



Araştırma Makalesi

İç Yer Fıstığı Sınıflama Makinesinin Ayrık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

Cem KORKMAZ*¹, İlyas KACAR²

ÖZ

Bu çalışmada iç yer fıstığı eleme-sınıflandırma süreci, ayrık eleman yöntemine (DEM) dayanan Ansys Rocky DEM® yazılımı ile simüle edilmiştir. Simülasyon 63 gün 18 saat 27 dakika sürmüştür. İç yer fıstığının hasarına, elek metal yüzeyinin aşınmasına ve elek değiştirilme sıklığının artmasına neden olan sürtünme kuvvetinin, zamana bağlı değişimi verisi toplanmıştır. Bu çalışma, parçacık simülasyonları ve sinir ağları kullanarak iç yer fıstığı sınıflandırma süreçlerinin iyileştirilmesini amaçlamaktadır. Sürtünme kuvvetinin modellenmesi ve kestirimi, bir yapay öğrenme yöntemi olan doğrusal olmayan oto-gerilemeli (NAR) sinir ağları ile gerçekleştirilmiştir. Ağda, her birinde sırası ile 100 ve 50 adet nöron bulunan, 2 adet saklı katman bulunmaktadır. Modeli eğitmek için Levenberg-Marquardt algoritması kullanılmıştır. Elde edilen iç yer fıstığı sınıflandırma modeli, 0.97 korelasyona ve 3.58 N kadarlık hataya (RMSE) sahiptir. Ortalama mutlak hatanın yüzdesi ise %3.30 seviyesindedir. Modelden elde edilen sonuçlar ile DEM simülasyonundan elde edilen veriler arasında oldukça iyi bir doğrusal ilişki elde edilmiştir. Ayrıca NAR ağı, veriye herhangi bir ön işlem yapılması gereksinimini ortadan kaldırmıştır. Üstelik ağı eğitimi esnasında toplam 10 adet iterasyon yapılmış ve hesaplamalar 129.8 s sürmüştür. Ağ, DEM simülasyonlarından elde edilen sürtünme kuvvetinin modellenmesi ve kestiriminde yüksek performans göstermiştir. Bu teknik, sektörde performans iyileştirmesine katkı sağlayabilecektir. Doğrudan tarım endüstrisi için ve dolaylı olarak da, ürün kalitesini artırma ve üretim süreçlerini optimize etme potansiyeline sahiptir.

Anahtar Kelimeler: İç yer fıstığı sınıflandırma, Ayrık eleman yöntemi, Doğrusal olmayan oto-gerilemeli sinir ağı, Modelleme, Kestirim

Modelling of Friction Data Obtained from Discrete Element Simulation of Peanut Kernel Grading Machine Using Nonlinear Auto-Regressive Network

ABSTRACT

In this study, the peanut kernel screening-grading process was simulated with Ansys Rocky DEM® software based on the discrete element method (DEM). The simulation lasted 63 days, 18 hours and 27 minutes. Data on the time-dependent variation of the friction force, which causes breakage to the peanut kernels, wear of the screen metal surface and increased frequency of screen replacement, were collected. This study aimed to improve the peanut kernel grading process using particle simulation and neural networks. The modelling and estimation of the friction force was performed with nonlinear autoregressive (NAR) neural networks, a machine learning method. The network had two hidden layers, each with 100 and 50 neurons respectively. Levenberg-Marquardt algorithm was used for training. The resulting peanut kernel classification model had a correlation of 0.97 and an error of 3.58 N (RMSE). The average absolute error was 3.30%. There was a very good correlation between the results obtained from the model and the data collected from the DEM simulation. In addition, the NAR network eliminated the need for any pre-process on the data. Moreover, a total of 10 iterations were performed during the training of the network and the calculations took 129.8 s. The network showed high performance in modelling and prediction of the friction force obtained from the DEM simulations. This technique can contribute to performance improvement in the sector. Directly for the agricultural industry and indirectly it has the potential to improve product quality and optimize production processes.

Keywords: Peanut kernel classification, Discrete element method, Nonlinear autoregressive neural network, Modelling, Prediction

ORCID ID (Yazar sırasına göre)

0000-0003-1062-4581, 0000-0002-5887-8807

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

Yayın Kuruluna Geliş Tarihi: 12.07.2024

Kabul Tarihi: 18.04.2025

¹ Çukurova Üniversitesi Ziraat Fakültesi, Tarım Makineleri ve Teknolojileri Mühendisliği Bölümü

² Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü

*E-posta: ckorkmaz@cu.edu.tr

Giriş

Modelleme; araştırma ve birçok endüstriyel alanda uzun süredir kullanılan bir tekniktir. Bunlar esasen matematikteki fonksiyonlardır. Türkçe'de, modellerin yaptığı işi anlatmak için "*tahmin, temsil, modelleme, öngörü, kestirim, içgörü, sezgi, zan, ileri görüş, niyet okuma*" gibi ifadeler kullanılmaktadır (Larose ve Larose, 2014; Lawrence ve ark., 2006; Tyralis ve Papacharalampous, 2024). Modelleme; yapay zekâ (YZ), simülasyon ve eğri uydurma teknikleri ile yapılabilmektedir (Urang ve ark., 2020). Literatür araştırmalarında yaygın olarak, yapay öğrenme yöntemlerinin sadece deneysel veri üzerinde uygulanması gerektiği savunulsa da, simülasyonlardan üretilen veriler üzerinde de yapay öğrenme çalışmaları yapılmaktadır (Thon ve ark., 2022). Böylece çok uzun hesaplama zamanı alan simülasyonlar yerine daha kısa sürede başarılı kestirim yapılması mümkün olabilmektedir (Davydzenka ve Tahmasebi, 2022; Islam ve ark., 2024).

Yer fıstığı sınıflandırma elekleri, tarım ve gıda endüstrilerinde önemli bir role sahip olup, doğru bir şekilde çalışmamaları, ürün kalitesini olumsuz etkileyebilmektedir. Sürtünme, elek yüzeyi ve fıstık taneleri arasındaki temas nedeniyle ortaya çıkan bir etkidir ve zaman ile değişebilmektedir. Üretim tesislerinde yüksek kapasiteli üretimde, fıstık kalitesi, enerji tüketimi ve özellikle elek malzemesinde oluşacak aşınmalardan kaynaklı değişim sıklığı gibi maliyetler oluşabilmektedir (Londhe ve ark., 2013; Nath ve ark., 2024). Sınıflama verimliliğinde sürtünmenin önemli bir etkisi vardır. Bu nedenle sınıflandırma eleklerinde sürtünme kuvveti verisinin doğasından kaynaklanan doğrusal ve/veya doğrusal olmayan davranışların, YZ sayesinde modellenmesinin ve kestiriminin mümkün olabileceği ön görülebilmektedir (Daghistani ve Abuel-Naga, 2024).

Ayrık elemanlar yöntemi (DEM), tanecikli malzemelerin davranışını incelemek için hesaplamalı mekanik alanında yaygın olarak kullanılan sayısal bir yöntemdir (Donea ve ark., 2004). DEM, tek tek parçacıkları, temas kuvvetleri aracılığıyla birbirleriyle etkileşime giren ayrık elemanlar olarak modellemektedir. Bu yöntem, partikül-partikül, partikül-yüzey ve partikül-akışkan etkileşimlerinin ayrıntılı hesaplanmasını sağlayarak partikül akışları, çarpışmalar ve sıkıştırma gibi olayların karmaşık fiziklerinin analizine olanak tanımaktadır. Sürtünme, kırılma, aşınma, dönme, temas, kuvvet-moment, enerji, güç gibi pek çok boyutu hesaplayabilmektedir. DEM, yıllar boyunca yığın malzeme taşıma, jeoteknik mühendisliği, ilaç üretimi ve toz işleme gibi çeşitli mühendislik problemlerine uygulanmıştır (Cornejo ve ark., 2021). DEM'i hesaplamalı akışkanlar dinamiği (HAD) gibi akış simülasyonları ile birleştiren araştırmacılar, hem katı parçacıkları hem de akışkan fazları içeren çok fazlı sistemleri inceleyebilmişlerdir. Bu birleşik yaklaşım, silolar, akışkan yataklı sistemler, tamburlar veya siklonlar gibi endüstriyel ekipmanlarda çökelleme, karıştırma, ayrışma gibi süreçlerin analiz edilmesini sağlamaktadır. Ayrıca, son yıllarda, geleneksel DEM'i, düzgün parçacık hidrodinamiği (SPH) veya Lattice-Boltzmann metodu (LBM) gibi diğer sayısal tekniklerle birleştiren hibrit yöntemlerin geliştirilmesi, karmaşık çok fazlı akışların daha verimli simüle edilebilmesi için yeni yollar açmıştır (Wang, 2020; Yu ve ark., 2024a; Zhao ve ark., 2024). Bir üretim hattının kurulması, prosesin her aşamasının izlenmesi, bunun için merkezi otomasyon sistemi ve buna bağlı algılayıcılar, eyleyiciler kurmak önemli bir maliyet oluşturmaktadır. Sürecin DEM, HAD-DEM simülasyonunun yapılması sayesinde, hat üzerindeki parametrelerin sonuçlar üzerindeki etkisi gerçekçi bir biçimde elde edilebilmektedir. Ancak simülasyonların da uzun hesaplama

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

süreleri gerektirmesi maalesef ki bir dezavantajdır. Her ne kadar günümüzde güçlü bilgisayarlarla bu dezavantaj giderilebiliyor olsa da, güçlü bilgisayar temini bir başka maliyeti beraberinde getirebilmektedir. İşte bu maliyet ve sonuç doğruluğu arasında bir denge noktasını yakalayabilmek için YZ yöntemleri devreye girmektedir (de Sousa Junior ve ark., 2019). Böylece simülasyon sayesinde deneme-yanılma maliyetlerinden uzak bir biçimde optimum işletme şartları tespit edilebilmektedir (Martignoni ve ark., 2024). Gerçek işletme şartlarına en iyi doğruluk ve yakınlık elde edilebilmektedir (Doroszuk ve ark., 2021; Gelnar ve Zegzulka, 2019). Son yıllarda bu simülasyonların hız, doğruluk vb. yönünden avantajları nedeniyle kullanımı da artmıştır (Adamczyk ve ark., 2024; Jadidi ve ark., 2024; Le ve ark., 2024).

Zaman serisi kestirim modelleri, sadece mevcut veriyi modellemekle kalmamakta, veriye bakarak gelecekteki değerleri kestirilebilmektedir. Bu modeller genellikle istatistiksel yöntemler veya makine öğrenmesi (machine learning, ML) teknikleri ile oluşturulabilmektedir. Farklı zaman serisi kestirim modellerinin uygulanmasıyla, fıstık sınıflandırma eleklerindeki sürtünmenin zaman içinde nasıl değiştiğini anlamak mümkündür. Birçok istatistiksel yöntem farklı tipteki zaman serilerinin analiz edilmesine olanak tanımaktadır. Oto-gerilemeli entegre hareketli ortalama (ARIMA, autoregressive integrated moving average) modelinin yanında Holt-Winters yöntemi gibi diğer istatistiksel yaklaşımlar da sürtünmenin zamana bağlı değişimini kestirmek için kullanılabilmektedir (Hyndman ve Athanasopoulos, 2021).

