

ARAŞTIRMA MAKALESİ

RESEARCH ARTICLE

GRU Ağı ve DEM Esaslı Fıstık Sınıflandırma Simülasyonu Kullanarak Zaman Serisi Tahmini

Time Series Prediction Using GRU Network and DEM Based Peanut Grading Simulation

Cem KORKMAZ^{1*}, İlyas KACAR²

Öz

Makale, yer fıstığı işletmelerindeki işleme verimliliğini ve eleme kalitesini optimize etmede, Ayrık Eleman Yöntemi (DEM) esaslı simülasyonlar ve derin öğrenme algoritmalarının kullanıldığı bir otomasyon sistemini araştırmaktadır. Bu amaç ile hasat sonrası bir işlem olan yer fıstığı vb. tahıl ürünlerinin sınıflandırılması için geliştirilip üretilen silindirik elekli yer fıstığı sınıflama makinesi işlemi, DEM esaslı Ansys RockyDEM© programı ile simüle edilmiştir. Sınıflandırma makinesinde kullanılan silindirik eleğin, geleneksel yöntemlere göre, sınıflandırma verimi yüksek ve enerji maliyetleri düşüktür. Simülasyonların gerçekleştirilebilmesi için bu eleğin bir katı modeli oluşturulmuştur. DEM temelli programlarda her bir fıstık tanesinin hareketi ayrı ayrı hesaplanmaktadır. Bu tür programların işletmelerde kullanılması, optimizasyon ve ürün kalitesi açısından önemli avantajlar getirmesine rağmen granül yapıda yüksek sayıda parçacıklar ciddi hesaplama maliyetleri ve güçlükleri oluşturmaktadır. Bu durum DEM tabanlı simülasyon programlarının en önemli dezavantajıdır. Bu çalışmada kullanılan sınıflama makinesi pilot ölçekte olmasına rağmen simülasyon işlemi 63 gün 18 saat 27 dakika sürmüştür. Endüstriyel ölçekte büyük sınıflama makineleri için bu sürecin çok daha fazla olacağı açıktır. Bu durum yüksek maliyetli hesaplama gerektirecektir. Bu çalışmada yapılan simülasyon sonucundan sürtünme verile elde edilmiştir. Bu tür makinelerde sınıflandırma verimliliği açısından önemli bir parametre, partiküller arası ve partikül-yüzey arası etkileşimin belirlenmesidir. Bu nedenle simülasyondan elde edilen partikül-yüzey sürtünme verilerinin modellenmesi amacıyla derin öğrenme ağlarının bir türü olan Geçitli Tekrarlayan Birim (GRU) türündeki tekrarlı ağlar kullanılmıştır. Modelleme ve tahmin performansı araştırılmıştır. Elde edilen fıstık sınıflandırma modelinde korelasyon değeri 0.88731 ve hata karesinin ortalamasının kökü 322.179 N olarak bulunmuştur. Ortalama mutlak hatanın yüzdesi ise %0.61988 olarak bulunmuştur. 100 adet iterasyon yapılmış ve hesaplamalar 6.42 s sürmüştür. Simülasyon programında bu verilerin elde edilmesinde yüksek işlem süreleri ve hesaplama güçlükleri düşünüldüğünde, bu derin öğrenme ağları, bu tip ürünlerin simülasyonunda bu zorlukların aşılmasında sınıflandırma makinelerinin üretim parametrelerinin optimize edilmesi yönünden ümit vermektedir.

Anahtar Kelimeler: DEM, Ansys RockyDEM©, Silindirik sınıflama makinesi, Derin öğrenme, GRU, LSTM

^{1*}**Sorumlu Yazar/Corresponding Author:** Cem Korkmaz, Çukurova Üniversitesi, Ziraat Fakültesi, Tarım Makineleri ve Teknolojileri Mühendisliği Bölümü, Adana, Türkiye. E-mail: ckorkmaz@cu.edu.tr  OrcID: 0000-0003-1062-4581

²İlyas Kacar, Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, Niğde, Türkiye. E-mail: ikacar@gmail.com  OrcID: 0000-0002-5887-8807

Atıf: Korkmaz, C., Kacar, İ. (2025). GRU Ağı ve DEM esaslı fıstık sınıflandırma simülasyonu kullanarak zaman serisi tahmini. *Tekirdağ Ziraat Fakültesi Dergisi*, 22(4): 896-909.

Citation: Korkmaz, C., Kacar, İ. (2025). Time series prediction using GRU network and DEM based peanut grading simulation. *Journal of Tekirdag Agricultural Faculty*, 22(4): 896-909.

©Bu çalışma Tekirdağ Namık Kemal Üniversitesi tarafından Creative Commons Lisansı (<https://creativecommons.org/licenses/by-nc/4.0/>) kapsamında yayınlanmıştır. Tekirdağ 2025

Abstract

The manuscript investigates an automation system that uses Discrete Element Method (DEM)-based simulations and deep learning algorithms to optimise process efficiency and screening quality in peanut processing. For this purpose, a peanut classification machine with a cylindrical screen, which is developed and manufactured for the classification of grain products such as peanuts, which is a post-harvest process, is simulated using DEM-based Ansys RockyDEM© software. The cylindrical screen used in the grading machine has high grading efficiency and low energy consumption compared to traditional methods. A solid model of this screen is created for the simulations. In DEM-based software, motion of each peanut grain is calculated separately. Although the use of such software in enterprises brings significant advantages in terms of optimisation and product quality, high number of particles with granular structure cause serious computational costs and difficulties. This is the most important disadvantage of DEM-based simulation software. Although the grading machine used in this study was on a pilot-scale, the simulation process took 63 days, 18 hours and 27 minutes. For large industrial-scale grading machines, this process will obviously be much longer. This situation will require high cost hardware tools. In this study, friction data were obtained from simulation. An important parameter in terms of classification efficiency in such machines is the determination of inter-particle and particle-wall interaction. For this reason, Gated Recurrent Unit (GRU), which is a type of recurrent deep learning networks, are used to model the particle-surface friction data obtained from the simulation. Modelling and prediction performance were investigated. In the obtained peanut classification model, the correlation is 0.88731 and the root mean square error is 322.179 N. The percentage of the mean absolute error is found to be 0.61988 %. 100 iterations are performed and the calculations took 6.42 s. In addition, when compared with the LSTM network, it is found that the model and prediction success of the GRU network is better than the LSTM network. These deep learning networks are promising for optimising the production parameters of classification machines.

