

Zaman Serisinin Kestirimi İçin Uzun-Kısa Süreli Bellek Ağı Yaklaşımı

Cem KORKMAZ^{1,a}, İlyas KACAR^{2,b}

¹Çukurova Üniversitesi, Ziraat Fakültesi, Tarım Makineleri ve Teknolojileri Mühendisliği Bölümü, Adana
²Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, Niğde

^aORCID: 0000-0003-1062-4581; ^bORCID: 0000-0002-5887-8807

Makale Bilgileri

Geliş : 15.07.2024

Kabul : 23.12.2024

DOI: 10.21605/cukurovaumfd.1606138

Sorumlu Yazar

Cem KORKMAZ

ckorkmaz@cu.edu.tr

Anahtar Kelimeler

Fıstık sınıflandırma

Ayrık eleman yöntemi

Modelleme

Uzun kısa süreli bellek

Kestirim

Öz
Uzun-kısa süreli bellek (LSTM) ağı, zaman içinde bilgileri depolayan ve unutan bellek hücrelerinden oluşmakta, uzun vadeli bağımlılıkları yakalamaktadır. LSTM'de sıralı işleme yeteneği, tekrarlayan bağlantılarla elde edilmektedir. LSTM, zaman serisi analizi, doğal dil işleme ve daha fazlası için uygun hâle getirilmiştir. Makine öğrenimi algoritmaları veri öğrenme ve karmaşık verilerden iç-görüler üretme konusunda etkilidir. Ayrık eleman yöntemi (AEY) ise taneli malzemelerin davranışını simüle etmek için güçlü hesaplama yöntemidir. AEY tarım ve gıda işleme gibi birçok endüstride, tanecikli eleman akış analizi ve optimizasyon amaçlı kullanılmaktadır. Bu çalışmada yer fıstığının sınıflandırılması için AEY esaslı simülasyon yapılmıştır. Zamana bağlı sürtünme kuvveti verisi toplanmıştır. Tane-duvar sürtünme verisi üzerinde LSTM kullanarak simülasyonlardan daha hızlı bir biçimde sürtünme kestirimi ve bu suretle de ekonomik ve kalite kayıplarını azaltmak amaçlanmıştır. Çalışmada modelin R değeri 0,857 olarak bulunmuştur. Ortalama mutlak hatanın yüzdesi ise % 2,326 olarak bulunmuştur. 300 adet iterasyon yapılmış ve hesaplamalar 37,934 saniye sürmüştür. Ağdan elde edilen veri ile seri arasında yüksek doğrulukta bir ilişki görülmüştür. LSTM ağı veriye bir ön işlem gereksinimini ortadan kaldırmıştır. Çalışmada kullanılan ağ, ağı parametreleri ve bu ağı kestirimi çalışmada verilmiştir.

Long-Short Term Memory Network Approach for Time Series Prediction

Article Info

Received : 15.07.2024

Accepted : 23.12.2024

DOI: 10.21605/cukurovaumfd.1606138

Corresponding Author

Cem KORKMAZ

ckorkmaz@cu.edu.tr

Keywords

Peanut classification

Discrete element method (DEM)

Modelling

Long-short term memory (LSTM)

Prediction

How to cite: KORKMAZ, C., KACAR, İ., (2024). Zaman Serisinin Kestirimi İçin Uzun-Kısa Süreli Bellek Ağı Yaklaşımı. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(4), 1053-1066.

ABSTRACT

The long-short-term memory (LSTM) network consists of memory cells that store and forget information over time, capturing long-term dependencies. LSTM sequential processing capabilities are achieved through recurrent connections. LSTM has been made suitable for time series analysis, natural language processing and more. Machine learning algorithms are effective in learning data and generating insights from complex data. The discrete element method (DEM) is a powerful computational method for simulating the behaviour of granular materials. DEM is used in many industries such as agriculture and food processing and is used in particle flow analysis and optimisation. In this study, DEM-based simulation is performed for peanut classification. Time dependent friction force data are collected. By using LSTM on particle-wall friction data, it is aimed to predict friction faster than simulations and thus reduce economic and quality losses. In the study, the R -value of the model is found to be 0,857. The percentage of the average absolute error was found to be 2,326%. 300 iterations were performed and the calculations took 37,934 seconds. A high accuracy relationship was observed between the data obtained from the network and the series. The LSTM network eliminated the need for pre-processing the data. The network used in the study, the parameters of the network and the estimation of this network are given in the study.

1. GİRİŞ

Modelleme, bilim ve endüstride sıklıkla kullanılan kadim araçlardan biridir. Temel olarak, matematikteki fonksiyonların belirli bir amaca yönelik uygulanmasıdır. Modelleme kavramını açıklarken, Türkçe'de "kestirim, tahmin, iç-görü, sanı, zan, sezgi, çıkarım, niyet okuma, kehanet" gibi ifadeler kullanılabilir [1]. Modelleme yapabilmek için eğri uydurma, simülasyon ve yapay zekâ (YZ) esaslı yöntemlerden yararlanılmaktadır. YZ yöntemleri, karmaşık sistemlerin analiz edilmesi, modelleme-kestirim doğruluğunun artırılması ve süreçlerin optimize edilmesi için temel araçlar sağlamaktadır.

Makine öğrenimi (ML, machine learning) çeşitli sektörlerde kullanım potansiyeli nedeniyle önemli bir ilgi ve tanınırlık kazanmıştır. ML, açıkça programlama gerektirmeden, verilerden yüksek performanslı öğrenme sağlayan YZ'nin bir alt kümesidir. ML algoritmaları, istatistiksel teknikler ve algoritmalar kullanarak örüntüleri otomatik olarak tanımlayabilmekte, kestirimlerde bulunabilmekte, karmaşık ve büyük veri kümelerinden iç-görüler üretebilmektedir. Evrişimli sinir ağları (CNN, convolutional neural network) ve tekrarlayan sinir ağları (RNN, recurrent neural network) gibi derin öğrenme yöntemleri, son yıllarda ML alanında kritik bir rol oynamıştır. Bu teknikler, karmaşık veri yapılarının işlenmesi ve anlamlandırılmasında güçlü araçlar olup görsel algıdan doğal dil işlemeye kadar birçok uygulama alanında çığır açan ilerlemelere olanak tanımıştır [2]. Takviyeli öğrenme algoritmaları, deneme-yanılma yaklaşımıyla karmaşık görevleri öğrenerek otonomi alanında önemli başarılar göstermiştir [3]. Bu yöntem, özellikle oyun, robotik ve endüstriyel otomasyon gibi alanlarda geniş bir uygulama yelpazesine sahiptir. Transfer öğrenimi ise bir ML görevinden elde edilen bilginin başka bir göreve aktarılmasını mümkün kılarak eğitim sürecini hızlandırmakta ve sonuçların doğruluğunu artırmaktadır. Bu yaklaşımlar, modern YZ araçlarının temelini oluşturmaktadır.