Zamana bağlı veri üzerinde doğrusal olmayan oto-gerilemeli (NAR, nonlinear autoregressive) ağlarının modelleme ve kestirim başarısından yararlanılmıştır. Dönen bir yel değirmeni miline gelen dinamik yüklerin oluşturduğu titreşim verilerinin kestiriminde, NAR yöntemi ile oldukça iyi bir başarı elde edilmiştir. Titreşim gibi zamana bağlı çok değişim gösteren verilerin kestirimi oldukça zordur. Makine parçalarına vereceği zararın önüne geçebilmek için kestirimci-bakım ve bunun için de erken-kestirim yapmak önemlidir (Jauregui-Correa, 2023).

Finans ve kontrol sistemleri de dâhil olmak üzere çeşitli alanlardaki NAR türündeki zaman serilerinin modellenmesi ve kestirimi için etkili bir araç olarak NAR ağı kullanılagelmektedir (Rindell, 2024). NAR modelleri, verilerdeki doğrusal olmayan bağımlılıkların yakalanmasına izin veren oto-gerilemeli (AR) modellerin ve sinir ağlarının kombinasyonuna dayanmaktadır. Bu modellerin doğruluk ve kestirim gücü açısından geleneksel doğrusal AR modellerinden daha iyi performans gösterdiği görülmüştür (He, 2024; Tiwari ve ark., 2022). Ancak ağların başarılı olabilmeleri için eğitilmeleri gerekmektedir. Eğitim süreci, kestirilen ve gerçek değerler arasındaki hatayı en aza indirmek amacıyla sahip geri yayılım (BP, back-propagation) veya parçacık sürüsü optimizasyonu (PSO, particle swarm optimization) gibi algoritmalar kullanılarak ağınlıklarının optimize edilmesini içermektedir. Farklı NAR ağı türleri mevcut olup bunlardan bazıları NARX (harici girdili NAR, exogenous NAR), NARMAX (harici girdili hareketli ortalama NAR, exogenous moving average NAR) ağlarıdır (Kelley ve Hagan, 2024).

Bununla birlikte kısa mesafeli seyahatler için trafik akışı ve hava durumu verilerinin kestiriminde uzun-kısa süreli bellek (LSTM, long-short term memory), kapılı tekrarlı birim (GRU, gated recurrent unit) türü derin öğrenme ağlarının, NAR ağına göre daha başarılı olduğu tespit edilmiştir (Walch ve ark., 2023). Müşterilerin elektrik tüketimindeki yük kestirimi, elektrik dağıtımı yapan bir firmanın enerji yönetimine, altyapı ve bütçe planlamasına olanak tanımaktadır. Çok geniş perspektifte model performansları araştırılmış, ARIMA modellerinin diğer sinir ağı modelleri ile hibritlenerek kullanılması sayesinde modellerin doğrusal ve doğrusal olmayan dinamik davranışları kestirim başarısının arttığı belirtilmiştir (Eren ve Küçükdemiral, 2024).

"Dikkat mekanizması" kullanımı da yaygınlaşmaktadır. Böylece bilişsel dikkati taklit eden derin öğrenme yöntemleri, girdi verileri arasında dikkat edilmesi gereken veriyi belirleyebilmektedir. Binalarda kullanılan soğutma sistemlerinin, günlük elektrik enerjisi tüketiminde önemli bir etkisinin olduğu, ARIMA

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

ve dikkat mekanizmasının hibrit kullanılmasıyla tespit edilmiştir (Cai ve Yang, 2024). Ayrıca, NAR modellerinin sıfırdan yeniden eğitilmesini gerektirmeden, akış verileriyle artımlı olarak eğitilmesini sağlayan çevrimiçi sıralı aşırı öğrenme makinesi (OS-ELM) gibi çevrimiçi öğrenme algoritmaları da verimliliği nedeniyle ilgi çekmektedir (Li ve ark., 2010). Örneğin, ARIMA, yıllık iklim değişikliği gibi mevsimsel değişimlerin modellenmesi ve kestiriminde çok yaygın kullanılmaktadır (Abd-Elhamid ve ark., 2024).

Son yıllarda, YZ yöntemlerinin çok geniş olan kullanım alanlarına, akışkanlar mekaniği, granül akışı konuları da girmiştir (Hossein ve ark., 2024; Rangel ve ark., 2024; Wang ve Kumar ve ark., 2024). Katı partikül-gaz etkileşimlerinden oluşan birleşik akışta sürüklenmenin deneysel ve simülasyonla yapılan analizlerinden elde edilen veriye (Jiang ve ark., 2021; Jiang ve ark., 2019), DEM türü SPH analizinden elde edilen veriye evrişimli sinir ağı (CNN) uygulanmıştır (Sarairoh, 2024). Bu yöntem aynı zamanda türbülanslı akışlara da uygulanmaktadır (Kochkov ve ark., 2021). HAD simülasyonlarının hızlandırılması için çekişmeli üretici ağ (GAN, generative adversarial network) kullanılmıştır (Xie ve ark., 2018). Dönen bir tamburlu kurutucudaki partikül akışı için yapılan DEM simülasyonlarında (Lu ve ark., 2021) CNN kullanımı hesaplama hızını artırmıştır (Cristianini ve Shawe-Taylor, 2000; Majka, 2024).

Mevcut çalışmalar ışığında; tarım, gıda, katı atıklar vb. ürünlerin çeşitli davranışlarının modellenmesi ve kestirimi konularında açık literatürde pek çok çalışmanın olduğu, pek çok alanda YZ teknikleri başarı ile uygulandığı ancak iç yer fıstığı sınıflandırmada işlem parametrelerinin modellenmesinde nadiren ML yöntemlerinin kullanıldığı görülmüştür. Bu konuda bir araştırma boşluğu bulunmaktadır. Böylece YZ yöntemlerinin, iç yer fıstığı sınıflandırmada, sürtünme kuvvetinin kestiriminde de kullanım potansiyeline sahip

olabileceği hipotezi ortaya atılarak, konunun incelenmesine karar verilmiştir.

Bu çalışmanın amacı, deneysel bir iç yer fıstığı sınıflandırma makinesindeki sürtünme kuvvetinin modellenmesi ve kestirimidir. Bu amaçla sınıflandırma işleminde, 60 saniyelik gerçek zaman için DEM esaslı simülasyon yapılmıştır. Simülasyondan elde edilen sürtünme kuvveti zaman serisi, NAR yöntemi ile modellenmiştir. Bu model, 12 saniyelik ileriye doğru kestirim için kullanılmıştır. Böylece fıstığı sınıflandırma süreçlerinin verimliliğini, kalitesini ve hassasiyetini artırmak amaçlanmıştır. Bu çalışmanın bulguları, iç yer fıstığı sınıflandırma sistemlerinin kalite kontrol ve üretim sürecinin işleyişinde, iyileştirme yapma potansiyeline sahiptir.

Materyal ve Yöntem

İç yer fıstığı sınıflandırma makinesi ve net kuvvet

Şekil 1’de görülen deneysel bir iç yer fıstığı sınıflama makinesi simüle edilmiştir. Makine iki kısımdan oluşmaktadır. İlk kısım besleyici, diğeri ise silindirik helisel elektir. Silindirin eksenine paralel olarak yerleştirilmiş iki taraflı fırçalar vardır. Bu fırçalar elek deliklerinin tıkanmasını önlemektedir. Güç, elektrik motoru tarafından kayış-kasnak sayesinde silindirik eleğin miline aktarılmaktadır. Silindir kendi eksenini etrafında dönerken, besleyicinin kapısı da aynı anda silindirik bir kam mekanizması aracılığıyla titreştirilerek fıstık tanelerinin eleğe akışı başlatılmaktadır. Silindirik eleğin altında küçük boylu fıstığı toplamak için bir hazne ve eleğin ucunda ise büyük boylu taneyi toplamak için başka bir hazne bulunmaktadır. Elek duvarının iç yüzeyine sarılmış bir helezonik sarmal bulunmaktadır. Eleğin dönmesi sayesinde, tanelerin ilerletilmesi sağlanmaktadır. Makina, deneysel çalışma için üretilmiş bir düzenektir. Ticari bir marka ve modeli yoktur.

Çizelge 1’de bu çalışmada kullanılan iç yer fıstığı sınıflama makinesinin bazı önemli özellikleri verilmiştir.

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi



Şekil 1. Simülasyonu yapılan deneysel iç yer fıstığı sınıflandırma makinesi ve silindirik elek

Çizelge 1. İç yer fıstığı makinesi özellikleri ve sınıflama performansı

Özellik	Değer
Boyutları (mm)	1590x990x780
Silindirik elek yarıçapı (mm)	318
Silindirik elek uzunluğu (mm)	1000
Elek delik genişliği (mm)	7
Elek delik uzunluğu (mm)	13
Elektrik motor gücü (kW)	0.36
Çıkış kapasitesi (kg/h)	169.6
Sınıflama verimliliği (%)	99.6
Dönme hızı (devir/dak)	10
Helis açısı (°)	12

Elek sabit bir ω açısal hızında dönerken tanecikli ürünün uygun delik üzerine geldiğinde, aşağı düşmesi sağlanmaktadır. Elek tamburu içerisindeki tanecik üzerine üç ana kuvvet etki etmektedir: Silindirin dönüşünden kaynaklanan merkezkaç kuvveti (elek yüzeyine normal), yerçekiminden kaynaklanan tanecik ağırlığı ve tanecik-elek yüzeyi arasındaki sürtünme kuvveti, $F(\beta)$. Tane, merkezkaç ve sürtünme kuvvetlerinin etkisiyle belirli bir yüksekliğe kadar tırmanmaya başlayacak ve yerçekimi nedeniyle geri kayacaktır. Düz elekler endüstriyel kapasitesi bakımından daha büyük ve yaygın olsa da, eleğe titreşim verilerek çalıştırıldığı için daha fazla güç ve enerji gerektirmektedir. Silindirik eleklerde ise fıstığın yığın hareketi için düşük kayma hareketleri yeterli olduğundan dolayı ω açısal hızı düşük olup sadece "sürtünme kuvveti+elek döndürme momenti"nden kaynaklanan güç-enerji gereksinimine sahiptir. Bu da düz eleklerle kıyasla oldukça az enerji sarfiyatına yol açmaktadır. Yüksek sınıflama verimliliği de elde edilmektedir. Tek veya çok katmanlı yüksek

debili tanecik akışı sayesinde düşük-yüksek kapasiteli uygulamalar da mevcuttur (Ercan, 2012). Çizelge 2’de %7.5 bağıl neme sahip iç yer fıstığı örneklerinin bazı fiziksel özellikleri verilmiştir (Atsyo, 2022).