Keywords: DEM, Ansys RockyDEM©, Cylindrical classification machine, Deep learning, GRU, LSTM

1. Giriş

Modelleme, bilimin ve endüstrinin pek çok alanında kullanılan kadim bir araçtır. Esas olarak matematiksel fonksiyonlardan oluşmaktadır. Modellerin yaptığı işi tanımlamak için "tahmin", "kestirim", "içgörü", "sanı", "zan", "sezgi" ve "niyet okuma" gibi kelimeler kullanılmaktadır.

Modellemeyi gerçekleştirmek için eğri uydurma, optimizasyon, simülasyon ve yapay zekâ yöntemleri gibi çeşitli teknikler kullanılmaktadır. Bilim camiasında bazı kesimler, yapay öğrenme yöntemlerinin sadece deneysel veriler üzerinde uygulanması gerektiğini savunurken, simülasyonla üretilen veriler üzerinde de yapay öğrenmenin gerçekleştirilebileceği gösterilmiştir. Bu sayede, uzun hesaplama süreleri gerektiren simülasyonlar yerine, daha kısa sürede kestirimlerde bulunmak mümkün hale gelmiştir.

"Ağ" ve "model" kelimeleri sıklıkla birbirlerinin yerine kullanılmaktadır. Aslında, her ikisi de aynı anlamı ifade etmektedir. Zira her ağın temelinde fonksiyonlar yatmaktadır. Bu durum, ağların da matematiksel fonksiyonlar olduğundan kaynaklanmaktadır.

Tekrarlayan Sinir Ağları (RNN'ler) doğal dil işleme, konuşma tanıma ve zaman serisi analizi gibi çeşitli alanlarda güçlü bir araç olarak ortaya çıkmıştır. Bununla birlikte, geleneksel RNN'ler, sıralı verilerdeki uzun vadeli bağımlılıkları yakalamadaki etkinliklerini sınırlayan, kaybolan ve patlayan gradyan problemleri gibi sorunlardan etkilenmektedir. Uzun Kısa Süreli Bellek (LSTM) ağları gibi Geçitli Tekrarlayan Birim (GRU)'lar da, bu zorluklara bir çözüm olarak geliştirilmiş RNN mimarisi olup gelişmiş performans ve eğitim verimliliği sunmaktadır. GRU ağları ilk olarak 2014 yılında Kyunghyun Cho ve arkadaşları tarafından tanıtılmıştır (Chung ve ark., 2014). GRU'ların en güçlü yönlerinden biri, LSTM ağlarına göre daha basit birim üniteye sahip olmalarıdır. Bu basitlik, daha hızlı eğitim ve daha az sayıda parametre anlamına gelmektedir (Alakbari ve ark., 2024). Naga ve ark. (2024) tarafından yapılan son araştırma, kalıntılı bağlantıya sahip yeni bir GRU varyantı önererek bu avantajı araştırmaktadır. Bu mimari değişiklik, yalnızca ağın verimliliğini artırmakla kalmamış, aynı zamanda konuşma tanıma gibi görevlerdeki performansını da geliştirmiştir. GRU'ların arkasındaki temel kavram, ağ içindeki bilgi akışını kontrol eden geçit mekanizmalarında yatmaktadır. Giriş, unutma ve çıkış kapılarına sahip LSTM'lerin aksine, GRU'lar iki kapı kullanmaktadır: sıfırlama kapısı ve güncelleme kapısı (Eren ve Küçükdemiral, 2024). Sıfırlama kapısı geçmiş bilginin (önceki gizli durum) ne kadarının devre dışı bırakılacağını belirlerken, güncelleme kapısı mevcut girdiden ne kadar yeni bilginin gizli duruma dâhil edileceğini düzenlemektedir. Bu seçici geçit süreci, GRU'ların sıralı veriler içindeki uzun vadeli bağımlılıkları etkili bir şekilde öğrenmesini sağlamaktadır. GRU'ların önemli avantajlarından biri, LSTM'lere kıyasla hesaplama verimlilikleridir. Özel bir hücre durumu ve çıkış kapısı olmaması nedeniyle daha az parametreye sahip olan GRU'lar daha az eğitim süresi ve kaynak gerektirmektedir (Dhanjal ve Singh, 2024). Bu da onları özellikle gerçek zamanlı işlemenin veya sınırlı hesaplama gücünün bir kısıtlama olduğu uygulamalar için cazip hale getirmektedir. GRU'lar, sıralı veri içeren çeşitli derin öğrenme görevlerinde kayda değer performans göstermiştir. Makine çevirisi (Zhang ve ark., 2024), konuşma tanıma (Li ve ark., 2024) ve zaman serisi tahmini (Bing ve ark., 2024) gibi alanlarda başarılı sonuçlar elde etmişlerdir. Uzun vadeli bağımlılıkları yakalama yetenekleri ve verimli mimarileri, onları sıralı verilerle çalışan derin öğrenme uygulayıcıları için değerli bir araç haline getirmektedir.

Yer fıstığı sınıflandırması veya boylanması, ürün kalitesini sağlamak ve pazar taleplerini karşılamak için tarım endüstrisinde önemli bir gereksinimdir. Geleneksel sınıflandırma yöntemlerinin emek yoğun, hassasiyetten yoksun olması, enerji maliyetlerinin yüksekliği vb. nedenlerden dolayı geleneksel sınıflandırma makinelerinden ziyade silindirik elekli sınıflandırma makinelerinin kullanılması ile birlikte sınıflandırma doğruluğunun ve verimliliğini artırılması için DEM simülasyonu ve derin öğrenme gibi gelişmiş teknolojilerin entegrasyonu araştırılmaktadır. Hesaplamalı akışkanlar dinamiği (Computational Fluid Dynamics, CFD) ise akışkan malzemenin analizinde kullanılan bir başka yöntemdir.