Uzun kısa süreli bellek (LSTM, long-short term memory) ağı, derin öğrenme özelliğine sahip bir ML yöntemidir. LSTM'nin sıralı işleme yetenekleri, bilginin farklı zaman adımları arasında akmasını sağlayacak tekrarlı bağlantılar yoluyla. Bu benzersiz mimari, LSTM'nin bilgileri uzun süreler boyunca etkili bir şekilde işlemesini ve saklamasını sağlayarak onu zaman serisi analizi, doğal dil işleme başta olmak üzere pek çok görevler için uygun hâle getirmektedir. LSTM'nin zaman serisi üzerinde kestirim ve normal olmayan durumların tespitinde etkili olduğu kanıtlanmıştır. Uzun vadeli bağımlılıkları yakalama yeteneği, borsa, enerji tüketimi ve hava durumu gibi alanlarda doğru kestirimlerin yapılmasını sağlamaktadır [4]. Araştırmacılar çeşitli uzantılar ve modifikasyonlar önererek LSTM'nin yeteneklerini geliştirmeye devam etmektedir. Ayrıca, hibrit model yaklaşımlarında, farklı modellerin güçlü yanlarını bir araya getirmek amacıyla LSTM yöntemi, CNN gibi diğer derin öğrenme mimarileriyle birleştirilmektedir. Bu yaklaşım, LSTM'nin zamansal bağımlılıkları yakalama yeteneği ile CNN'lerin uzaysal özellikleri çıkarılabilir kapasitesini bir arada kullanarak daha güçlü ve kapsamlı bir öğrenme modeli oluşturmayı sağlamaktadır.

Ayrık elemanlar yöntemi (AEY), taneli malzemelerin davranışını hesaplamak için güçlü bir yöntemdir. İlk olarak 1979 yılında Cundall ve Strack tarafından geliştirilmiştir [5]. Tanecikli malzemeler; temas kuvvetleri aracılığıyla etkileşime giren ayrık parçacıkların oluşturduğu bir yığın olarak ele alınmaktadır. Parçacık-parçacık, parçacık-duvar, parçacık-akışkan etkileşimlerinin hesaplanmasına olanak tanımakta ve tek tek parçacıkların hareketini takip etmektedir. AEY esaslı simülasyonlar, parçacıklar arasındaki temasları temsil etmek için temaslı-temassız etkileşim modelleri kullanılmaktadır. Doğrusal yay-damper, doğrusal olmayan kuvvet ve Van der Waals kuvveti, sıvı köprü kuvveti ve elektrostatik kuvvet, adheziif-kohezif kuvvet modelleri dâhil olmak üzere çeşitli etkileşim modelleri geliştirilmiştir [6]. Bu modeller parçacık kırılması, kohezyon ve sürtünme gibi gerçek dünya olaylarının simülasyonunu mümkün kılmaktadır. Bilim camiasında bazı kesimler, yapay öğrenme yöntemlerinin sadece deneysel veri üzerinde uygulanması gerektiğini savunsa da, simülasyon ile üretilen veri üzerinde de yapay öğrenme yapılabilir. Böylece çok uzun hesaplama zamanı alan simülasyonlar yerine daha kısa sürede kestirim yapılması mümkün olabilmektedir [7,8].

Yer fıstığı endüstrisi, yer fıstığı ve yer fıstığı bazlı ürünlere yönelik artan talebi karşılayarak küresel tarım sektöründe önemli bir rol oynamaktadır [9]. Yer fıstığı sınıflamada AEY esaslı simülasyonlar; fıstık tanelerinin yığın hareketinin dinamik davranışını belirlemektedir. Tanelerin birbirleri ve yüzeyle her türlü etkileşimlerinin belirlenmesinde, tüm gerçek şartları oluşturma imkânı vermektedir. Geleneksel eleme işlemlerinde elekler düzdür ve ağır metal gövdelerine titreşim hareketi verilerek çalıştırılmaktadır. Ancak, bu çalışma yüksek enerji tüketimine neden olmaktadır. Buna rağmen, büyük sınıflandırma yüzeyine sahip oldukları için daha yüksek üretim kapasiteleri ile endüstride yaygın olarak kullanılmaktadır. Enerji

kullanımının azaltılması amacıyla, daha az enerji tüketen sınıflandırma yöntemleri üzerine araştırmalar sürdürülmektedir. Bu bağlamda, enerji verimliliği açısından önemli bir alternatif olarak, iç fıstık gibi ürünlerin sınıflandırılması için silindirik eleklerin kullanılması öne çıkmaktadır. Bu elekler, geleneksel elek sistemlerine kıyasla çok daha düşük enerji tüketimi sunarak, hem enerji tasarrufu hem de sınıflandırma işlemlerinin etkinliğini artırmayı hedeflemektedir.

Mevcut çalışmalar ışığında; tarım, gıda, katı atıklar vb. ürünlerin çeşitli davranışlarının modellenmesi ve kestirimi konularında açık literatürde pek çok çalışmanın olduğu, pek çok alanda ML tekniklerinin başarı ile uygulandığı, ancak fıstık sınıflandırmada işlem parametrelerinin modellenmesinde nadiren ML kullanıldığı görülmüştür. Bu konuda bir araştırma boşluğu bulunmaktadır. Böylece ML yöntemlerinin fıstık sınıflandırmada, sürtünme kuvvetinin kestiriminde de kullanım potansiyeline sahip olabileceği hipotezi ortaya atılarak, konunun incelenmesine karar verilmiştir.