Çizelge 2. İç yer fıstığı örneklerinin bazı fiziksel özellikleri

Fiziksel özellik	Min.	Maks.	Ortalama
Uzunluk (mm)	11.15	26.84	17.39
Genişlik (mm)	5.02	11.69	8.77
Kalınlık (mm)	4.61	13.24	9.66
Kütle (g)	0.19	1.52	0.80

Sürtünme kuvvetine esas olan net kuvvetin hesaplanması, Akcalı ve ark. (2014) tarafından, dairesel ve helisel yol hâlleri için Eşitlik (1-a) ve Eşitlik (1-b)' deki gibi verilmiştir (Uğurluay ve Akcalı, 2021). Ayrıca güç ve enerji hesabı da verilmiş olmakla birlikte bu makale kapsamında sadece sürtünme kuvveti ele alınmıştır.

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

$$F(\beta) = \frac{pre}{\beta} \left[(1 + n(\beta - 1)) \left(g(\cos\varphi - \mu_n\sin\varphi)(\sin\beta - \beta\cos\beta) + \left(g - \frac{1}{2}r\omega^2\beta^2 - g\cos\beta - g\beta\cos\beta \right) \mu_d \right) \right] = 0 \quad \text{Eşitlik (1-b)}$$

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

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

Bu çalışma kapsamında silindirik eleğe sahip iç yer fıstığı sınıflama makinesinin DEM simülasyonu yapılarak zamana bağlı sürtünme kuvveti verisi hesaplanmış; bu verinin modellenmesi ve kestirimi için NAR yöntemi kullanılmıştır.

DEM

DEM, katı parçacıklar ve çevreleri arasındaki etkileşimi hesaplamak için kullanılmaktadır. DEM, her bir partikül-partikül, partikül-duvar ve partikül-akışkan arasındaki konum, hız gibi dinamiklerini, bunların her türlü etkileşimlerini (kuvvet, moment, ısı-nem transferi, vb.) hesaplamak için kullanılan bir yöntemdir. Yöntem tarım, inşaat, maden, gıda vb. birçok sektörde (Kacar ve Korkmaz, 2021), tanecikli ürünlerin taşınması analizlerinde (Li ve ark., 2024; Tian ve ark., 2024; Wang ve Tian ve ark., 2024; Zhang ve ark., 2024), tarımsal gübre serpmeye, hasat vb. makinelerindeki işletme parametrelerinin analizinde ve son yıllarda ziraat alanında yapılan çalışmalarda yaygın olarak kullanılmaktadır (Okudan, 2020).

DEM esaslı hesaplama, d'Alembert ilkesine, açısal momentuma ve Newton'un ikinci hareket yasasına dayanmaktadır. Parçacıkların yörüngesini hesaplamak için kullanılan denge denklemleri, yöntemin temelini oluşturmaktadır. Her ikisi de adi diferansiyel denklemlerdir (Eşitlik 2).

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

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

Burada; i, j parçacık numarası, g yerçekimi ivmesi, m kütle, I parçacığın kütle eylemsizlik momentidir. n ve t sırasıyla normal ve teğetsel doğrultulardır. v ve ω ise sırasıyla parçacığın doğrusal ve açısal hız vektörleridir. F kuvvet iken, $M_{t,ij}$ parçacığın dönmesine neden olan tüm teğetsel kuvvetler (teğetsel kuvvet bileşeninin yanı sıra yerçekimi veya sürüklenme gibi etkiler) tarafından üretilen net teğetsel torktur. $M_{r,ij}$ terimi j parçacığı veya duvar tarafından i parçacığına etki eden yuvarlanma direnci torkudur. $M_{r,ij}$ momentinin doğrultusu açısal hız

doğrultusu ile aynı ancak yönü terstir. Normal kuvvet, parçacık dönüşüne katkıda bulunmamaktadır.

Parçacık-akışkan etkileşimi durumunda kuvvet ve momentler $F_{f \rightarrow p}$ ve $M_{f \rightarrow p}$ olup HAD-DEM birleşik simülasyonlarında ortaya çıkmaktadır. Bu çalışmada sadece DEM simülasyonu yapıldığından dolayı $F_{f \rightarrow p}$ ve $M_{f \rightarrow p}$ ifadeleri sıfırdır.

Herhangi bir çarpışma esnasında temas meydana gelmektedir. Temas modelleri ise parçacık-parçacık ve parçacık-duvar çarpışma esnasında, oluşan temas kuvvetini hesaplayabilmek için kullanılmaktadır. Temasın modellenmesinde *yumuşak* veya *sert* küre teknikleri kullanılmaktadır. Ayrıca Van der Waals kuvveti, sıvı köprü kuvveti ve elektrostatik kuvvet gibi temas dışı kuvvetler de fiziksel-kimyasal etkileşim sağlamak üzere hesaplama dâhil edilebilmektedir (Korkmaz, 2022). Sert küre yönteminde, parçacıklar rijit kabul edilmekte ve temasta herhangi bir deformasyon olmamaktadır. Bu yöntemde parçacıklar rijittir ve temas ettiğinde deforme olmazlar. Bu nedenle ikili temas hâlinde, hareket ve enerji kaybını hesaplayabilmek için sıçrama katsayıları ve şok yasaları kullanılmakta ve bir çarpışma esnasında oluşabilecek çoklu temas hesaba katılmamaktadır. Yumuşak küre yönteminde ise temas sırasında parçacıklarda oluşacak deformasyon, "üst-üste binme" olarak adlandırılan bir teknikle modellenmektedir (Yeom ve ark., 2019).

DEM esaslı simülasyon ve veri toplama

Yazılım, kullanıcı dostu bir ara yüz ve birçok gelişmiş özellik sunmaktadır. Bu özellikler arasında parçacık şekil kütüphaneleri, temas algılama algoritmaları ve paralel hesaplama yetenekleri bulunmaktadır. Sistem geliştirme, üretim süreçlerinin izlenmesi ve kontrolü, üretim sorunlarının belirlenmesi ve giderilmesi, üretimde optimum parametrelerin belirlenip geliştirilmesi gibi tüm gerçek işletme şartları altında analizlerin bilgisayar ortamında yapılabilmesi, bu ve benzeri yazılımlar ile

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi


mümkün hâle gelmiştir (Ansys Rocky DEM©, 2021). Her bir partikülün tek tek izlenmesi, çevre ile her türlü etkileşimlerinin hesaplanmasında Lagranj takip şeması kullanılmaktadır. Ancak partikül sayılarının 10^4 - 10^8 gibi yüksek olduğu durumlarda hesaplama süresi artmaktadır (Yu ve ark., 2024b). Geleneksel DEM yönteminde hesaplama süresinin azaltılması amacıyla YZ teknikleri uygulanmaktadır (Zhang ve Ge, 2024).

Her bir parçacık için tek bir zaman adımında ayrı ayrı hesaplama yapılmaktadır. Hesaplamalar ardışık zaman adımları için tekrar edilmektedir. Parçacık hareketinin her yeni konumu, tek zaman adımına uygulanmaktadır. Parçacıkların bu hareketlerinin tek tek belirlenmesi ilk kez Cundall ve Strack (1979) tarafından gerçekleştirilmiştir. Mevcut çalışmada DEM simülasyonunda kullanılan parametreler Çizelge 3'te verilmiştir. Hesaplama 60 adımda gerçekleştirilmiş olup, her bir adım 1 saniyelik zaman dilimine sahiptir. Ayrıca her bir zaman dilimi de 0.1 saniyelik alt adımlara bölünmüştür. Dinamik analizlerde "zaman adımı" ve "alt adımlar"ın kullanımı, analizdeki fiziksel olayların doğru şekilde yakalanabilmesi ve sayısal stabilitenin sağlanması için temel bir gerekliliktir. Bu ayırıklaştırma işlemi, diferansiyel denklemleri sayısal olarak çözmek için kullanılan yöntemlerde (örneğin, sonlu elemanlar yöntemi) zamansal ayırıklaştırmanın bir parçasıdır.

Çizelge 3. DEM esaslı simülasyonda kullanılan kanunlar ve ilişkili parametreler

Enjeksiyon özellikleri	Değer
Parçacık şekli	216 adet üçgen yüze sahip çok yüzlü,
Parçacık türü, malzeme	Tek bileşenli, iç yer fıstığı taneleri
Parçacık malzeme davranışı	Sert küre
Parçacık eşdeğeri çap dağılımları, dp (mm)	22 (100%)+7.6 (22%)
Parçacık hacmi, (cm ³)	5.56
Partikül kütle akış hızı (kg/saat)	0.169

Parçacıkların enjeksiyon noktasındaki hız vektörü (m/s) ve partikül boyutları



Zaman adımı uzunluğu (s) ve alt adım sayısı (adet)	1 ve 10
Gerçek zaman süresi (s)	60

Simülasyon fiziği	Değer
Normal kuvvet	Doğrusal yay-damper
Teğetsel kuvvet	Coulomb
Yuvarlanma direnci torku	Sabit, $\mathbf{M}_{r,ij} = -\mu_r \mathbf{r} \times \mathbf{F}_{cn,ij} \frac{\omega_p}{ \omega_p }$
Sayısal yumuşama faktörü	1
Yerçekimi ivmesi	9.81 m/s ²


Malzeme özellikleri	Partikül (İç fıstık)	Duvar (çelik)
Young modülü, E (MPa)	10.1	200e3
Poisson oranı, ν	0.2	0.3
Katı yoğunluğu, ρ_s (kg/m ³)	416	7850
Yığın yoğunluğu, ρ_b (kg/m ³)	250	--
Tambur dönüş hızı (d/dak)	--	10

Temas	Partikül-partikül	Partikül-duvar
Sürtünme katsayısı,	0.408	0.326
$\mu(\dot{s}_t)_{static}, \mu(\dot{s}_t)_{dynamic}$	0.318	0.326
Yuvarlanma direnci katsayısı, μ_r	0.20	0.20
Sıçrama katsayısı, ε	0.224	0.224

Ayrıca sistemdeki hızlı değişimlerin, çözümde gözden kaybolmasını engellemek için yapılmaktadır. Her bir alt adımda hesaplanan ara değerler, zaman içindeki sürekliliği ve doğruluğu korumaya yardımcı olmaktadır. Her adımın 1 saniyelik olması, analizin toplam süresini belirlemektedir ve sistemin ana değişim süreçlerini izlemek için seçilmiş bir zaman dilimidir. Alt adımlar (0.1 saniye) ise her bir ana adımın, 10 alt adıma bölündüğünü göstermektedir. Genel bir kural olarak, ne kadar fazla alt adım varsa, o kadar yüksek hassasiyette çözüm elde edilecektir (Kacar, 2023). Ancak unutulmamalıdır ki, hesaplama sayısı artacağı için çözüm süresi de artacaktır. Sonuç olarak, Şekil 2'de verildiği gibi zamana bağlı sürtünme kuvveti veri kümesi elde edilmiştir. Yatay eksen zaman adımı olup simülasyonda her bir zaman adımının 1 s süreye karşılık geldiği

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi


düşünüldüğünde toplam 60 s'lik bir gerçek zaman hesaplaması yapıldığı görülecektir. Her bir zaman adımı da çözünürlüğü daha yüksek sonuç elde etmek için ayrıca 10 alt adıma bölünmüştür. Toplam veri sayısı 600 adettir. Veri, partikül-duvar teması ve sürtünme katsayısından kaynaklanan zamana bağlı sürtünme kuvvetidir. 60 s'lik gerçek zamanın simülasyonu için hesaplama 63 gün 18 saat 27 dakika sürmüştür. Hesaplama 8 GB RAM ve 2.8 GHz dört çekirdekli CPU'ya sahip bir bilgisayar kullanılarak gerçekleştirilmiştir.