Ansys RockyDEM© gibi DEM esaslı analiz programları fıstık sınıflama işlemindeki fıstık tanelerinin dinamik yığın hareketinin anlaşılması ve işlem sırasında bu partiküllerin herhangi bir konum ve zamanda birbirleri ve çevreleri ile olan her türlü (hız, kuvvet, moment, güç, enerji, sürtünme) etkileşimlerinin belirlenmesinde ayrıntılı sonuçlar sağlayarak parçacık dinamikleri ve ayıklama mekanizmaları hakkında değerli bilgiler sağlamaktadır (Korkmaz ve Kacar, 2024a). Bu yazılımlar, sınıflandırma işlemi sırasında yer fıstığı davranışını da simüle edebilmektedir (Liu ve ark., 2023). DEM yazılımı, sınıflandırma makinelerinin bilgisayar ortamında test ve optimize edilmesine olanak sağlayarak yer fıstığı işleme tesislerinde ekipman tasarımının ve operasyonel

verimliliğin iyileştirmelerine katkı sunabilmektedir (Chen, 2019). GRU ve LSTM ağlarının DEM simülasyonları ile birleştirilmesi, yer fıstığı sınıflandırılmasında makine öğrenimi odaklı karar vermeyi mümkün kılarak sınıflandırma doğruluğunu ve sistem performansını artırma potansiyeline sahiptir (Wang ve ark., 2025).

Bu çalışmada geleneksel sınıflandırma makinelerine göre daha fazla enerji verimliliğine sahip silindirik elekler yer fıstığı vb. ürünlerin sınıflandırma işlemini simüle etmek için DEM esaslı Ansys RockyDEM© yazılımı kullanılmıştır. Yapılan sınıflandırma simülasyonunda elde edilen sürtünme kuvvetine ait zaman serisi verisi, yapay öğrenme yöntemlerinden biri olan GRU ile modellenmiştir. Tahmin başarısı, farklı modeller ile karşılaştırılmıştır. Bu çalışmada, zaman serisi türünde olan, fıstık tanesi-elek duvarı arasındaki sürtünme verisi incelenmiştir.

2. Materyal ve Metot

2.1. Fıstık sınıflandırma esnasında net kuvvet

Şekil 1'de gösterilen fıstık sınıflandırma (boylama) makinesinin simülasyonu yapılmıştır. Simülasyonda, fıstıkların makine içinde hareketini etkileyen kuvvetler hesaplanmıştır. Bu kuvvetlerden biri, fıstık tanelerinin birbirleri ve silindirik elek duvarı arasındaki sürtünmeden kaynaklanan teğetsel kuvvettir. Teğetsel kuvvetin büyüklüğü, tane-duvar arası sürtünme katsayısı ve fıstığa etkiyen dik kuvvete bağlıdır. Dik kuvvet ise, fıstığın ağırlığı ve makine tarafından uygulanan diğer kuvvetlerin bileşkesidir.

Simülasyonda, net kuvvetin bileşenlerinin (teğetsel ve normal kuvvetler) ayrı ayrı hesaplanması ve bu kuvvetlerin yardımıyla tork, güç ve enerjinin belirlenmesi amaçlanmıştır. Bu hesaplamalar, fıstıkların makine eleğinde nasıl hareket ettiğinin ve hangi aşamalarda sınıflandırıldığına daha iyi anlaşılmasını sağlayacaktır.



Figure 1. Simulated peanut grading machine

Şekil 1. Simülasyonu yapılan fıstık tasnif makinası (Ugurluay ve Akcalı, 2021)

Sürtünme kuvvetine esas olan net kuvvetin hesaplanması, Ugurluay ve Akcalı (2021) tarafından yapılarak dairesel ve helisel yol halleri için sırasıyla Eşitlik (1-a) ve Eşitlik (1-b)' deki gibi verilmiştir.

$$F(\beta) = g[\beta(n - \cos\beta) - (n - 1)\sin\beta] - g\mu_d[\beta\sin\beta + (n - 1)(1 - \cos\beta)] - \frac{1}{2}r\mu_d\omega^2\beta^2(1 + n) = 0 \quad (\text{Eş.1-a})$$

$$F(\beta) = \frac{\rho r e}{\beta} \left[(1 + n(\beta - 1)) \left(g(\cos\varphi - \mu_h \sin\varphi)(\sin\beta - \beta\cos\beta) + \left(g - \frac{1}{2}r\omega^2\beta^2 - g\cos\beta - g\beta\cos\beta \right) \mu_d \right) \right] = 0 \quad (\text{Eş.1-b})$$

Burada ω, r, μ_d, α ve g sırasıyla açısal hız, tambur yarıçapı, tanecikli malzemenin sürtünme katsayısı, silindirik elek dönme açısı ve yerçekimi ivmesidir. β silindirin tabanından itibaren partikülün oluşturduğu yayın açısıdır. e elek yüzeylerindeki tabakanın minimum yüksekliğidir. $n = \frac{h_0}{e}$ burada n katman sayısı olup h_0 ise elek yüzeylerindeki tabakanın maksimum kalınlığıdır.

2.2. Ayrık eleman yöntemi

DEM'de parçacıkların yörüngesini hesaplamak için denge denklemleri kullanılmaktadır. Bu denklemler d'Alembert ilkesine, açısal momentuma ve Newton'un ikinci hareket yasasına dayanmaktadır (Eşitlik 2). Her ikisi de adi diferansiyel denklemdir.


$$m_i \frac{dv_i}{dt} = \sum_j (F_{n,ij} + F_{t,ij}) + m_i g + F_{f \rightarrow p} \quad (\text{Eş.2-a})$$

$$I_i \frac{d\omega_i}{dt} = \sum_j (M_{t,ij} + M_{r,ij}) + M_{f \rightarrow p} \quad (\text{Eş.2-b})$$