Bu çalışmada bir silindirik eleğin gerçek işletme şartlarına uygun olarak Ansys Rocky DEM© ticari programı ile AEY esaslı simülasyonu gerçekleştirilmiştir. Simülasyon sonunda tane-elek arasındaki zamana bağlı sürtünme kuvveti verisi elde edilmiştir. Sürtünme, fıstık tanelerinin duvar yüzeyinden kayması, böylece sınıflama verimi ve elek metalinin aşınması-değişim sıklığı üzerinde temel etkenlerdendir. Zira aşınmış bir elek, deliklerde takılı kalan taneler nedeni ile verimi düşürmekte, tane kırılmalarına neden olmaktadır. Sürtünme kuvvetinin, bir derin öğrenme yöntemi olan LSTM ağı ile modellenmesi ve kestirim performansı araştırılmıştır. LSTM sayesinde birincil olarak tane-duvar sürtünme kuvveti hızlı ve doğru bir biçimde kestirilebilmekte, ikincil olarak da isabetli kestirim sayesinde üretim sürecine erken müdahale için kestirimci-bakım yapılması mümkün olmakta, böylece daha ekonomik bir süreç elde edilmekte ve kalite kayıplarının önüne geçilebilmektedir.

2. YÖNTEM

2.1. Fıstık Sınıflandırma Esnasında Net Kuvvet

Bu çalışmada, Çukurova Üniversitesi Ziraat Fakültesi'nde bulunan ve Şekil 1'de gösterilen fıstık sınıflandırma (boylama, tasnif, eleme, ayıklama, derecelendirme) makinasının simülasyonu yapılmıştır. Sürtünme kuvvetinin (teğetsel temas kuvveti) oluşmasına yol açan hususlar başta tane-elek duvarı arası sürtünme katsayısı ve dik kuvvettir. Teğetsel doğrultudaki net kuvvetin, verilen makine şekline göre nasıl hesaplanacağı bu bölümde izah edilmiştir. Kuvvetin hesaplanmasıyla birlikte tork, bu tork kullanılarak güç ve güç kullanılarak enerji hesaplanabilecektir.




Şekil 1. Simülasyonu yapılan fıstık tasnif makinası

Yüksek verim, tanelerin elek yüzeyi üzerinde tek tabakalı dağılması durumunda elde edilse de, gözlemler, silindirin iç yüzeyindeki tanelerin tek tabakalı akışının, eleğin dönme hareketi esnasında, korunamayacağını göstermektedir. Sürtünme hesabı aşağıdaki varsayımlar ile birlikte yapılmıştır [10].

- Tanecikli malzeme tabakası, iyi tanımlanmış yollar (dairesel veya sarmal) boyunca tane dizilerinden oluşmaktadır.

- Tanecikli malzeme tabakası, silindirin iç yüzeyini sürekli olarak kaplamaktadır.
- Tabaktaki tüm bitişik diziler, ihmal edilebilecek kadar küçük bağıl harekete sahiptir. Bu nedenle, komşu diziler arasındaki tane-tane sürtünme kuvvetleri göz ardı edilebilmektedir.



Şekil 2. Silindirik elek içinde, fıstık kümesinin (a) dairesel ve (b) sarmal hareketine dair serbest cisim diyagramları [11]

İyi tanımlanmış yollardan biri "dairesel", diğeri ise "sarmal" yoldur. Öncelikle dairesel bir yol boyunca hareket incelenecektir. Şekil 2-a'ya bakıldığında, Newton'un ikinci yasası, sonsuz küçük bir dm kütlesi üzerine uygulandığında, kayan bu kütle için aşağı doğru ivmesi, $\ddot{s} = g \sin \alpha - g \mu_d \cos \alpha - \omega^2 r \mu_d$ olacaktır. Burada s silindirin tabanından itibaren yay uzunluğu, ω açısal hız, r silindirik elek yarıçapı, μ_d fıstık-elek arası sürtünme katsayısı, α eleğin dönme açısı ve g ise yerçekimi ivmesidir. Tabaka kalınlığı, eleğin en alt noktasında en büyük ve yukarı doğru en küçük olmak üzere doğrusal olarak değişmektedir ve $h(s) = h_0 - \frac{h_0 - e}{r\beta} s$ denklemi ile hesaplanmaktadır. Burada h_0 ve e sırasıyla elek duvarındaki tabakanın maksimum ve minimum yükseklikleri, β ise bu yayı oluşturan açıdır. Yay uzunluğu s , ve açısal konum α arasındaki ilişki $s = r\alpha$ olup bu durumda tabaka kalınlığı $h(\alpha) = e \left[n - (n-1) \frac{\alpha}{\beta} \right]$ veya $h(s) = e \left[n - \frac{(n-1)}{r\beta} s \right]$ olarak da hesaplanabilmektedir. Burada n , tanecikli malzemenin tabaka sayısı olup $n = \frac{h_0}{e}$ ile hesaplanmaktadır. α açısal konumunda, eleğin birim uzunluğu başına düşen tabakanın sonsuz küçük kütlesi $dm = \rho h r d\alpha$ olarak ifade edilmektedir. Burada ρ tanecik yığınının yoğunluğudur. Eleğin iç yüzeyini kapladığı varsayılan tanecikli malzeme tabakası β açısında dengeye gelecektir, Şekil 2-a'daki serbest cisim diyagramına göre, teğetsel doğrultudaki denge denklemi, $F_{net} = \int_0^\beta \ddot{s} dm = 0$ biçiminde yazılabilecektir. Burada F_{net} teğetsel doğrultudaki toplam kuvvet olup tabakayı teğetsel yörüngede aşağı doğru hareket ettirmektedir. Terimler yerine yazılırsa ve integrasyon 0 ve β açıları arasında yapılırsa $F_{net} = \frac{1}{2} \rho r \left[\left(\frac{h_0 - e}{\beta} \right) (-2g\mu_d + r\omega^2\beta^2\mu_d + 2g(\beta + \mu_d)\cos\beta + 2g(\beta\mu_d - 1)\sin\beta - 2(r\omega^2\beta\mu_d - g + g\cos\beta + g\mu_d h_0 \sin\beta) \right]$ olacaktır. Elde edilen bu denklem, tabaka sayısı n ve β açısının bir fonksiyonu olarak ifade edilirse de $F(\beta) = g[\beta(n - \cos\beta) - (n-1)\sin\beta] - g\mu_d[\beta\sin\beta + (n-1)(1 - \cos\beta)] - \frac{1}{2}r\mu_d\omega^2\beta^2(1+n) = 0$ olacaktır. $F(\beta) = 0$ denkleminin analitik bir çözümü yoktur. Kökünü bulmak için sayısal bir yöntem gerekmektedir. Bununla birlikte, küçük β açısı için yaklaşık bir başlangıç çözümü (kökü) $\beta = 2\mu_d \left[1 + \frac{1}{2}(1+n) \frac{r\omega^2}{g} \right]$ olmaktadır. Tabakanın ağırlık merkezinin konumu θ_* olmak üzere $\int_0^\beta r g \sin \alpha dm = r g \sin \theta_* m$ ifadesi kullanılarak θ_* hesaplanabilmektedir. Tabakanın birim külesinin, elek eksenine etrafında dönerken, $0-\beta$ açıları arasında oluşturduğu moment T_0 olup bu moment $T_0 = \int_0^\beta r g \sin \alpha dm$ ile hesaplanabilmektedir. İfadeler yerlerine yazıldığında tork formülü $T_0 = g e r^2 \left[n(1 - \cos\beta) + (n-1)r\cos\beta - (n-1) \frac{r}{\beta} \sin\beta \right]$ biçiminde olacaktır. Ayrıca, gereken güç $G = T_0 \omega$ ile ve t_0 ile t_n zaman aralığında tüketilen enerji ise $E = \int_{t_0}^{t_n} G dt$ ile hesaplanacaktır.