Şekil 2. Sürtünme kuvvetinin zamanla değişimi verisi ve bölümlendirme boyutu

Veri incelendiğinde görülecektir ki pek çok tepe ve çukur mevcuttur. Sebebi ise her bir zaman adımında duvara sürtün tanecik sayısının aynı olmamasıdır. Çok tabakalı bir eleme gerçekleşmektedir. Bu hâli ile böylesi bir veri üzerine, bir regresyon fonksiyonunun kullanılması düşünülse bile, bu denli karmaşık bir şekli temsil edebilecek fonksiyon türü üretmek çok zordur. Bu nedenle kullanılacak modelin, genel veri eğrisini yakalayabilmesinin yanı sıra eğrideki tepe ve çukurları da yakalayabilmesi, YZ modelinin ayırt edici özelliklerinden birisi olacaktır.

Şekil 3'te ise simülasyonda kullanılan elek geometrisi ve tanecik boyutunu gösteren ekran görüntüleri verilmiştir.




Şekil 3. a) Silindirik eleğin simülasyonda kullanılan geometri, b) iç yer fıstığı tanesinin geometrisi

Tane geometrisi ve bölge geometrisi, simülasyon üzerinde etkiye sahiptir. Elek geometrisi üzerinde çok sayıda delik mevcuttur. Her bir delik, her bir tanecığın geçip-geçmediğini tek tek hesaplamayı gerektirmektedir. Üstelik elek dönmektedir. Gerçekçi bir tane geometrisi için tanenin kenar sayısının fazla olması iyidir ancak bu durumda hesaplama yükü de artırmaktadır. Ayrıca dikkatlice bakılırsa görülecektir ki, deliklerin boyutları ve dizilimleri birbirinden farklıdır. Bir tarafa doğru, dizilim değişmektedir. Bu tasarım

eleme verimini artırmak amacıyla kasıtlı olarak yapılmıştır.

Şekil 4'te ise simülasyon esnasında elde edilen iç yer fıstığı dağılımları gösterilmektedir. Ayrıca elenen fıstıkların bölgeye akıtılma şekli, girişin dikdörtgensel açıklığı ve elek altındaki iki adet biriktirme kutusu, elek içerisindeki helisel sarmallar da görülmektedir. Çok tabakalı bir dağılım gerçekleşmiştir.

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi




Şekil 4. a) $t=10$ s b) $t=60$ s anında tambur içerisindeki fıstık dağılımı

Veri ön analizi

Modellemeyi önce mevcut verilerin nasıl bir davranışta olduğunu anlamak çok önemlidir. Bu anlayış, veriye uygun bir model bulmak için yol göstericidir. Zaman gecikmelerinin tayini ve hipotez testleri, zaman serilerinde sıklıkla kullanılan ön analiz türlerinden biridir. Zaman gecikmeleri NAR ağ şemasında  şeklinde gösterilmiştir ve "1 seride, 10 gecikme" anlamına gelmektedir. Bu gecikmeler, veriler arasında, geriye doğru, bağımlılık ilişkisini vermektedir. İşte bu nedendir ki, "doğrusal olmayan oto-gerilemeli - autoregressive" ifadesindeki "gerileme" kelimesi, "gecikme" anlamına gelmektedir. Bu, verinin seride kendisinden önce

bulunan kaç adet veri ile ilişkili olduğunu göstermektedir. Bu ilişki, serinin zaman eğrisine bakıldığında gözle tespit edilememektedir. Serinin gecikmesinin doğru tespiti, eğitilen ağın başarısını artırmak için önemlidir (Korkmaz ve Kacar, 2024a). Zaman gecikmesinin tayininde "oto-korelasyon (OKF)" veya "çapraz korelasyon (ÇK)" grafikleri kullanılmaktadır. Bu çalışma kapsamında, hem NAR ağı hem de oto-korelasyon grafikleri Matlab® ticari programı sayesinde üretilmiştir (Şekil 5) (The MathWorks Inc., 2022). OKF yanı sıra kısmi oto-korelasyon (KOKF) eğrisi de görülmektedir. Her ikisi bir arada değerlendirilmelidir. OKF ve KOKF değerleri birimsizdir. Gecikme ise "zaman adımı" birimindedir.



Şekil 5. Veriye ait a) oto-korelasyon (OKF), b) kısmi oto-korelasyon (KOKF)

0 gecikmede, hem OKF hem de KOKF 1 değerinde olmalıdır. Bu durumda iki adet birebir seri, birbirleri ile kıyaslanmaktadır ki 1 değeri elde edilmelidir. Sırası ile 1, 2, 3 gibi her bir kaydırma sonrasında yapılan kıyaslamada, 1 olmasa da belli bir seviyede etkili OKF pikleri görülmektedir. Ancak KOKF pikleri incelendiğinde 10 adet gecikmeye kadar etkili bir korelasyon gözlemlenmişken sonrasında beyaz

gürültü (güven sınırı altında ve sıfıra yakın pikler) olduğu görülmektedir. Bu tespitler ışığında; ① değerler arasında rasgele bir dağılım olmadığı, yani, ② bu serinin 10 adet gecikmeye sahip olduğu anlaşılmaktadır (Alsharif ve ark., 2019; Chu ve ark., 2024; Hagan ve Behr, 1987; Sainbhi ve ark., 2024).


Korkmaz ve Kacar (2024), OKF'nin sıfıra doğru azalması ile birlikte KOKF'de belirli bir

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

gecikmeden sonra aniden kesilme oluşmasının, AR türünde seriye işaret ettiğini ve gecikme sayısının da KOKF'deki birden kesilmenin olduğu değere karşılık geleceğini belirtmişlerdir (Korkmaz ve Kacar, 2024a).

NAR ile modelleme

Bu çalışmada kullanılan NAR topolojisi, geçmiş (önceki) 10 değeri kullanarak, gelecekteki değerleri kestirmek amacıyla geliştirilmiştir. Şekil 6' da gösterilen şema, dışsal girdisi olmayan, ileri beslemeli ve çok katmanlı bir doğrusal olmayan oto-gerilemeli ağı göstermektedir.



Şekil 6. NAR ağ topolojisi

$Y(t)$ hem giriş hem de çıkışta görülmektedir. Bu da çıkışın, girişi beslediği anlamına gelmektedir.

Şemada 1:10 şeklinde gösterilen kısım 1 seride, 10 gecikme anlamına gelmektedir. Giriş katmanı, 10 adet geçmiş gecikmelerin geri beslenmesiyle oluşturulmuştur. 2 adet saklı katman mevcut olup her birinde sırası ile 100 ve 50 adet nöron bulunmaktadır. Her nöron arasındaki ağırlık w ve bias ise b ile gösterilmiştir. w ağırlıkları, bir önceki katmandan gelen çıktı değeriyle çarpılmaktadır. Bu çarpıma, modelin kestirim performansını artırmak amacıyla gerekiyorsa sabit bir b değeri eklenmekte ve nöronlardan bir çıktı elde edilmektedir. Elde edilen bu çıktının, belirlenen bir eşik değeri (0, 1) aralığında olup-olmadığını görmek için bir aktivasyon (transfer) fonksiyonuna sokularak net çıktı elde edilmektedir. Çıktı, eşik değerinin altında kalırsa, bu bilgi dikkate alınmamakta; böylece ağ daha verimli bir şekilde yapılandırılmış

olmaktadır. S ve S sembolleri sırası ile sigmoid ve doğrusal aktivasyon fonksiyonlarını göstermektedir. Görüleceği üzere saklı katmanlarda sigmoid aktivasyon fonksiyonu kullanılmışken çıkışta doğrusal aktivasyon fonksiyonu kullanılmıştır. Doğrusal fonksiyon, değerinde herhangi bir değişiklik yapmadan çıkışa göndermektedir. Her ne kadar türevinin sıfıra yakın olması nedeni ile gradyen kaybolması veya patlaması problemine yol açsa da deneme-yanılma yoluyla saklı katmanlarda sigmoid fonksiyonu kullanılmıştır.

NAR ağlarında öğrenme, w ağırlıklarının ve b değerlerinin iteratif olarak güncellenmesi yoluyla gerçekleştirilmektedir. Eğitim sürecinde, her iterasyondan sonra, ağın genel performansını değerlendirmek amacıyla test ve/veya doğrulama işlemleri yapılmaktadır. Eğitim işlemi çeşitli optimizasyon algoritmaları ile gerçekleştirilmektedir. Bu çalışmada Levenberg-Marquardt algoritması tercih edilmiştir (Khan ve Gupta, 2020). Bu makale kapsamında yer yer "ağ" ve yer yer de "model" kelimesi kullanılmış olup her ikisi de aynı anlamdadır. Zira bir ağın arkasında fonksiyon(lar) bulunmaktadır. Bu da ağın, matematiksel bir fonksiyon olduğunu göstermektedir. Bir MLP (çok katmanlı algılayıcı) ağ oluşturmak için öncelikle ağın hiper-parametreleri uygun şekilde seçilmelidir (Olmedo ve ark., 2018; Pinkus, 1999). NAR bir tür MLP ağıdır. MLP türü bir ağın hiper-parametreleri aşağıdaki gibidir (Korkmaz ve Kacar, 2024b):


- Eğitim, test ve doğrulama bölümleri için veri yığını boyutu
- Aktivasyon fonksiyonu
- Eğitim algoritması
- Öğrenme eşiği, öğrenme oranı, momentum, iterasyon sayısı gibi eğitim parametreleri
- Ağdaki saklı katman sayısı
- Saklı katmanlardaki nöron sayısı