Burada i, j parçacık numarası, g yerçekimi ivmesi, m kütle, I parçacığın kütle eylemsizlik momentidir. n ve t sırasıyla normal ve teğetsel doğrultulardaki yön vektörleridir. v doğrusal hız vektörü iken, ω parçacığın dönme hızı vektörüdür. $F_{f \rightarrow p}$ ve $M_{f \rightarrow p}$ ifadeleri ise CFD-DEM ortak çalışması durumunda, parçacık-akışkan etkileşimi nedeniyle oluşan sırasıyla ek kuvvet ve momenttir. Bu çalışmada ortak çalışma olmadığı için $F_{f \rightarrow p}$ ve $M_{f \rightarrow p}$ ifadeleri sıfırdır. F kuvvet iken, $M_{t,ij}$ parçacığın dönmesine neden olan tüm teğetsel kuvvetler (teğetsel kuvvet bileşeninin yanı sıra yerçekimi veya sürüklenme gibi) tarafından üretilen net teğetsel tork, $M_{r,ij}$ terimi j parçacığı veya duvar tarafından, i parçacığına etki eden yuvarlanma direnci torkudur. $M_{r,ij}$ 'nin doğrultusu, dönme hızı doğrultusu ile aynı ancak yönü terstir. Normal kuvvet, parçacık dönüşüne katkıda bulunmaz.

Tablo 1. DEM simülasyon parametreleri

Table 1. DEM simulation parameters

Enjeksiyon özellikleri	Değer	
Parçacık şekli	216 adet üçgen yüze sahip çok yüzlü, 	
Parçacık türü, malzeme	Yer fıstığı taneleri, tek bileşenli malzeme	
Parçacık malzeme davranışı	Sert küre	
Parçacık eşdeğer çap dağılımları, dp (mm)	22 (%100)+7.6 (%22)	
Parçacık hacmi, (m^3)	$5.57528 \cdot 10^{-6}$	
Partikül kütle akış hızı ($kg \cdot h^{-1}$)	0.169	
Parçacıkların enjeksiyon noktasındaki hız vektörü ($m \cdot s^{-1}$)	 $3 \cdot m \cdot s^{-1}$ (giriş yüzeyine normal)	
Zaman adımı boyutu (s)	0.01	
Gerçek zaman süresi (s)	60	
Simulation fiziği	Değer	
Normal kuvvet	Lineer yay-damper	
Teğetsel kuvvet	Coulomb	
Yuvarlanma direnci torku	Sabit, $M_{r,ij} = -\mu_r \mathbf{r} \times \mathbf{F}_{cn,ij} \frac{\omega_p}{ \omega_p }$	
Sayısal yumuşama faktörü	1	
Yerçekimi	$9.81 \cdot m \cdot s^{-2}$	
Malzeme özellikleri	Partikül	Duvar (çelik)
Young modülü, E	10.11 MPa	200 GPa
Poisson oranı, ν	0.201	0.3
Katı yoğunluğu, ρ_s ($kg \cdot m^{-3}$)	416	7.850,00
Yığın yoğunluğu, ρ_b ($kg \cdot m^{-3}$)	250	--
Tambur dönüş hızı	--	10 dev dak^{-1}
Malzeme etkileşim özellikleri	Partikül-partikül	Partikül-duvar
Sürtünme katsayısı, $\mu(\dot{s}_t)_{static}$, $\mu(\dot{s}_t)_{dynamic}$	0.408, 0.318	0.326, 0.326
Yuvarlanma direnci katsayısı, μ_r	0.2	0.2
Sıçrama katsayısı, ϵ	0.224	0.224

Bir çarpışma esnasında temas oluşmaktadır. Temas modelleri, parçacık-parçacık ve parçacık-duvar temaslarında oluşan temas kuvvetini hesaplamak için kullanılmaktadır. Temasın modellenmesinde *yumuşak* veya

sert küre teknikleri kullanılmaktadır. *Sert küre* yönteminde, parçacıklar rijittir ve temasta herhangi bir deformasyon yoktur. İkili temasta, hareket ve enerji kaybını hesaplamak için sıçrama katsayıları ve şok yasaları kullanılmaktadır. Fakat bir çarpışma esnasında oluşabilecek çoklu temas hesaba katılmamaktadır. Yumuşak küre yönteminde ise parçacıklar rijit olmakla birlikte, temas sırasında parçacıklarda oluşacak deformasyon, "üst-üste binme" olarak adlandırılan bir teknikle modellenmektedir. Bunun yanı sıra, van der Waals kuvveti, sıvı köprü kuvveti ve elektrostatik kuvvet gibi temas dışı kuvvetler de hesaplama dâhil edilebilmektedir. Çoklu temas hesaba katılmaktadır.

2.3. Simülasyon ve veri toplama

Ansyes RockyDEM©, taneli sistemlerin davranışlarını simüle etmek için kullanılan bir yazılım paketidir (Rocky, 2025). Bu program, karmaşık etkileşimleri ve tanecikli akışları inceleyerek, taneli malzemelerin davranışlarını analiz etmeye yardımcı olmaktadır. Yazılım, kullanıcı dostu bir arayüze ve gelişmiş özelliklere sahiptir. Bu özellikler arasında parçacık şekli kütüphaneleri, temas algılama algoritmaları ve paralel hesaplama yetenekleri yer almaktadır. Simülasyon parametreleri *Tablo 1*'de sunulmuştur. Hesaplama 60 adımdan oluşmaktadır. Her adım 1 saniyelik bir zaman diliminde gerçekleşmektedir. Daha yüksek çözünürlüklü sonuçlar elde etmek için her *bir* zaman adımı ayrıca 10 alt adıma daha bölünmüştür. Bu sayede toplam 600 zaman noktasında hesaplama yapılmıştır. Veri, partikül-duvar teması ve sürtünme katsayısından kaynaklanan zamana bağlı sürtünme kuvvetidir. 60 s gerçek zamanın simülasyonu 63 gün 18 saat 27 dakika sürmüştür. Hesaplama, 8 GB RAM Intel® Core™ i5-1135G7 işlemci 8M önbellek, 4.2 GHz dört çekirdekli işlemciye sahip bir bilgisayar kullanılarak gerçekleştirilmiştir. Simülasyon sonunda zamana bağlı sürtünme veri seti elde edilmiştir.

Şekil 2'de deneysel tambur geometrisi ve tanecik boyutunu gösteren ekran görüntüleri verilmiştir. *Şekil 3*'te ise fıstık sınıflama makinesinde, simülasyon esnasında oluşan partikül dağılımları gösterilmektedir.