Tane tabakanın sarmal bir yol boyunca hareket ettiği durum Şekil 2-b'de verilmiştir. Silindir eksenine sarmal yol arasındaki helis açısı φ ve bunun tümler açısı φ' ile gösterilmektedir. Newton'un ikinci yasası, sarmal yüzeyindeki dm kütle üzerine uygulanırsa, kayan elemanın teğetsel doğrultudaki ivmesi $\ddot{s}(\alpha) = g \sin \alpha (\cos \varphi - \mu_h \sin \varphi) - g \mu_d \cos \alpha - \omega^2 r \mu_d$ olacaktır. Burada μ_h ifadesi tanecik ile helison arasındaki sürtünme katsayısıdır. Teğetsel doğrultudaki denge denkleminde yerine yazılırsa, toplam kuvvet $F_{net} =$

$\frac{\rho r e}{\beta} \left[(1 + n(\beta - 1)) \left(g(\cos\varphi - \mu_n \sin\varphi)(\sin\beta - \beta \cos\beta) + \left(g - \frac{1}{2} r \omega^2 \beta^2 - g \cos\beta - g \beta \cos\beta \right) \mu_d \right) \right] = 0$ olacaktır. Bu denklemin analitik bir çözümü yoktur, ancak küçük β açıları için teknik anlamı ile kökü $\beta = \frac{\mu_d(n+1)}{\cos\varphi - \mu_n \sin\varphi} \left[1 + \frac{r\omega^2}{g} \right]$ olacaktır. Tabakanın birim kütesinin, birim zamandaki hareketi sonunda tabakanın akış hızı $\frac{dm}{dt} = \int_0^\beta r \rho h V_z d\alpha$ ile hesaplanmaktadır. İntegrasyon gerçekleştirilirse $\frac{dm}{dt} = e^{\frac{n+1}{2}} r \rho \beta V_z$ olacaktır. Makinenin performansını değerlendirmek için kullanılan önemli bir işletme parametresi verim olup iki boylu bir sınıflandırma hâlinde $\eta = r_K r'_K \eta_K + r_B r'_B \eta_B$ ile hesaplanabilmektedir. Burada $r_B = \frac{K}{T}$ ve $r'_B = \frac{B}{K_B + B}$ ve $\eta_K = \frac{K'}{K}$ ve $\eta_B = \frac{B'}{B} = 1$ olarak verilmiştir. Burada K ve B sırasıyla sınıflandırılacak küçük ve büyük boylu malzeme miktarını temsil etmektedir.

2.2. Ayrık Eleman Yöntemi (AEY)

AEY'nin esası, denge denklemlerini kullanarak parçacığın yörüngesini hesaplamaktır [12]. Bu denklemler Newton'un ikinci hareket yasasına, açılal momentumun korunumuna ve d'Alembert ilkesine dayanmaktadır (Eşitlik 1). Her ikisi de adi diferansiyel denklemlerdir.

$$m_i \frac{dv_i}{dt} = \sum_j (F_{n,ij} + F_{t,ij}) + m_i g + F_{f \rightarrow p} \quad (1-a)$$

$$I_i \frac{d\omega_i}{dt} = \sum_j (M_{t,ij} + M_{r,ij}) + M_{f \rightarrow p} \quad (1-b)$$

Burada i, j parçacık numarası, g yerçekimi ivmesi, m kütle, I parçacığın kütsel eylemsizlik momentidir. n ve t sırasıyla normal ve teğetsel doğrultulardır. v ve ω sırasıyla parçacığın doğrusal ve açılal hız vektörüdür. $F_{f \rightarrow p}$ ve $M_{f \rightarrow p}$ terimleri ise CFD-AEY müşterek çalışması durumunda parçacık-akışkan etkileşiminden hâsil olan sırasıyla kuvvet ve momenttir. Bu çalışmada müşterek 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. $M_{r,ij}$ torkunun doğrultusu, dönme hızı doğrultusu ile aynı ancak ters yöndedir. Normal kuvvet ise parçacık dönüşüne katkıda bulunmaz.