Bazılarının seçimi için özel yöntemler olsa da, çoğu deneme-yanılma yoluyla belirlenmektedir. Ağdaki saklı katman sayısı, saklı katmanlardaki nöron sayısı ve eğitimdeki iterasyon sayısının optimum değerlerinin tespiti için bazı yöntemler

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

mevcuttur. Saklı katman sayısı, problemin karmaşıklığına bağlı olarak belirlenebilmektedir. Daha fazla sayıda saklı katman kullanılması hâlinde ağın, daha karmaşık özellikleri temsil etme yeteneği yükselmektedir. Fakat ezberleme riskini de beraberinde getirmektedir. Sıfır saklı katman doğrusal ayrılabilir fonksiyonlarda veya kararlarda iyidir. Sonlu bir uzaydan diğerine sürekli bir eşlemeyi kapsayan fonksiyonlara yaklaşma yeteneği sadece bir saklı katman ile elde edilebilmektedir. Bununla birlikte, iki saklı katmanın kullanılması, keyfi bir karar sınırının benzersiz bir doğrulukla temsil edilmesini sağlayabilmektedir. 3 ve daha fazlası, herhangi bir düzgün eşlemeye keyfi bir hassasiyet seviyesinde yaklaşma kabiliyetine sahiptir. Bu açıklamalardan 0, 1, 2 katmanın genellikle yeterli olacağı anlaşılmaktadır. Dolayısıyla, bu çalışmada sürtünme kuvvetinin zamana bağlı değişimi, bir fonksiyon veya bir sınır olabileceği için 1, 2 saklı katman denenmiştir. Katmanlarda gereğinden daha az nöron bulunması, yetersiz temsiliyete yol açabilirken gereğinden fazla nöron ise ezberleme hatasına yol açabilecektir. Katmanlardaki optimum nöron sayılarının tespitine yönelik çeşitli formüller mevcuttur. Bunlardan biri $N_h = \frac{N_s}{(\alpha * (N_i + N_o))}$ olup N_i girişteki, N_o çıkıştaki nöron sayılarıdır, N_s ise eğitim veri setindeki veri sayısıdır. α genellikle 2-10 arasında değişen keyfi bir ölçekleme faktörüdür. Saklı katmandaki nöron sayısı N_h 'dir. Bu çalışmada, toplam veri sayısı 600'dür. Bunun %80'lik kısmı eğitimde kullanılmıştır. Yani $N_s = 540$, $N_i = 11$, $N_o = 1$ olmaktadır. $\alpha = 2$ alınmıştır. Bu durumda saklı katmandaki nöron boyutu $N_h \leq 22.5$ olmalıdır. Bununla birlikte, ezberlemeye yol açmadığından emin olduğu sürece daha fazla nöron kullanılabilir. Ezberleme olup-olmadığını tespit etme yöntemlerinden biri şudur: Eğitim esnasında performans (hata yakınsama) eğrileri takip edilerek, hatanın sıfıra yakınsaması beklenmektedir. Yakınsama eğrisi sıfıra yaklaşıyorken, stabilitesinin bozulup hatanın tekrar artışa geçmesi durumu ezberleme oluşmaya başladığına işaret etmektedir. Bu durumda artık eğitime devam edilmemeli veya ardı arkasına belli sayıda iterasyon sonunda hata azalmıyor-artmıyor aynı kalıyorsa da artık

hesaplamaya devam edilmemelidir. Şekil 7'de iterasyon sayısına bağlı olarak hatadaki değişim, hata yakınsama gösterilmiştir. Görüleceği üzere tüm eğriler sıfıra yaklaşmaktadır. Yakınsamanın gidişatına bakıldığında 10 iterasyona kadar bütün eğriler (eğitim, doğrulama, test) giderek sıfır hataya yakınsamıştır. Ancak 10 iterasyondan sonra durum değişmektedir. Zira her ne kadar eğitim hatası azalmaya devam etse de, test esnasında müteakip 6 iterasyonda da sabit bir durum mevcuttur. Doğrulama esnasında ise hata artmaya başlamıştır. Bu nedenle optimum iterasyon sayısı 10 olarak tespit edilmiştir. 10 iterasyondan fazlası hâlinde stabilite bozulacak ve aşırı uyum (ezberleme hatası) oluşabilecektir.



Şekil 7. MSE (mean squared error) hata yakınsama grafiği ve en uygun yineleme sayısı


Levenberg-Marquardt algoritması bir gradyen azalması esaslı algoritma olduğu için Şekil 8'deki gradyendeki azalma ve mü değerindeki artma beklenen bir durumdur. Doğrulama esnasında 10uncu iterasyondan sonra hatanın arttığı (Şekil 7'deki yeşil eğri) ve doğrulamanın yapılamadığı Şekil 8-(c)'den de daha net bir biçimde görülebilecektir.

Gradyen kelimesi "değişim" anlamına gelmektedir. Eğitim algoritması aslında bir optimizasyon işlemidir. Optimizasyon ise minimum veya maksimum gibi bir hedefi bulmayı amaçlamaktadır. Bir minimuma veya maksimuma doğru ilerlerken eğitimdeki değişimin azalması ve tam minimum, maksimum nokta üzerinde sıfır olması gerekmektedir. Bu bakış açısı ile Şekil 8-a'da verilen gradyen eğrisindeki azalma, modelin eğitimi esnasında kullanılan algoritmanın, optimum değere yakınsadığının işaretlerinden biridir. Bir diğer işaret ise mü değeri olup, bunun yüksek değerleri optimuma

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

yaklaşıldığının işaretidir. Şekil 8-b'de mü eğrisi gittikçe artmıştır. Bu da modelin eğitiminin iyi olduğunun bir diğer göstergesidir. Son gösterge ise Şekil 8-c' de verilen doğrulama durumudur. Her yineleme sonunda, oluşan modelin doğruluğu, kontrol edilmektedir. Doğrulamanın yapılması beklenmektedir. Görüleceği üzere 10 yinelemeye kadar doğrulamalar hatasız bir biçimde yapılabilmektedir. Ancak 10 yinelemeden

sonraki ardışık 6 yineleme doğrulanamamıştır. Yani hata artmaktadır. Bu da "eğitimin 10 yineleme ile en iyi şartlarda olacağı, daha fazla eğitmeye devam edilmesinin overfitting (aşırı öğrenme) hatasına götürdüğü" anlamına gelmektedir. Doğrulamanın 6 defa art arda yapılamaması hâlinde, ağ, 6 önceki hâline geri getirilmekte ve bu suretle en iyi modelin elde edildiğinden emin olunmaktadır.



Şekil 8. Ağın eğitimi esnasında gözlemlenen a) gradyen, b) mü ve c) doğrulama durumu

Bu açıklamalar ve tespitler ışığında diğer ağ hiper-parametreleri ise deneme-yanılma yoluyla tespit edilmiştir (Çizelge 4).

Hata metriklerinden MSE değeri $\frac{1}{N} \sum_{t=1}^{NN} (p(t) - o(t))^2$ eşitliği ile hesaplanmaktadır. Burada $p(t)$ değeri t zaman adımında kestirilen değerdir. $o(t)$ ise t zaman adımında deneysel ölçülen veri ve NN ise toplam veri sayısıdır. MSE 'nin birimi, verinin biriminin karesidir. Burada sürtünme kuvveti verisi N (Newton) biriminde olduğundan dolayı MSE değeri de N^2 biriminde olacaktır. RMSE (root mean squared error) ise MSE 'nin karekökü olup, birimi veri birimi ile aynıdır. Bir modelin başarısını, diğer modeller ile değerlendirebilmek amacıyla literatürde hata kriterlerinin birbirleri ile kıyaslandığı görülmüştür. Bu nedenle bu çalışmada elde edilen modelin metrikleri, literatürdeki modellerin metrikleri ile kıyaslanmıştır. MAE (mean average error) mutlak hata ortalamasıdır. Birimi veri birimi ile aynıdır. MAPE (mean absolute percentage error) ise MAE'nin yüzdesidir. MSE (birim²), RMSE

(birim), MAE (birim) ve MAPE (%) değerleri model başarısını ölçmede kullanılan hata metrikleridir. Bu değerler ne kadar sıfıra yakınsa model o kadar az hatalıdır. R (korelasyon) değerleri de ne kadar 1'e veya -1'e yakın ise model o kadar tutarlıdır (Kacar, 2023). Akaike bilgi kriteri (AIC, Akaike Information Criteria) bir başka metriktir, $\log_{10}(f/Hz)$ birimindedir. Daha düşük AIC puanına sahip model, neredeyse aynı hassasiyet seviyesinde kestirim yapmak için daha az bilgi gerektirmektedir. Basitlik ve uyum iyiliği açısından en iyi model, AIC'i en az olan modeldir. Aşırı uyum, AIC formülünün ilk terimini daha negatif, ikincisini daha pozitif yapmakta ve bu iki etki arasında bir uzlaşmaya yol açmaktadır. Sıfır en iyi modeli göstermektedir. Veri, $o(t)^{normalize} = \frac{o(t) - \overline{o(t)}}{\sigma}$ formülü kullanılarak normalize edilmiştir. Burada $o(t)$ veri, $\overline{o(t)}$ değeri ortalama veri ve σ ise standart sapma olup $\sigma = \sqrt{\frac{\sum_{t=1}^{NN} [(p(t) - \overline{o(t)})]^2}{NN}}$ ile hesaplanmaktadır. Korelasyon katsayısı, $R =$

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

$$\frac{NN \sum_{t=1}^{NN} p(t)o(t) - (\sum_{t=1}^{NN} p(t))(\sum_{t=1}^{NN} o(t))}{\left(\sqrt{NN \sum_{t=1}^{NN} p(t)^2 - (\sum_{t=1}^{NN} p(t))^2} \sqrt{NN \sum_{t=1}^{NN} o(t)^2 - (\sum_{t=1}^{NN} o(t))^2} \right)^2}$$
 olup determinant katsayısı ise R^2 'dir.