Figure 2. a-) Model of the cylindrical sieve, b-) Geometry and dimensions of the peanut kernel

Şekil 2. a-) Silindirik eleğin modeli, b-) Yer fıstığı tanesinin geometrisi ve boyutları




Figure 3. a-) Simulation process at step 15, b-) at step 46

Şekil 3. a-) Simülasyon sürecinde 15. adım b-) 46. adım

Şekil 4'te sürtünme kuvvetine ait zaman serisi, bu serinin eğitim-doğrulama-test bölümleri görülmektedir.



Figure 4. Time series data of contact friction force from the simulation and data portions

Şekil 4. Simülasyondan elde edilen temas sürtünme kuvvetinin zamana bağlı verisi ve veri bölme oranı

2.4. Veri ön analizi

Veriyi modelleme aşamasına geçmeden önce, mevcut verinin davranışını anlamak kritik önem taşımaktadır. Bu amaçla, veriye, zaman serilerinin yaygın ön analiz yöntemlerinden olan gecikme tayini ve hipotez testleri uygulanmıştır. Testler ve GRU ağı oluşturmak için kullanılan program MATLAB ® R2023a' dır (MathWorks, 2023).

Gecikmelerin Belirlenmesi: Zaman gecikmelerini belirlemek için korelogramlar (kısmi oto korelasyon (KOKF) ve oto korelasyon (OKF) grafikleri) kullanılmıştır (Şekil 5).




Figure 5. (a) ACF, (b) PACF of the data

Şekil 5. Veriye ait (a) OKF, (b) KOKF

Her iki grafikte de verinin rastgele bir dizi biçiminde olmadığı ve kendi gecikmelerine bağlı olduğu açıkça görülebilmektedir. OKF katsayılarının sıfırdan önemli ölçüde farklı olması ve yavaş yavaş sıfıra doğru düşmesi bunu göstermektedir. KOKF grafiğindeki dağılım ise 11. gecikmeden sonra iki standart sapma kadarlık güven sınırının altında kalmakta ve sonraki gecikmeler neredeyse sıfıra yaklaşmaktadır. Bu durum, ilk onbir gecikmenin birbirleriyle yüksek oranda ilişkili olduğunu, ancak sonraki değerlerin birbiriyle ilişkili olmadığını göstermektedir.

Seri Türünün Belirlenmesi: Korkmaz ve Kacar (2024a) OKF'de azalma ve KOKF'de ani kesilme gözlemlenen serilerin otomatik gerileyen (AR) türde olduğunu belirtmektedir (Korkmaz ve Kacar, 2024a). Bu durumda, KOKF'deki kesilme sayısı gecikmeyi verecektir. Elde edilen bu bulgulara göre, analiz edilen seri ilk on bir gecikmeye bağlı ve otomatik gerileyen AR(11) türünde bir seridir.

2.5 GRU ile modelleme

Oluşturulan GRU ağının mimarisi Şekil 6'da verilmiştir. GRU, bir tür kendini tekrarlayan ağ olduğu için, şema sürekli tekrar etmektedir.



Figure 6. GRU network topology

Şekil 6. GRU ağ topolojisi

ANALYSIS RESULT					
#	Name	Type	Activations	Learnable Prope...	States
1	sequenceInput Sequence input with 1 dimensions	Sequence Input	$1(C) \times 1(B) \times 1(T)$	-	-
2	GRU01 GRU with 48 hidden units	GRU	$48(C) \times 1(B) \times 1(T)$	InputWeight: 144 ... RecurrentW: 144 ... Bias: 144 ...	HiddenState: 48 x 1
3	dropout 20% dropout	Dropout	$48(C) \times 1(B) \times 1(T)$	-	-
4	fc 1 fully connected layer	Fully Connected	$1(C) \times 1(B) \times 1(T)$	Weights: 1 x 48 Bias: 1 x 1	-
5	output mean-squared-error with response Res...	Regression Output	$1(C) \times 1(B) \times 1(T)$	-	-

Figure 7. The configuration and characteristics of the GRU network

Şekil 7. GRU ağının konfigürasyonu ve özellikleri

Şekil 7'de GRU ağının konfigürasyonu ve özellikleri verilmiştir. Bu çalışmada GRU katmanında 48 gizli birim kullanılmış olup her birinin iç yapısı Şekil 8'deki gibidir.




Figure 8. The internal structure of a GRU hidden unit

Şekil 8. Bir GRU gizli biriminin iç yapısı

GRU ağı oluşturmak için öncelikle ağı hiper-parametreleri uygun şekilde seçilmelidir. Ağ hiper-parametreleri aşağıdaki gibidir:

- Girdi parametresi = 11;
- Çıktı parametresi = 1;
- Gizli katmandaki eleman sayısı = 48;
- Aktivasyon fonksiyonları: Reset kapısı ve unutma kapısında sigmoid fonksiyonu kullanılmıştır. Aday aktivasyonunda ise tanh aktivasyon fonksiyonu kullanılmıştır. Sigmoid fonksiyonu [0, 1] aralığında değer üretirken tanh ise [-1, 1] aralığında değer üretmektedir.
- Eğitim algoritması: ADAM
- İterasyon = 100;

- MiniBatchSize=256;
- Hata kriteri : $MSE = \frac{1}{N} \sum_{t=1}^N (p(t) - o(t))^2$ burada $p(t) = t$ zaman adımında kestirilen değerdir. $o(t) = t$ zaman adımında deneysel ölçülen veri ve N ise toplam veri sayısıdır. MSE'nin kareköküne RMSE denmektedir. MAE ortalama relatif hatanın mutlak değeridir. MAPE ise yüzde hatanın mutlak değerinin ortalama değeridir.
- GRU katmanı sayısı = 1
- Öğrenme hızı = 0.01
- Gradyan eşiği = 1
- L2 regularization katsayısı= 0.01
- Tüm verinin ilk % 90'lık kısmı eğitim ve doğrulama için tahsis edilmişken son % 10 ise test için ayrılmıştır. Ağ; test verilerine karşı kördür.