Bir çarpışma olayı bir dizi temastan oluşmaktadır. Bir temas *yumuşak* veya *sert küre* yaklaşımları kullanılarak modellenilebilmektedir. Sert küre yönteminde, parçacıklar rijittir ve temasta herhangi bir deformasyon görülmemektedir. İkili temas esnasında hareket ve enerji kaybını hesaplamak için, temas kuvvetleri yerine, sıçrama katsayıları ve şok yasaları kullanılmaktadır. Çoklu temasa izin verilmemektedir. Yumuşak küre yönteminde ise temas esnasında parçalıklarda oluşacak deformasyon "üst üste binme" olarak modellenmektedir. Parçacık-parçacık ve parçacık-duvar teması hâlinde etki eden temas kuvvetini hesaplamak için temas modelleri kullanılmaktadır. Buna ek olarak, Van der Waals kuvveti, sıvı köprü kuvveti ve elektrostatik kuvvet gibi temassız kuvvetler de gerekirse her iki yöntemde de tanımlanabilmektedir.


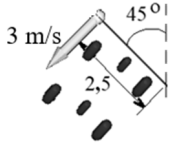
2.3. AEY Esaslı Simülasyon ve Sürtünme Verisi Eldesi

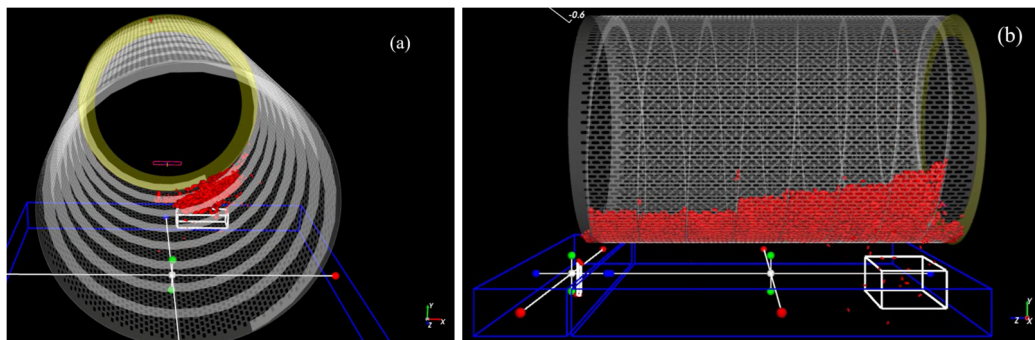
AEY esaslı simülasyon için Ansys Rocky DEM© programı kullanılmıştır [6]. Yazılım; kapsamlı tane şekli kütüphaneleri, gelişmiş temas algılama algoritmaları, gelişmiş tane kırılma modelleri, dinamik ağ oluşturma, tane-akışkan etkileşimleri ve paralel hesaplama imkânları sunmaktadır [13]. Yazılımın bu gibi yetenekleri onu madencilik, ilaç, tarım, gıda, tohum ve tahıl işleme, mahsul kurutma ve toprak mekaniği gibi çok çeşitli uygulamalar için uygun hâle getirmektedir [14].

Çizelge 1'de AEY simülasyonunda kullanılan parametreler verilmiştir. Hesaplamalar ardışık zaman adımları için tekrar edilmektedir. Tane hareketinin her yeni konumu, tek zaman adımına uygulanmaktadır. 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 temsil edilmesi ve sayısal stabilitenin sağlanması için temel bir gerekliliktir. Zaman adımı ve alt adımlar, zamana bağlı diferansiyel denklemleri sayısal olarak çözen yöntemlerde, zamansal ayrıklaştırma amacıyla kullanılmaktadır. Ayrıca sistemdeki

hızlı değişimlerin, çözümde gözden kaybolmasını engellemek için ayrıklaştırmanın uygun küçük boyutta olması gerekmektedir. Her bir alt adımda hesaplanan ardışık değerler, zaman içindeki sürekliliği ve doğruluğu korumaya yardımcı olmaktadır.

Çizelge 1. AEY esaslı simülasyonda kullanılan parametreler


Enjeksiyon özellikleri	Değer	
Tane şekli	216 adet üçgen yüze sahip çok yüzlü, 	
Tane türü, malzeme	Tek bileşenli (Yer fıstığı taneleri)	
Tane malzeme davranışı	Sert küre	
Tane eşdeğeri çap dağılımları, dp (mm)	22 (100%)+7,6 (22%)	
Tane hacmi, (cm ³)	5,56	
Tane kütle akış hızı (kg/saat)	0,169	
Tanelerin enjeksiyon noktasındaki hız vektörü (m/s) ve boyutları	 Giriş yüzeyine normal	
Zaman adımı uzunluğu (s) ve alt adım sayısı (adet)	1 ve 10	
Gerçek zaman süresi (s)	60	
Simülasyon fiziği	Değer	
Normal kuvvet	Lineer yay-damper	
Teğetsel kuvvet	Coulomb sürtünme kanunu	
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 m/s ²	
Malzeme özellikleri	Tane (İç fıstık)	Duvar (çelik)
Young modülü, E (MPa)	10,11	200E3
Poisson oranı, ν	0,201	0,3
Katı yoğunluğu, ρ_s (kg/m ³)	416	7850
Yığın yoğunluğu, ρ_b (kg/m ³)	250	--
Tambur dönüş hızı (rpm)	--	10
Temas	Tane-tane	Tane-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



Şekil 3. Fıstık sınıflama makinesinin AEY esaslı simülasyonunda (a) $t=5$ s (b) $t=40$ s anında elek içerisindeki fıstık dağılımı ve sınıflandırma kutuları

Şekil 3'te eleğin simülasyonda kullanılan geometrisi ve simülasyonun çeşitli adımlardaki ekran görüntüleri verilmiştir. Şekil üzerinde, fıstık tanelerinin bölgeye aktılma şekli, girişin dikdörtgensel açıklığı ve elek altındaki iki adet biriktirme kutusu, elek içerisindeki helisel sarmallar görülmektedir.