Çizelge 4. Oluşturulan NAR ağının hiper-parametreleri


Parametre	Değer
İterasyon sınırı	Eğitim esnasında =1000
Saklı katman sayısı	2
Saklı katmandaki nöronlar	1. saklı katmanda: 100 2. saklı katmanda: 50
Aktivasyon fonksiyonu	1. ve 2. saklı katmanda: sigmoid (hiperbolik tanjant türündeki) Çıkışta: doğrusal
Eğitim yöntemi	Levenberg-Marquardt
Gecikme (adet)	10
Giriş düğümleri	10 ($Y_{t-1}, Y_{t-2}, \dots, Y_{t-10}$)
Çıkış düğümleri	1 (Y_t)
Çıkış eşiği	0.99
Öğrenme hızı, η	0.1
Momentum, α	0.1
Öğrenme eşiği	0.0001
Veri kümesinin bölümlenmesi	Modelleme (eğitim %75+test %15+doğrulama %15) % 80 (48 s), kestirim % 20 (12 s)
Eğitimi durdurma kriterleri	Hata = 0, Minimum gradyan = $1e-7$, Ardışık doğrulama hata sayısı=6

mevcutken yapılmaktadır. Örneğin, '1' ile 't-1' zaman adımları için bir zaman serisi verisinin gerçek değerleri mevcutken 't+1' anındaki değeri kestirmek işlemidir. Böyle bir durumda, 't' zaman adımıdaki gerçek değer kaydedilmeli ve bu, 't+1' zaman adımı için kestirim yapmak üzere bir girdi olarak kullanılmalıdır. Kapalı döngü kestirim, önceki kestirimleri girdi olarak kullanarak bir dizideki sonraki zaman adımlarını kestirmektedir. Bu durumda, model kestirim yapmak için gerçek değerlere ihtiyaç duymamaktadır. Örneğin, yalnızca '1' ile 't-1' arasındaki zaman adımlarında toplanan verileri kullanarak dizinin 't' ile 't+k' arasındaki zaman adımlarının değerinin kestirilmesi durumunda; Zaman adımı t'nin kestirilmesi için, zaman adımı t-1 için kestirilen değer, girdi olarak kullanılmaktadır. Kapalı döngü kestirimi, birden fazla sonraki zaman adımı kestirmek gerektiğinde veya bir sonraki kestirimi yapmadan önce ağa sağlanacak gerçek değerler yokken kullanılmaktadır. NAR ağı eğitilirken tüm veri setinin ilk %80'lik kısmı eğitimde kullanılmış ve böylece son %20'lik kısma dair herhangi bir deneyimi olması engellenmiştir. Böylece kapalı çevrim kestirim yapıldığından emin olunmuştur.

Bulgular ve Tartışma

Kestirim eğrisi

Elde edilen model kestirim eğrisi Şekil 9'da gösterilmektedir.



Şekil 9. NAR ağının zaman serisi kestirimi

Ağ, eğitim, test ve doğrulama sırasında kestirim verilerini görmemiştir. Grafikte "açık" ve "kapalı" olmak üzere iki ayrı kestirim eğrisi mevcuttur. Açık döngü kestirim, test verisi


Doğrulama

Modeli doğrulamak için zaman serisi yanıt eğrisi, hata histogramı, varyans analizi, regresyon analizi, MSE yakınsama eğrisi ve korelasyon katsayısı (R) kullanılmıştır.

Varyans analizi, model doğrulamada yaygın olarak kullanılan tekniklerden biridir. Modellemenin temel ilkelerinden biri, varyansların tüm seviyelerde sabit kalmasıdır. İyi bir model, sabit varyans değerinden anlaşılabilir. "Model kestirimleri" ile "fark (hata)" noktalarının çizilmesi, bir modelin sabit varyansa sahip olup-olmadığını belirlemek için kullanılan en popüler yöntemdir. Tüm noktaların, rasgele dağılması, birbirine paralel iki çizgi arasında kalıyor olması sabit varyansı göstermektedir. Aksi takdirde, farkların dağılımı düzenli olarak artar veya azalırsa varyans değişkendir (Korkmaz ve Kacar, 2024a; Khan ve Gupta, 2020). Şekil 10'da bu noktalar verilmiş olup model kestirimi arttıkça varyans dağılımının rastgele ve tekdüze bir duruma yaklaştığı


İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

gözlemlenebilir. Sonuç olarak, varyans sabit görünmektedir.



Şekil 10. Varyans analizi için nokta dağılımı

Şekil 11'de ise 20 çubuklu bir hata histogramı verilmiştir. Bu şekil, hem eğitim, hem doğrulama ve hem de test adımlarındaki hataların histogramını göstermektedir. Histogramlarda, adına "normal dağılım" veya "Gauss dağılımı" denen, çan eğrisi biçiminde bir şeklin oluşması istenen bir durumdur. Bu eğrinin sivri veya yassı olmaması da istenir. Ayrıca mümkün olduğunca simetrik olması da istenen bir başka durumdur. Simetrik bir dağılım, modelin sistematik bir yanlılığa (bias) sahip olmadığını göstermektedir. Model, tahmin ederken gerçek değerlerin hem altında hem de üstünde benzer miktarda hata yapıyor demektir. Yatay eksen hata değeridir. Turuncu çizgi "sıfır hata" değerini göstermektedir. Dikey eksen ise "oluşma sıklığıdır". Histograma bakıldığında en büyük çizgilerin "sıfır hata" etrafında toplandığı görülmüştür. Bu da sıklıkla, küçük hataların oluştuğunu göstermektedir. Yani modelin başarılı olduğu anlaşılmaktadır.




Şekil 11. Hata histogramı

Şekil 12'de ise regresyon analizinin sonuçları gösterilmektedir. Regresyon analizi de model performansının değerlendirilmesinde sıklıkla kullanılan bir başka tekniktir. Bu analiz sayesinde "modelin kestirimi" ile "veri kümesindeki değerler" arasındaki korelasyon tespit edilmektedir. Korelasyon katsayısı R ile gösterilirken R^2 ifadesine determinant katsayısı denmektedir. Her ikisi de birimsizdir. R 'nin 0.01-0.29 arasında değişen değerleri, düşük seviyede bir ilişkiyi, 0.30-0.70 arasında aldığı değerler orta seviyede bir ilişkiyi, son olarak 0.71-0.99 arasında aldığı değerler ise veriler arasında yüksek seviyede bir ilişki olduğunu ortaya koymaktadır (Akoglu, 2018; Schober ve ark., 2018). Sıfır değeri, ilişki olmadığını gösterirken, negatif değerler, ters bir ilişki anlamına gelmektedir. Mutlak değerce R 'nin artması, ilişkinin daha belirgin hâle geldiğini göstermektedir. Beklendiği gibi ağ, eğitim verisi üzerinde en yüksek korelasyona sahiptir ($R=0.99996$) (Şekil 12-a). Bu durum ağın eğitiminin başarısını ortaya koymaktadır. Ancak ağ eğitim verisini zaten tanımaktadır. Bu nedenle yüksek başarı göstermesi zaten beklenen bir durumdur. Asıl gösterge, test verisi üzerindeki korelasyondur. Şekil 12-(b) ve (c) incelendiğinde, ağın, hem doğrulama ($R=0.9667$) hem de test ($R=0.9745$) verisi üzerinde yüksek korelasyona sahip olduğu görülecektir. "Hedef" olarak belirtilen eksen, veri setindeki değerler bulunurken, "çıkış" olarak gösterilen eksen ise ağın kestirdiği değer verilmiştir. Umulan ise birbirlerine eşit olmasıdır ki bu hâlde $R=1$ olacak ve tüm noktalar 45° doğrusu (Çıkış=hedef hattı) üzerinde olacaktır. Grafiklerdeki "eğri uydurma"

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

doğruları ise (hedef, çıkış) noktalarının tümünün üzerine birinci dereceden regresyon yapıldığında elde edilen “Çıkış= a *Hedef+ b ” türündeki doğrudur. Burada a , regresyon doğrusunun eğimi

ve b ise doğrunun "çıkış" isimli eksenini kestiği noktadır. Bu doğrunun korelasyonu ise R ile gösterilmektedir.



Şekil 12. Ağın regresyon analizi, a) eğitim, b) doğrulama ve c) test verisi üzerindeki korelasyon

Çizelge 5'te ağın kestirim performans metrikleri verilmiştir. Elde edilen iç yer fıstığı sınıflandırma modelinde korelasyon değeri 0.97 ve hata karesinin ortalamasının karekökü (RMSE) 3.58 N olarak bulunmuştur. Ortalama mutlak hatanın yüzdesi ise %3.31 olarak bulunmuştur. 10 adet iterasyon yapılmış ve hesaplamalar 129.8 saniye sürmüştür. Model sonuçları ile DEM simülasyonlarından elde edilen veri seti arasında oldukça iyi doğrusal bir ilişki elde edilmiştir. Bu metriklerle sahip NAR ağının, böylesine pik-çukur içeren bir eğriyi, üstelik veri setine herhangi bir ön işlem yapmaya gerek kalmadan oldukça yüksek temsil yeteneğine sahip olduğu tespit edilmiştir. Çizelge 6'da "eğitim ve doğrulama" verisinin ortalama, minimum, maksimum, standart sapma değerleri ile "test" verisinin ortalama, minimum, maksimum, standart sapma değerleri verilmiştir. Bu değerlerin birbiri ile uyumlu olduğu görülmektedir. Bu veriye ait fark değerleri ise Şekil 13'te verilmiştir. Şekilde eğriler en büyük,

en küçük ve ortalama değerlere ilişkin bir fikir vermektedir.

Çizelge 5. Ağın performans metrikleri

Ölçüt	Değer
MAE (birim)*	2.57
MAPE (%)	3.31
Ort. Hata (birim)	3.92
MSE (birim ²)	12.85
RMSE (birim)	3.58
Hesaplama süresi (s)	129.8
R_{test}	0.97
İterasyon adeti	10


(*) Sürtünme zaman serisinin birimi Newton'dur.

Çizelge 6. Veri seti ve model kestirimleri arasındaki farka ait tanımlayıcı istatistik

Ölçüt (*)	Eğitim ve doğrulama	Test
Minimum	0.19	0.27
Maksimum	7.65	10.57
Ort.	2.86	3.93
σ	0.18	0.85

(*) Sürtünme zaman serisinin birimi Newton'dur.

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi



Şekil 13. a) Eğitim ve doğrulama ve b) test verisi üzerinde, veri seti ile model kestirimleri arasındaki fark

Önceki çalışmalar incelendiğinde, iç yer fıstığı sınıflandırmada işlem parametrelerinin modellenmesinde nadiren ML yöntemleri kullanıldığı görülmüştür. Verilerin modellenmesinde kullanılagelen eğri uydurma, regresyon vb. yöntemlerden önce, yöntemin başarısı için, veriye uygulanan ön işlemler, kabul edilen sınırlar içinde olsa da verilerin doğallığını bir miktar değiştirmektedir. Ayrıca geleneksel regresyonlarla sürtünme eğrisinin şekline sahip bir fonksiyon üretmek zordur. Ancak bu çalışmada NAR ağı kullanılarak, veriye bir ön işlem yapmaya gerek olmadan, veri doğallığı bozulmadan sürtünme kuvveti; 0.97 korelasyonla ve 3.58 N hata (RMSE) ile kestirilmiştir. Kestirimdeki varyansın sabit olduğu görülmüştür. Ağ, eğrideki tepe-dipleri yüksek başarı ile kestirmiştir.