3. Araştırma Bulguları ve Tartışma

3.1 Kestirim eğrisi

Orijinal veri ve model kestirim eğrisi Şekil 9'da gösterilmektedir.




Figure 9. GRU model prediction performance

Şekil 9. GRU modelin kestirim performansı




Figure 10. Prediction performance of the GRU model on test data

Şekil 10. Test verisi üzerinde GRU modelinin kestirim performansı

Şekil 10'da ise veri setinin test için ayrılmış son kısmını odaklayan bir kestirim eğrisi ve bu eğri ile veri seti arasındaki hatanın dağılımı daha detaylı gösterilmiştir. Dağılımındaki tepe değerlerin, eğrideki tepe ve çukurluklara karşılık geldiği görülmektedir. Bu da modelin, tepe-çukurları algılamada iyi olduğu anlamına

gelmektedir. Tepe-çukur arası değişimleri temsil yeteneği ise daha iyidir. Ayrıca verilerin hata dağılımı da bir değerlendirme yöntemidir. Hata grafiğine bakıldığında hatalar sıfıra yakın rastgele dağılıma sahiptir. Bu durum modelin başarısının bir başka kanıtıdır (Korkmaz ve Kacar, 2024a).

3.2 Doğrulama

Oluşturulan modelin doğrulaması hata yakınsama grafiklerini, zaman serisi yanıt eğrilerindeki hataları, varyans analizini, hata ölçümlerini (MSE, RMSE, MAE, MAPE), korelasyon katsayısı R^2 'yi kullanarak yapılmıştır. Şekil 11'de ağı eğitimi esnasında kaydedilen hata yakınsaması ve kayıp değişimi verilmiştir. Kayıp olarak verilen değer MSE, crossentropy... gibi hata türleridir. Beklendiği üzere iterasyonlarla birlikte RMSE ve kayıp hataları azalmıştır. Ayrıca ezberleme (overfitting) hatasına işaret edecek olan ani artışlar olmamıştır.




Figure 11. a-) Error convergence and b-) loss in training

Şekil 11. a-) Eğitimdeki hata yakınsaması ve b-) kayıp değişimi

Model performansının ölçümünde sıklıkla kullanılan bir diğer yöntem varyans analizi olup modelin temel varsayımlarından biri olan sabit varyans hipotezini test etmek için kullanılmaktadır. Bu hipotez, modelin farklı gruplar için tahmin edilen değerlerin varyansının sabit olduğunu varsaymaktadır. Böylece eğer ağı varyansı sabit çıkarsa, ağ farklı veriler üzerinde aynı performansı sergileyebilecek anlamına gelmektedir. Eğer bir model bu hipotezi karşılamıyorsa ve varyans gruplar arasında değişkenlik gösteriyorsa, bu durum modelin yeterince iyi olmadığını ve iyileştirilmesi gerektiğini göstermektedir.

Hata grafiği ile varyans değerlendirilebilmektedir. Modelin sabit varyansa sahip olup olmadığını belirlemenin en yaygın yolu, model kestirimlerine karşı fark (hata) grafiği oluşturmaktır. Bu grafikte, kestirilen her değer hatasının model tahminine göre dağılımı incelenmektedir. Eğer farklar eşit dağılıyorsa (dağılım iki paralel çizgi arasında kalıyorsa) varyansın sabit olduğu anlaşılabilecektir. Aksi takdirde, farkların dağılımı sistematik olarak artar veya azalır (koni şekli oluşmuşsa) bu durumda varyans değişkendir.

Şekil 12'de verilen fark-kestirim dağılımı incelendiğinde, model kestirimi arttıkça başlangıçta sıfıra yakın olan varyans dağılımı rastgele ve tekdüze hâle gelerek durağan bir duruma ulaşmaktadır. Bu durum, modelin varyansının sabit olduğunu göstermektedir. Ayrıca, modelin eğitim ve doğrulama verilerindeki varyanslar da benzer şekilde hesaplanabilecektir.




Figure 12. Homoscedasticity in the GRU model's prediction

Şekil 12. GRU modelinin tahminindeki eş varyans durumu

Tablo 2'de ise tüm hata metrikleri bir arada gösterilmiştir. Elde edilen fıstık sınıflandırma modelinde korelasyon değeri 0.88731 ve hata karesinin ortalamasının kökü 322.179 N olarak bulunmuştur. Ortalama mutlak

hatanın yüzdesi ise % 0.61988 olarak bulunmuştur. 100 adet iterasyon yapılmış ve hesaplamalar 6.42 s sürmüştür. Model çıktıları ile veri seti arasında yüksek doğrusal bir ilişki mevcuttur. Bu bulgulardan anlaşılan önemli bir çıkarım, GRU ağına ilişkin herhangi bir ön işlem yapılması gereksinimini ortadan kaldırmış olduğudur.

Tablo 2. GRU ağına ilişkin performans metrikleri

Table 2. Performance metrics on GRU network

Özellik	Tahmin
MAE (birim)*	244.779
MAPE (%)	0.61988
Ort. hata (birim)	-20.836
MSE (birim ²)	103.799,3
RMSE (birim)	322.179
Hesaplama süresi (s)	6.42
R (--)	0.88731
İterasyon sayısı (adet)	--

3.3 Tartışma

Literatürdeki bulgulara dayanarak (Altan ve ark., 2021; Kacar ve Korkmaz, 2022; Korkmaz, 2023) söylenebilecektir ki fıstık sınıflandırma eleklerindeki sürtünme grafiğinin zamana bağlı değişimi üzerine yapılan çalışmaların sektörde performans iyileştirmesine katkısı olabilecektir. Bununla birlikte bu ağı LSTM ağları ile olan kıyaslaması *Tablo 3*'te verilmiştir. Listelenen performans metrikleri, tahmin verisi içindir. Literatürdeki LSTM ağı 300 iterasyonla eğitilmiş olduğu için, mevcut çalışma ile kıyaslama yapabilmek amacıyla, mevcut GRU ağı, bu sefer 300 iterasyon yapılarak eğitilmiştir. İlk olarak GRU yönteminin hızı ve daha iyi tahmin yeteneği dikkat çekmektedir.