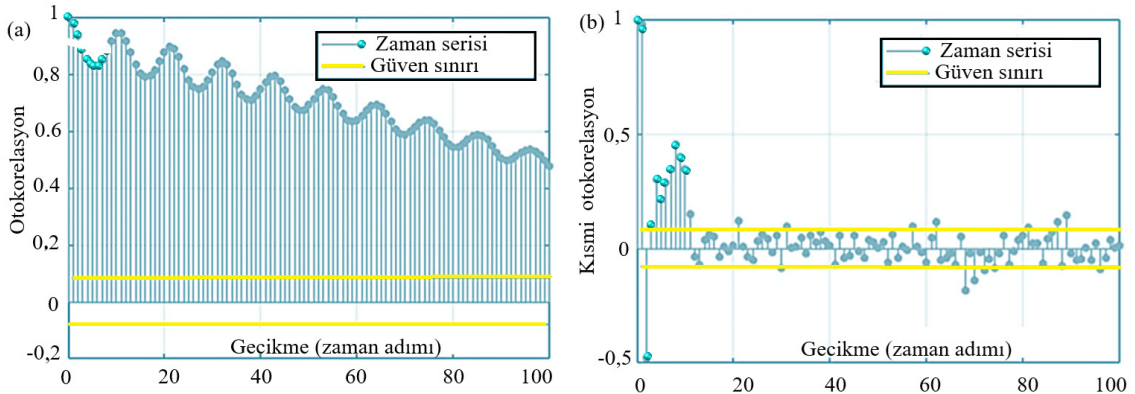
Şekil 4'te ise toplanan sürtünme kuvvetine ait zaman serisi verisi gösterilmiştir. Yatay eksen zaman adıdır. Toplam veri sayısı 600 adettir. Bu çalışma kapsamında incelenen veri kümesi, tanenin duvarla teması esnasında, sürtünme katsayısı nedeniyle oluşan zamana bağlı sürtünme kuvveti serisidir. Bu veri 60 saniyelik gerçek zamanın simülasyonu olup 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 4. Simülasyondan elde edilen temas sürtünme kuvvetinin zamanla değişimi verisi ve bölümlendirme oranı

2.4. AEY Simülasyonu ve Sürtünme Verisi Eldesi

Modellemeye başlamadan önce eldeki verinin doğasını anlamak önemlidir. Bu suretle veriye uygun model belirlemek daha kolaydır. Zaman serilerinde sıklıkla uygulanan analiz türü, zaman gecikmelerinin tayini için oto-korelasyon (OKF) ve kısmi oto-korelasyon (KOKF) grafiklerini birlikte değerlendirmek ve hipotez testleri uygulamaktır.




Şekil 5. Veriye ait (a) OKF, (b) KOKF

Zaman gecikmelerini tespit etmek için korelogramlar kullanılmıştır (Şekil 5). OKF veya KOKF değerleri birimsizdir. Gecikme ise "zaman adımı" birimindedir. Her bir pik, bir gecikmeye karşılık gelmektedir. 100 adet gecikme incelenmiş olup tespit için 2 standart sapmalılık güven sınırı esas alınmıştır. Her iki tip grafikten serideki verilerin rastgele olmadığı, kendi gecikmelerine bağlı olduğu görülmüştür. OKF pikleri giderek azalmaktadır. KOKF ise 10'uncu pikten sonra güven sınırının altında kalmaktadır (beyaz gürültü). Beyaz gürültü, gecikme üzerinde etkisiz değerlerdir. OKF'de azalma ve KOKF'de kesilme olması, otomatik gerileyen türde bir seri olduğu anlamına gelmektedir. Eğer OKF'de ani kesilme ve KOKF'de de azalma olsaydı, seri, hareketli ortalama türünde olacaktı. Buradan ilk 10 gecikmeye kadar olan ardışık değerlerin birbirleri ile yüksek ilişkili olduğu ve sonraki değerlerin birbiriyle anlamlı bir ilişkisinin olmadığı görülmüştür. Böylece bu serinin, ilk on gecikmeye bağlı, otomatik gerileyen AR(10) türünde bir seri olduğu anlaşılmıştır [15].

2.5. LSTM ile Modelleme

LSTM bir derin öğrenme yöntemidir. Her ne kadar hangi ağların, hangi verilere uygulanacağı ile ilgili herhangi bir başparmak kuralı yoksa da zaman serileri için LSTM, GRU, NAR yöntemleri kullanılmaktadır [16]. Metin içerisinde yer yer "ağ" yer yer de "model" kelimesi kullanılmıştır. Her ikisi de aynı anlamdadır. Zira bir ağın akasında fonksiyon(lar) bulunmaktadır. Bu da ağın, matematiksel bir fonksiyon olduğunu

göstermektedir. Ağlar Matlab© programı ile oluşturulmuştur [17]. Bu çalışmada oluşturulan LSTM ağıнын mimarisi Şekil 6'da verilmiştir.



Şekil 6. Çalışmada kullanılan LSTM ağ topolojisi

Bu çalışmada oluşturulan LSTM ağı dört temel tabakadan oluşmuş ve bunların özellikleri ise Çizelge 2'de verilmiştir.

Çizelge 2. LSTM ağ tabakaları ve özellikleri

Tabakalar	Tür, aktivasyon boyutu	Öğrenebilir özellik	Durum
● Bir boyutlu giriş	Sıralı giriş $1(C) \times 1(B) \times 1(T)$	—	—
● 128 adet saklı birim	LSTM $128(C) \times 1(B) \times 1(T)$	Giriş ağırlıkları (512×128), Tekrarlı ağırlıklar (512×128), Bias (512×128)	Saklı (128×1) Hücre (128×1)
● Bağlama	Tam bağlı tabaka $1(C) \times 1(B) \times 1(T)$	Ağırlıklar (1×128), Bias (1×1)	—
● MSE esaslı regresyon	Regresyon $1(C) \times 1(B) \times 1(T)$	—	—

Ağ, bir tabakalı bir derinliğe sahiptir. Ağın öğrenilebilir özelliği, ağırlıkları ve bias'tır. C, B ve T harflerinin anlamı aşağıdaki gibidir:

- C (Channels): Özellik haritasındaki kanalları (features) ifade etmektedir. LSTM'de bu genellikle hücre durumlarının veya gizli durumların boyutunu belirtmektedir. Çizelgede 128 LSTM birimi kullanıldığı için $C = 128$ olacaktır.
- B (Batch Size): Giriş verilerinin bir iterasyonda (seferde) işlendiği örnek sayısını ifade etmektedir. Mini-batch işlem sırasında kullanılan veri örneği sayısını temsil etmektedir. Çizelgede $B = 1$ olduğu gözlemlenmekte, yani her iterasyonda tüm veri işlenmektedir.
- T (Time Steps): Zaman eksenindeki adım sayısını ifade etmektedir. Zaman serisi veya ardışık veri için kullanılan veri noktalarının sayısını belirtmektedir. Çizelgede $T=1$ olup bir adet zaman serisi olduğu anlaşılmaktadır.