Son araştırmalar, yeni mimariler ve optimizasyon teknikleri aracılığıyla NAR ağlarını geliştirmeye odaklanmıştır. Derin öğrenme tekniklerinin kullanılması, NAR modellerinin girdi verilerinden hiyerarşik temsilleri öğrenmesini sağlayarak değişkenler arasındaki daha karmaşık ilişkileri keşfetmelerine olanak tanımaktadır. Önceki bir çalışmada, AR(4) modeli ile AIC kriteri 1.582 olarak elde edilmiş, ARMA(4, 2) modeli ile bu kriter 0.924, ANFIS modeli ile 1.357 ve MLP modeliyle de 1.407 değerleri aldığı bildirilmiştir (Heydari ve ark., 2009). RMSE hatasının BP algoritmasının kullanılması ile 0.0135°C, SVM (destek vektör makinesi, support vector

machine) yönteminin kullanılması ile 0.0151°C ve LSTM yöntemiyle de 0.0112°C değerler aldığı belirtilmiştir (Heydari ve ark., 2009). Tarımsal kurutma kestiriminde regresyon, NAR ve LSTM modelleri kullanılmış ve 0.015 g gibi çok küçük RMSE değerine yakınsayabildikleri bildirilmiştir (Kacar ve Korkmaz, 2022; Korkmaz, 2023).

Bu yöntemin sınırlaması ise zaman serisi verisine uygulanabiliyor olması, bazen gradyen kaybolması/patlaması oluşturabilmesidir. Bununla birlikte yüksek kestirim başarısı, hata toleranslı olması, eksik bilgi ile çalışabilmesi, veriye ön işlem gerektirmemesi ise temel avantajlarıdır. Literatürdeki bulgularla kıyaslandığında görülmektedir ki NAR ağı modelleme ve kestirim görevleri için güçlü bir araçtır. Bu gelişmiş tekniklerin uygulanması doğrudan tarım endüstrisinde devrim niteliğinde olup dolaylı olarak da, ürün kalitesini artırma ve üretim süreçlerini optimize etme potansiyeline sahiptir. İç yer fıstığı sınıflandırma eleklerindeki sürtünme kuvvetinin zamana bağlı değişiminin başarılı bir biçimde kestirilebilmesi, sektörde performans iyileştirmesine katkı sağlayabilecektir.

Sonuçlar

NAR ağları ve DEM simülasyonlarının entegrasyonu, iç yer fıstığı sınıflandırmasında yenilikçi bir yaklaşım sunmuştur. DEM esaslı simülasyonlar ile veri toplanmış ve müteakiben bu veri NAR ağı ile modellenmiştir. Parçacık-

İç Yer Fıstığı Sınıflama Makinesinin Ayrık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

duvar sürtünmesi dikkate alındığında önerilen teknik, sürtünme kuvvetinin kestiriminde, doğruluğu ve güvenilirliği artırmaktadır. Sistem tarım ve gıda endüstrilerinde kullanıldığından dolayı önemlidir. Bu çalışmadan elde edilen ana sonuçlar, aşağıda maddeler hâlinde verilmiştir.

İç yer fıstığı sınıflandırma simülasyonundan elde edilen sürtünme verilerinin modellenmesi ve kestiriminde NAR yöntemi, genel eğri şeklini ve eğrideki tepe ve dipleri temsil etmede oldukça başarılı olmuştur. NAR ağı, veriye herhangi bir ön işlem yapılması gereksinimini ortadan kaldırmıştır.

Elde edilen iç yer fıstığı sınıflandırma modelinde korelasyon değeri 0.97 ve RMSE değeri 3.58 N olarak bulunmuştur. Ortalama mutlak hatanın yüzdesi (MAPE) değeri ise % 3.30 olarak bulunmuştur. 10 adet iterasyon yapılmış ve hesaplamalar 129.8 saniye sürmüştür. Model çıktıları ile veri seti arasında yüksek doğrusal bir ilişki mevcuttur.

Çok katmanlı algılayıcı ağların bir türü olan NAR ağı Levenberg-Marquardt algoritması ile eğitilmiştir. Saklı katman sayısı 2 olup saklı katmanlardaki nöron sayısı sırası ile 100 ve 50'dir.

Simülasyon 60 saniyelik gerçek zamanı hesaplamak için 63 gün 18 saat 27 dakika sürmüştür. NAR yöntemi 12 saniyelik kestirim işlemi için hem eğitim hem de test toplam hesaplama süresi 129.8 saniyedir. Kıyaslandığında aradaki bariz fark dikkat çekicidir. Tüm hesaplamalar 8 GB RAM ve 2.8 GHz dört çekirdekli CPU'ya sahip aynı bilgisayar kullanılarak gerçekleştirilmiştir.

Bu çalışma sonunda oluşturulan model, müteakip çalışmalarda, diğer ML yöntemleri ile oluşturulabilecek modellerle kıyaslanabilecektir. Ayrıca gelecek çalışmalar, bu teknolojilerin doğruluğunu ve hızını iyileştirmeye, yeni tekniklerle birlikte uygulamalarını keşfetmeye, farklı iç yer fıstığı sınıflandırma çeşitlerini ve işleme koşullarını ele alma potansiyellerine odaklanmalıdır. Zaman serisinin kendi gecikmelerine ilave olarak harici girişlerin de bulunabileceği ve bunlarla ağın beslenerek yeni

modeller denenmesi müteakip çalışma olarak başka bir araştırma potansiyeline sahiptir.

Teşekkür

DEM simülasyonları için Ansys Rocky DEM®'in ve Matlab®'in eğitsel amaçlı kullanım imkânını sağlayan sırasıyla, Numesys® Genel Müdürü Sayın Ekin Ersan'a, Sayın Begüm Çifci'ye ve Çukurova Üniversitesi'ne teşekkür ederiz. Bu çalışmanın inceleme ve değerlendirme aşamasında yapmış oldukları değerli katkılardan dolayı editör, hakemler ve emeği geçenlere içten teşekkür ederiz.

Kaynaklar

- Abd-Elhamid, H. F., El-Dakak, A. M., Zeleňáková, M., Saleh, O., Mahdy, M. ve Ghany, S. H. A. E. (2024). Rainfall forecasting in arid regions in response to climate change using ARIMA and remote sensing. *Geomatics, Natural Hazards and Risk*, 15(1): 2347414.
- Adamczyk, W., Widuch, A., Morkisz, P., Zhou, M., Myöhänen, K., Klimanek, A., et al. (2024). A machine learning-based simplified collision model for granular flows. *Powder Technology*: 120006.
- Akcali, İ. D., Mutlu, H. ve Ercan, U. (2014). Mathematical model of a sorting machine. *Tarım Makinaları Bilimi Dergisi*, 10(3): 229-234.
- Akoglu, H. (2018). User's guide to correlation coefficients. *Turkish journal of emergency medicine*, 18(3): 91-93.
- Alsharif, M. H., Younes, M. K. ve Kim, J. (2019). Time series ARIMA model for prediction of daily and monthly average global solar radiation: The case study of Seoul, South Korea. *Symmetry*, 11(2): 240.
- Ansys Rocky DEM®. (2021). The most powerful particle simulation software. (Version 2024 R2). Germany: Ansys®.
- Atsyo, S. (2022). Classification of peanut seeds based on different feed rates using a grading machine. (Master Thesis), Cukurova University, Institute of Science and Technology. (706206).

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

- Cai, J. ve Yang, H. (2024). Attention mechanism-aided model ensemble method of chiller energy consumption prediction. *International Journal of Refrigeration*.
- Chu, H., Wang, Z. ve Nie, C. (2024). Monthly streamflow prediction of the source region of the yellow river based on long short-term memory considering different lagged months. *Water*, 16(4): 593.
- Cornejo, A., Franci, A., Zárate, F. ve Oñate, E. (2021). A fully Lagrangian formulation for fluid-structure interaction problems with free-surface flows and fracturing solids. *Computers & Structures*, 250: 106532. doi: <https://doi.org/10.1016/j.compstruc.2021.106532>.
- Cristianini, N. ve Shawe-Taylor, J. (2000). An introduction to support vector machines and other kernel-based learning methods. Cambridge: Cambridge University Press.
- Daghistani, F. ve Abuel-Naga, H. (2024). Advancements in understanding interface friction: A combined experimental and machine learning approach using multiple linear and random forest regressions. *Geotechnics*, 4(1): 109-126.
- Davydzenka, T. ve Tahmasebi, P. (2022). High-resolution fluid-particle interactions: a machine learning approach. *Journal of Fluid Mechanics*, 938: A20.
- de Sousa Junior, W. T., Montevechi, J. A. B., de Carvalho Miranda, R. ve Campos, A. T. (2019). Discrete simulation-based optimization methods for industrial engineering problems: A systematic literature review. *Computers & Industrial Engineering*, 128: 526-540.
- Donea, J., Huerta, A., Ponthot, J.-P. ve Rodríguez-Ferran, A. (2004). Chapter 14: Arbitrary Lagrangian-Eulerian methods *The Encyclopedia of Computational Mechanics* (Vol. 1, pp. 413-437): Wiley.
- Doroszuk, B., Król, R. ve Wajs, J. (2021). Simple design solution for harsh operating conditions: redesign of conveyor transfer station with reverse engineering and DEM simulations. *Energies*, 14(13): 4008.
- Ercan, U. (2012). Modeling of cylindrical helical sieve. (MSc Thesis), Çukurova University, Institute of Science and Technology. Retrieved from <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp> Available from YÖK National Thesis Centre (318706).
- Eren, Y. ve Küçükdemiral, İ. (2024). A comprehensive review on deep learning approaches for short-term load forecasting. *Renewable and Sustainable Energy Reviews*, 189: 114031.
- Gelnar, D. ve Zegzulka, J. (2019). Discrete element method in the design of transport systems. *Verification and Validations of 3D models. Switzerland*: 5-15.
- Hagan, M. T. ve Behr, S. M. (1987). The time series approach to short term load forecasting. *IEEE transactions on power systems*, 2(3): 785-791.
- He, T. (2024). Stock returns prediction: Comparison between ARIMA and support vector regression *Exploring the Financial Landscape in the Digital Age* (pp. 371-376): CRC Press.
- Heydari, P., Khaloozadeh, H. ve Heydari, A. (2009). Gyroscope random drift modeling, using neural networks, fuzzy neural and traditional time-series methods. *Journal of Aerospace Science and Technology*, 6(1): 35-44.
- Hossein, F., Errigo, M., Cheng, S., Materazzi, M., Lettieri, P., Arcucci, R., et al. (2024). Acoustic emission and machine learning algorithms for particle size analysis in gas-solid fluidized bed reactors. *Particuology*.
- Hyndman, R. J. ve Athanasopoulos, G. (2021). Forecasting: Principles and practice. (3rd edition ed.). Melbourne, Australia: OTexts.
- Islam, M. S., Larpruenrudee, P., Rahman, M. M., Li, G., Husain, S., Munir, A., et al. (2024). Pharmaceutical aerosol transport in airways: A combined machine learning (ML) and discrete element model (DEM) approach. *Powder Technology*, 448: 120271.
- Jadidi, B., Ebrahimi, M., Ein-Mozaffari, F. ve Lohi, A. (2024). Analysis of cohesive