Tablo 3. Kıyaslama

Table 3. Comparison

Özellik	Mevcut çalışma	(Korkmaz ve Kacar, 2024b)
Yöntem	GRU	LSTM
MAE (birim)*	292.315	379.120
MAPE (%)	2.20834	2.326
Ort. hata (birim)	-117.49	204.2835
MSE (birim ²)	103.799.3	223.442.778
RMSE (birim)	372.043	472.697
Hesaplama süresi (s)	8	37.934
R (--)	0.87044	0.857
İterasyon sayısı (adet)	--	--

Tablo 3'te GRU modelde hesaplama süresinin (8 s) LSTM modele göre (37.934 s) çok iyi olduğu görülmektedir. *Tablo 3*'teki hata metriklerinde azda olsa GRU daha iyi sonuç vermiştir. GRU modelin tahmin performansı RMSE metriği ile değerlendirildiğinde LSTM'ye göre daha iyi performansa sahip olduğu görülmektedir.

GRU'lar derin öğrenmede zaman serisi gibi sıralı verilerin işlenmesi için güçlü ve hesaplama açısından verimli bir yaklaşım sunmaktadır. Geçit mekanizmaları, uzun vadeli bağımlılıkların öğrenilmesini kolaylaştırarak makine çevirisi, konuşma tanıma ve zaman serisi tahmini gibi çeşitli görevleri çok uygun hâle getirmektedir. Derin öğrenme alanındaki araştırmalar gelişmeye devam ettikçe, GRU'ların karmaşık sıralı verileri işlemek için RNN'lerin yeteneklerini geliştirmede giderek daha önemli bir rol oynayacağı beklenmektedir. Bu çalışmada da literatürde belirtilen birçok çalışmada gösterildiği gibi GRU yönteminin veriler üzerine uygulanması, benzer bir yöntem olan LSTM'ye kıyasla daha basit ve hızlı olduğu belirlenmiştir. Yer fıstığı ile çalışmada kullanılan silindirik sınıflandırma parametrelerine uyan diğer ürünlerin de sınıflandırılmasında DEM simülasyonlarının kullanılabilirliğinin yanı sıra, çalışmadaki sürtünme zaman serisine ait modellerin kullanılması, geliştirilerek

başarısının artırılması, gelecek çalışmalar için bir umut ve potansiyel oluşturmaktadır. Makine öğrenme algoritmalarının kullanılması ve geliştirilmesi ile üretimde mevcut güçlüklerin azaltılması da sağlanabilecektir.

Ancak ele alınması gereken zorluklar da vardır. En büyük zorluklardan biri, DEM hesaplaması esnasında, her bir partikül için ayrı hesaplama yapılıyor olmasıdır. Yüksek partikül sayılarında hızlı ve hassas şekilde hesaplama verimliliği için güçlü donanım araçlarına (GPU) ihtiyaç duyulmaktadır. Bu nedenle literatürde son yıllarda DEM analizi ile ilgili yapılan araştırmalar, hesaplama süresi veya maliyetini azaltma yönünde çalışmalara odaklanmaktadır. Simülasyonların verimli bir şekilde çalıştırması, hesaplama kaynaklarına bağlıdır. Ayrıca, simülasyon sonuçlarının doğruluğu büyük ölçüde girdi parametrelerine ve model varsayımlarına bağlıdır. DEM modellerinin geliştirilmesi ve makine öğrenme algoritmaları ile entegrasyonu yer fıstığı vb. ürünlerin sınıflandırma verimliliğini ve doğruluğunu artırabilmektedir. 60 s bir gerçek zamanın DEM simülasyonuna ait 600 adet çözüm elde edebilmek için yapılan simülasyon, 63 gün 18 saat 27 dakika sürmüştür. GRU yönteminin sunduğu 8 s hesaplama süresi, simülasyonlar ile kıyaslandığında, dikkat çekici bir hızdır.

4. Sonuç

Bu çalışmada bir fıstık sınıflandırma işleminin analizi yapılarak elde edilen sürtünme verisinin GRU ağı ile modellenmesi sağlanmıştır. Ayrık eleman yöntemi esaslı yapılan DEM simülasyonu sayesinde veri toplanmıştır. Partikül ile elek yüzeyi arasında oluşan sürtünme kuvvetinin zamanla değişiminin GRU ağı ile modellenmesi yapılmıştır. Sistem tarım ve gıda endüstrilerinde kullanıldığından dolayı önemlidir. Modelin performansı araştırılmış olup bu amaçla istatistiki yöntemler kullanılmıştır. Çalışma sonunda elde edilmiş olan temel çıkarımlar aşağıda maddeler halinde sıralanmıştır.

- Fıstık sınıflandırma kestiriminde GRU ağı hem eğri genel şeklini hem de eğrilerdeki pik ve çukurları yüksek temsil yeteneğine sahiptir. Yöntem veri üzerine herhangi bir ön işlem yapılması gereksinimini ortadan kaldırmıştır.
- Elde edilen fıstık sınıflandırma modelinde korelasyon değeri 0.88731 ve hata karesinin ortalamasının kökü 322.179 N olarak bulunmuştur. Ortalama mutlak hatanın yüzdesi ise %0.61988 olarak bulunmuştur. 100 adet iterasyon yapılmıştır. Model çıktıları ile veri seti arasında yüksek doğrusal bir ilişki ($R = 0.88731$) mevcuttur. Kullanılan ağ, ağıın hiperparametreleri ve bu ağ ile elde edilen kestirim performansı çalışma içerisinde sunulmuştur. Simülasyonda, 60 s gerçek zamanı hesaplamak 63 gün 18 saat 27 dakika sürmüştür. GRU yöntemi 6 s gerçek zaman sınıflandırma işleminin tahminine ilişkin hem eğitim hem de test için toplam hesaplama süresi 6.42 s sürmüştür.
- GRU ağı 1 katman derinliğe sahiptir. Gizli katmanda 48 adet birim bulunmaktadır. Eğitim algoritması ADAM olup başlangıç öğrenme hızı 0.01 değerindedir. Bu değer her 100 iterasyonda bir kez azaltılmaktadır. Azalma katsayısı ise 0.1 olup gradyan eşiği 1 ve L2 regularization katsayısı 0.01 değerindedir. RNN ağ türleri olan GRU ve LSTM ağları birbirleri ile kıyaslandığında, GRU ağının hız ve başarısının LSTM ağına göre daha iyi olduğu görülmüştür.
- Bu çalışma sonunda oluşturulan model, müteakip çalışmalarda, diğer makine öğrenme yöntemleri ile oluşturulabilecek modellerle kıyaslanabilecektir. Ayrıca gelecekteki çalışmalar, bu teknolojilerin doğruluğunu ve hızını iyileştirmeye, yeni ortaya çıkan diğer tekniklerle birlikte uygulamalarını keşfetmeye, farklı fıstık sınıflandırma çeşitlerini ve işleme koşullarını ele alma potansiyellerini araştırmaya odaklanmalıdır. Zaman serisinin gecikmeleri yanı sıra, aynı zamanda harici girişlerin de olabileceği ve bunlarla ağı beslenerek yeni modeller denenmesi ise müteakip çalışma olarak başka bir çalışma potansiyeline sahiptir.