Sıralı giriş, $1(C) \times 1(B) \times 1(T)$ boyutlu olup tek boyutlu bir dizinin (1 kanal) işlendiğini ifade etmektedir. LSTM tabakası $128(C) \times 1(B) \times 1(T)$ boyutunda olup bu, 128 birim (hücre) kullanıldığını göstermektedir. Bu tür bir gösterim, derin öğrenme modellerinde zaman serisi veya sıralı verilerle çalışırken yaygın olarak kullanılmaktadır. LSTM ağlarının eğitimi, ağırlık ve/veya bias güncelleme esaslı olduğu için bu ağların öğrenilebilir yeteneği ağırlık ve biaslar sayesinde. LSTM, bilgileri zaman içinde seçici olarak depolayabilen ve gerektiğinde silebilen bellek hücrelerinden oluşmaktadır. Bu yapı, özellikle uzun vadeli bağımlılıkların öğrenilmesinde ve işlenmesinde etkili bir şekilde çalışmaktadır. Her bir gizli birim, dört kapı ile donatılmıştır. Bunlar bilgi akışını düzenleyen giriş kapısı, unutma kapısı, durum kapısı ve çıkış kapısı olarak adlandırılmaktadır. Ayrıca her gizli birim "saklı" ve "hücre" adında iki adet duruma da sahiptir.

Ağın hiperparametreleri ise şu biçimdedir:

- Veri bölümlenme: Eğitim % 80 (48 saniye), kestirim % 20 (12 saniye)
- 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. NN, veri sayısıdır. $p(t)$ ise ağ tarafından kestirilen değerdir. t zaman adıdır.

- Hata kriteri : $MSE = \frac{1}{NN} \sum_{t=1}^{NN} (p(t) - o(t))^2$ burada $p(t)$ değeri, t zaman adımında kestirim yapılan değerdir. $o(t)$ değeri, t zaman adımında zaman serisi verisi ve NN ise toplam veri sayısıdır. RMSE ise MSE'nin kareköküdür. MSE'nin birimi, verinin biriminin karesidir. Burada sürtünme verisi Newton (N) biriminde olduğundan dolayı MSE (N^2) biriminde olacaktır. Bu durumda RMSE ise (N) biriminde olacaktır. MAE mutlak hata ortalamasıdır. Birimi veri birimidir. MAPE, MAE'nin yüzdesidir. MSE (birim²), RMSE (birim), MAE (birim) ve MAPE (%) değerleri model başarısını ölçmede kullanılan hata metrikleridir. Bu kriterler ne kadar sifıra yakınsa modelde hata değerleri o kadar azdır. R (veya R^2) değerleri de ne kadar 1'e veya -1'e yakın ise model o kadar başarılıdır. 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 tahmin 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.

- Korelasyon katsayısı, $R = \frac{NN \sum_{t=1}^{NN} p(t)o(t) - (\sum_{t=1}^{NN} p(t))(\sum_{t=1}^{NN} o(t))}{\left(\sqrt{NN \sum_{t=1}^{NN} p(t)^2 - (\sum_{t=1}^{NN} p(t))^2} \sqrt{NN \sum_{t=1}^{NN} o(t)^2 - (\sum_{t=1}^{NN} o(t))^2} \right)}$ olup determinant


katsayısı ise R^2 'dir.

- Zaman serisindeki gecikme sayısı : 10
- Giriş sayısı : 10
- Çıkış sayısı : 1
- LSTM tabaka sayısı : 1
- Tabakadaki birim sayısı: 128
- Aktivasyon fonksiyonu : Hücre adayında hiperbolik tanjant $\frac{e^x - e^{-x}}{e^x + e^{-x}}$ türünde sigmoid fonksiyon kullanılmışken geri kalan tüm kapılarda lojistik, $(1 + e^{-x})^{-1}$ türünde sigmoid fonksiyon kullanılmıştır.
- Eğitim algoritması: ADAM (Uyarlanabilir moment tahmini, Adaptive moment estimation)
- Maksimum iterasyon sayısı: 300
- Doğrulama frekansı: 1 iterasyon
- Gradyan doyumu: 1
- Başlangıç öğrenme hızı: 0,05
- Öğrenme hızı azalma periyodu: 100 iterasyonda 1 kere
- Öğrenme hızı azalma katsayısı: 0,1
- Gradyan eşiği: 0,8
- L2 düzeltme katsayısı: 0,001

3. ARAŞTIRMA BULGULARI VE TARTIŞMA

3.1. Kestirim Eğrisi

İterasyonlar bittikten sonra elde edilen LSTM ağının, ayrıca %20'lik veri üzerindeki kestirimi, Şekil 7'de verilmiştir.




Şekil 7. LSTM ağının kestirimi

Kestirim eğrisi incelendiğinde, modelin genel eğri şeklini yüksek bir doğrulukla temsil ettiği, ayrıca zaman serisindeki yerel pik ve dipleri de başarıyla yakaladığı görülmektedir. LSTM ağı, veriye herhangi bir ön işlem yapılması gereksinimini ortadan kaldırmaktadır.


3.2. Doğrulama

Oluşturulan modelin doğrulaması için hata yakınsama grafikleri, kestirim hatası, varyans analizi, hata metrikleri (MSE, RMSE, MAE, MAPE), korelasyon katsayısı R gibi istatistikî araçlar kullanılmıştır.

Ağ eğitimi, iterasyonlar ile yapılmaktadır. Beklenti, her iterasyon sonunda modeldeki hata değerinin azalmış olmasıdır. Bu duruma "hatanın yakınsaması" denmektedir. Hata yakınsama grafiği Şekil 8'de verilmiştir. Eğrilerin sıfıra yaklaştığı görülmektedir. Yakınsama esnasında herhangi ani bir sapma oluşmamıştır. Yakınsama eğrisi kararlı bir biçimde azalmaktadır. Eğrinin kararlılığında bir bozulma oluşmaması, aşırı uyum hatası oluşmadığı sonucunu vermektedir.