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

- particles mixing behavior in a twin-paddle blender: DEM and machine learning applications. *Particuology*, 90: 350-363.
- Jauregui-Correa, J. C. (2023). Forecasting the dynamic response of rotating machinery under sudden load changes. *Machines*, 11(9): 857.
- Jiang, Y., Chen, X., Kolehmainen, J., Kevrekidis, I. G., Ozel, A. ve Sundaresan, S. (2021). Development of data-driven filtered drag model for industrial-scale fluidized beds. *Chemical Engineering Science*, 230: 116235.
- Jiang, Y., Kolehmainen, J., Gu, Y., Kevrekidis, Y. G., Ozel, A. ve Sundaresan, S. (2019). Neural-network-based filtered drag model for gas-particle flows. *Powder Technology*, 346: 403-413.
- Kacar, İ. (2023). Mekanik tasarım ve analizin bilimsel esasları. (1 ed.). Ankara: Akademisyen Kitabevi.
- Kacar, İ. ve Korkmaz, C. (2021). Döner tamburlu kurutucularda gübre kurutma simülasyonu. *Tarım Makinaları Bilimi Dergisi*, 17(3): 94-100.
- 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.
- Kelley, J. ve Hagan, M. T. (2024). Comparison of neural network NARX and NARMAX models for multi-step prediction using simulated and experimental data. *Expert Systems with Applications*, 237: 121437.
- Khan, F. M. ve Gupta, R. (2020). ARIMA and NAR based prediction model for time series analysis of COVID-19 cases in India. *Journal of Safety Science and Resilience*, 1(1): 12-18.
- Kochkov, D., Smith, J. A., Alieva, A., Wang, Q., Brenner, M. P. ve Hoyer, S. (2021). Machine learning-accelerated computational fluid dynamics. *Proceedings of the National Academy of Sciences*, 118(21): e2101784118.
- Korkmaz, C. (2022). Organomineral gübre üretim işlemindeki kurutma tamburuna yönelik işletme parametrelerinin geliştirilmesi üzerine araştırmalar. (Ph.D. Thesis), Çukurova Üniversitesi, Fen Bilimleri Enstitüsü Tarım Makineleri ve Teknolojileri Mühendisliği Ana Bilim Dalı. Retrieved from <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp> (776730).
- Korkmaz, C. (2023). The place of organic and organomineral fertilizer production in sustainable agriculture. In A. Bayat (Ed.), *Sustainable Agriculture Technologies – II* (1 ed., Vol. 244, pp. 184-206). Golbasi, Adiyaman: İksad. doi: 10.5281/zenodo.10370827.
- 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). Time-series prediction of organomineral fertilizer moisture using machine learning. *Applied Soft Computing*, 165: 112086.
- Larose, D. T. ve Larose, C. D. (2014). *Discovering knowledge in data: an introduction to data mining*. (Vol. 4): John Wiley & Sons.
- Lawrence, M., Goodwin, P., O'Connor, M. ve Önkol, D. (2006). Judgmental forecasting: A review of progress over the last 25 years. *International Journal of forecasting*, 22(3): 493-518.
- Le, D., Nguyen, L., Phung, T., Howard, D., Kahandawa, G., Murshed, M., et al. (2024). Machine learning accelerated prediction of 3d granular flows in hoppers. Paper presented at the International Conference on Artificial Neural Networks.
- Li, D., Wang, R., Zhu, Y., Chen, J., Zhang, G. ve Wu, C. (2024). Calibration of simulation parameters for fresh tea leaves based on the discrete element method. *Agriculture*, 14(1): 148.
- Li, G., Liiu, M. ve Dong, M. (2010). A new online learning algorithm for structure-adjustable extreme learning machine. *Computers & Mathematics with Applications*, 60(3): 377-389.

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

- Londhe, D. H., Nalawade, S. M., Pawar, G. S., Atkari, V. T. ve Wandkar, S. V. (2013). Grader: A review of different methods of grading for fruits and vegetables. *Agricultural Engineering International: CIGR Journal*, 15(3): 217-230.
- Lu, L., Gao, X., Dietiker, J.-F., Shahnam, M. ve Rogers, W. A. (2021). Machine learning accelerated discrete element modeling of granular flows. *Chemical Engineering Science*, 245: 116832.
- Majka, M. (2024). Seasonal time series analysis: Why SARIMA outshines ARIMA. Retrieved 24.12.2024, 2024
- Martignoni, A., Iorio, L. ve Strano, M. (2024). Determination of discrete element method (DEM) simulation parameters for polymeric waste particles. *Granular Matter*, 26(4): 104.
- Nath, B., Chen, G., O'Sullivan, C. M. ve Zare, D. (2024). Research and technologies to reduce grain postharvest losses: A review. *Foods*, 13(12): 1875.
- Okudan, A. (2020). Rocky DEM ayırık elemanlar çözücü ile partikül taşıma analizleri. from <https://learning.numesys.com.tr/me/courses/35831/>.
- Olmedo, M. T. C., Mas, J. F. ve Paegelow, M. (2018). The simulation stage in LUCC modeling. (M. T. C. Olmedo, M. Paegelow, J. F. Mas & F. Escobar Eds.): Springer International Publishing.
- Pinkus, A. (1999). Approximation theory of the MLP model in neural networks. *Acta numerica*, 8: 143-195.
- Rangel, R. L., Gimenez, J. M., Oñate, E. ve Franci, A. (2024). A continuum–discrete multiscale methodology using machine learning for thermal analysis of granular media. *Computers and Geotechnics*, 168: 106118.
- Rindell, J. (2024). Exploring the utilization of neural networks in Forex market forecasting: a comparative analysis of nonlinear autoregressive neural network and autoregressive integrated moving average. (Bachelors Thesis), LUT University, LUT-yliopisto PL 20 53851 Lappeenranta. Retrieved from <https://lutpub.lut.fi/handle/10024/166809>
- Sainbhi, A. S., Vakitbilir, N., Gomez, A., Stein, K. Y., Froese, L. ve Zeiler, F. A. (2024). Time-Series autocorrelative structure of cerebrovascular reactivity metrics in severe neural injury: An evaluation of the impact of data resolution. *Biomedical Signal Processing and Control*, 95: 106403.
- Sarairoh, M. (2024). Enhancing unsteady heat transfer simulation in porous media through the application of convolutional neural networks. *Engineering Research Express*, 6(1): 015516.
- Schober, P., Boer, C. ve Schwarte, L. A. (2018). Correlation coefficients: appropriate use and interpretation. *Anesthesia & analgesia*, 126(5): 1763-1768.
- The MathWorks Inc. (2022). MATLAB version: 9.13.0 (R2022b). Natick, Massachusetts:: The MathWorks Inc. Retrieved from <https://www.mathworks.com>.
- Thon, C., Böttcher, A.-C., Möhlen, F., Yu, M., Kwade, A. ve Schilde, C. (2022). Multi-modal framework to model wet milling through numerical simulations and artificial intelligence (part 1). *Chemical Engineering Journal*, 449: 137794.
- Tian, Y., Zeng, Z. ve Xing, Y. (2024). A review of discrete element method applications in soil–plant interactions: Challenges and opportunities. *Agriculture*, 14(9): 1486.
- Tiwari, S., Kumaraswamidhas, L. ve Garg, N. (2022). Comparison of SVM and ARIMA model in time-series forecasting of ambient noise levels. Paper presented at the Advances in Energy Technology: Select Proceedings of EMSME 2020.
- Tyralis, H. ve Papacharalampous, G. (2024). A review of predictive uncertainty estimation with machine learning. *Artificial Intelligence Review*, 57(4): 94.
- Ugurluay, S. ve Akcali, I. D. (2021). Development of a vibrationless sorting system. *Spanish journal of agricultural research*, 19(1): 204.
- Urang, J. G., Ebong, E. D., Akpan, A. E. ve Akaerue, E. I. (2020). A new approach for porosity and permeability prediction from well logs using artificial neural network and curve fitting techniques: A case study

İç Yer Fıstığı Sınıflama Makinesinin Ayırık Elemanlar Simülasyonundan Elde Edilen Sürtünme Verisinin Doğrusal Olmayan Oto-Gerilemeli Ağ ile Modellenmesi

- of Niger Delta, Nigeria. *Journal of Applied Geophysics*, 183: 104207.
- Walch, M., Neubauer, M. ve Schildorfer, W. (2023). Floating car data-based short-term travel time forecasting with deep recurrent neural networks incorporating weather data. *Journal of Transportation Engineering, Part A: Systems*, 149(6): 04023035.
- Wang, B. (2020). Analysis of drop point track of ping pong ball after hitting based on dynamic analysis. *The International Journal of Multiphysics*, 14(2): 193-202. doi: 10.21152/1750-9548.14.2.193.
- Wang, M., Kumar, K., Feng, Y., Qu, T. ve Wang, M. (2024). Machine learning aided modeling of granular materials: A review. *Archives of Computational Methods in Engineering*: 1-38.
- Wang, X., Tian, H., Xiao, Z., Zhao, K., Li, D. ve Wang, D. (2024). Numerical simulation and experimental study of corn straw grinding process based on computational fluid dynamics-discrete element method. *Agriculture*, 14(2): 325.
- Xie, Y., Franz, E., Chu, M. ve Thuerey, N. (2018). Tempogan: A temporally coherent, volumetric gan for super-resolution fluid flow. *ACM Transactions on Graphics (TOG)*, 37(4): 1-15.
- Yeom, S. B., Ha, E.-S., Kim, M.-S., Jeong, S. H., Hwang, S.-J. ve Choi, D. H. (2019). Application of the discrete element method for manufacturing process simulation in the pharmaceutical industry. *Pharmaceutics*, 11(8): 414.
- Yu, J., Wang, S., Luo, K. ve Fan, J. (2024a). CFD-DEM modeling of dense gas-solid reacting flow in the framework of GPU. *Chemical Engineering Journal*, 484: 149480.
- Yu, J., Wang, S., Luo, K. ve Fan, J. (2024b). GPU-accelerated discrete element simulation of granular and gas-solid flows. *Powder Technology*, 437: 119475.
- Zhang, S. ve Ge, W. (2024). Accelerating discrete particle simulation of particle-fluid systems. *Current Opinion in Chemical Engineering*, 43: 100989.
- Zhang, S., Jia, X., Dong, J., Wang, X., Zhao, H., Chen, X., et al. (2024). Optimization of operating angles of disc coulters for maize residue management using discrete element method. *Computers and Electronics in Agriculture*, 218: 108691.
- Zhao, Z., Zhou, L., Bai, L., Wang, B. ve Agarwal, R. (2024). Recent advances and perspectives of CFD-DEM simulation in fluidized bed. *Archives of Computational Methods in Engineering*, 31(2): 871-918.