Teşekkür

Yazarlar, bu çalışmanın incelenmesi ve değerlendirilmesi sürecinde sağladıkları değerli katkılar için editörlere, hakemlere ve emeği geçen herkese içten teşekkürlerini sunar.

Etik Kurul Onayı

Bu çalışma için etik kuruldan izin alınmasına gerek yoktur.

Çıkar Çatışması Beyanı

Makale yazarları olarak aramızda herhangi bir çıkar çatışması olmadığını beyan ederiz

Yazarlık Katkı Beyanı

Planlama: Korkmaz, C., Kacar, İ.; Materyal ve Metot: Korkmaz, C., Kacar, İ.; Veri toplama ve İşleme: Korkmaz, C., Kacar, İ.; İstatistikî Analiz: Korkmaz, C., Kacar, İ.; Literatür Tarama: Korkmaz, C., Kacar, İ.; Makale Yazımı, İnceleme ve Düzenleme: Korkmaz, C., Kacar, İ.

Kaynakça

- Alakbari, F. S., Mohyaldinn, M. E., Ayoub, M. A., Hussein, I. A., Muhsan, A. S., Ridha, S. and Salih, A. A. (2024). A gated recurrent unit model to predict Poisson's ratio using deep learning. *Journal of Rock Mechanics and Geotechnical Engineering*, 16(1): 123-135.
- Altan, A. D., Diken, B. and Kayışoğlu, 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.
- Bing, Q., Zhao, P., Ren, C., Wang, X. and Zhao, Y. (2024). Short-term traffic flow forecasting method based on secondary decomposition and conventional neural network–transformer. *Sustainability*, 16(11): 4567.
- Chen, Z. (2019). *Developing a validated model for predicting grain damage using DEM*. (MSc. Thesis) Purdue University, West Lafayette, USA.
- Chung, J., Gulcehre, C., Cho, K. and Bengio, Y. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *Advances in Neural Information Processing Systems 2014 (NeurIPS 2014, Workshop at the 2014)*. 12–13 December, Montreal, Canada.
- Dhanjal, A. S. and Singh, W. (2024). A comprehensive survey on automatic speech recognition using neural networks. *Multimedia Tools and Applications*, 83(8): 23367-23412.
- Eren, Y. and Küçükdemiral, İ. (2024). A comprehensive review on deep learning approaches for short-term load forecasting. *Renewable and Sustainable Energy Reviews*, 189(n.a.): 114031.
- Kacar, İ. ve Korkmaz, C. (2022). Çok katmanlı algılayıcı ağı, uzun kısa süreli bellek ağı ve regresyon yöntemleri ile tarımsal kurutma tahmini. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 12(4): 1188-1206.
- Korkmaz, C. (2023). The Place of Organic and Organomineral Fertilizer Production in Sustainable Agriculture. In: *Sustainable Agriculture Technologies – II*, Ed(s): Bayat, A., İksad Yayınevi, Ankara, Türkiye.
- Korkmaz, C. ve Kacar, İ. (2024a). Modelleme ve tahmin amaçlı veri ön işleme yöntemlerinin ürün kurutma örneği ile açıklanması. *Tekirdağ Ziraat Fakültesi Dergisi*, 21(2): 482-500.
- Korkmaz, C. ve Kacar, İ. (2024b). Zaman serisinin kestirimi için uzun-kısa süreli bellek ağı yaklaşımı. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 39(4): 1053-1066.
- Li, X., Li, S., Zhang, X.-L. and Rahardja, S. (2024). Transformer-based end-to-end speech translation with rotary position embedding. *IEEE Signal Processing Letters*, 31(n.a): 1105-1109.
- Liu, Z., Yu, Y., Wang, J., Kang, Z., He, F. and Gao, L. (2023). Numerical simulation and optimization of peanut sheller air–screen cleaning device. *Agriculture*, 13(10): 1997.
- MathWorks. (2023). Matlab R2023a. <https://www.mathworks.com/products/matlab.html> (Erişim Tarihi: 19.06.2024).
- Naga, R. M., Jayachandran, T., Alzubaidi, L. H., Mazumder, D. and Praveena, H. D. (2024). Residual Network Based Bidirectional Gated Recurrent Unit for Speech Recognition Using Speech Signals. *2024 International Conference on Distributed Computing and Optimization Techniques (ICDCOT)*. 15–16 March, Bengaluru, India.
- Rocky DEM. (2025). Ansys Rocky Particle Dynamics Simulation Software. <https://www.ansys.com/products/fluids/ansys-rocky>, (Erişim Tarihi: 16.08.2025).
- Ugurluay, S. and Akcali, I. D. (2021). Development of a vibrationless sorting system. *Spanish Journal of Agricultural Research*, 19(1): 204.
- Wang, M., Kumar, K., Feng, Y. T., Qu, T. and Wang, M. (2025). Machine learning aided modeling of granular materials: A review. *Archives of Computational Methods in Engineering*, 32(4): 1997-2034.
- Zhang, J., Li, F., Zhang, X., Cheng, Y. and Hei, X. (2024). Multi-task mean teacher medical image segmentation based on swin transformer. *Applied Sciences*, 14(7): 2986.