine Learning Toolbox. https://www.mathworks.com/help/stats/index.html?s_tid=CRUX_lftnav, Yayın tarihi: 2022. Erişim tarihi: May 23, 2018
 30. MathWorks, 2022. Kernel (Covariance) Function Options. <https://www.mathworks.com/help/stats/kernel-covariance-function-options.html>, Yayın tarihi: 2022. Erişim tarihi: May 23, 2018
 31. Sit, H., 2019. Quick Start to Gaussian Process Regression. <https://towardsdatascience.com/quick-start-to-gaussian-process-regression-36d838810319>, Yayın tarihi: 2019. Erişim tarihi: April 18, 2019.
 32. 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 İncelenmesi. Journal of Tekirdag Agricultural Faculty, 17(1), 53-65.