Şekil 8. Eğitim esnasında gözlenen; (a) RMSE hata yakınsama grafiği, (b) Kayıp (MSE)




Şekil 9. Test verisi üzerinde (a) zaman serisi cevap eğrisi (b) modelin hatası

Kestirim eğrisi Şekil 9-a'da ve kestirim verisindeki hata ise Şekil 9-b'de gösterilmiştir. Ağın kestirdiği değer ile zaman serisi arasındaki fark, hata olarak adlandırılmaktadır. Zaman serisinin son %20'lik kısmı, kestirim için kullanılmıştır. Şekil 9-b'deki hata değerleri aynı zamanda varyans analizi, hata metrikleri (MSE, RMSE, MAE, MAPE), korelasyon katsayısı R gibi istatistikî araçlarda kullanılacak olan yegâne veridir. Grafiklerden LSTM ağlarının, hem eğri genel şeklini hem de veri doğasından gelen pik ve dipleri temsil edebilme yeteneğinin yüksek olduğu görülmektedir. Bunun yanı sıra kestirim eğrisinde sabit bir kayma olduğu görülmüştür. Bu durumun bias b , terimi ile ilgili olduğu düşünülmektedir.

Bir modeldeki varyansın sabit veya değişken olup-olmadığı, "modelin kestirimi" ve "kestirim hatası" grafiği ile belirlenmektedir. Modellemelerde temel yaklaşım, farkların, her seviyede sabit varyansa sahip olmasıdır. Bu durumda fark dağılımı, tüm kestirim değerlerinde kabaca eşitse, sabit varyans varsayımı karşılanmış olacaktır. Yani, dağılım *eğer iki paralel çizgi arasında kalıyor ise* varyansın sabit olduğu

söylenektir. Aksi takdirde, farkın yayılımı sistematik olarak artar veya azalır, sabit varyans varsayımı büyük olasılıkla ihlal edilmiş demektir. Şekil 10'da verilen varyans dağılımları incelendiğinde dağılımın iki paralel çizgi arasında kaldığı ve rasgele olduğu, bu nedenle de varyansın sabit olduğu anlaşılmıştır [15].



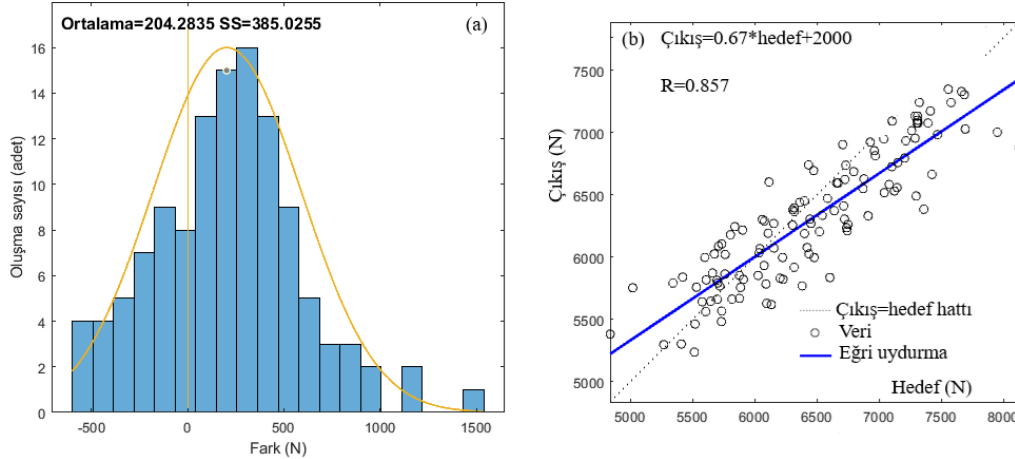
Şekil 10. Varyans analizi

Ağın kestirim performansı ölçümleri Çizelge 3'te gösterilmiştir. Ağ eğitilirken, toplamda 300 iterasyon yapılmış ve hesaplamalar 37,509 saniye sürmüştür. Ağ 0,857 değerinde pozitif korelasyona sahiptir. Bu da ağın kestirimi ile veri seti arasında yüksek doğrulukta bir ilişki olduğu anlamına gelmektedir. Yüksek korelasyon, modelin performansının önemli bir ölçütüdür, ancak tek başına yeterli bir kriter değildir. Bu nedenle hata metrikleri de incelenmelidir.

Çizelge 3. LSTM ağının, eğitim ve test performans metrikleri

Özellik	Eğitim	Kestirim
MAE (birim)*	520,945	379,120
MAPE (%)	3,123	2,326
Ortalama hata (birim)	-137,079	204,2835
MSE (birim ²)	443483,94	223442,778
RMSE (birim)	665,94592	472,697
Hesaplama süresi (s)	37,509	37,934
R	0,608	0,857
İterasyon adeti	300	--

(*) Sürtünme zaman serinin birimi Newton'dur.



Şekil 11. (a) Hata histogramı (b) regresyon analizi

Şekil 11-a'da, 20 çubuklu bir hata histogramı verilmiştir. Bu şekil, kestirim esnasındaki hataların oluşma sayılarını göstermektedir. Yatay eksen hata değeridir. Dikey eksen ise "oluşma sayısı"dır. Hata histogramlarında, ① çan eğrisi biçiminde bir şeklin oluşması, ② eğrinin tepesinin "sıfır hata" çizgisine yakın olması, ③ eğrinin de dar olması istenen bir durumdur. Çan eğrisi oluşmuşsa, rasgele bir hata dağılımı var demektir. Eğrinin darlığı da hatalardaki sapmaların azlığına işaret etmektedir. Eğrinin tepesinin "sıfır hata" çizgisine yakın olması ise sıklıkla, sıfır hataya yakın hata oluştuğu anlamına gelmektedir. Turuncu dikey çizgi "sıfır hata" değerini göstermektedir. Histograma bakıldığında en uzun çubukların "ortalama hata" etrafında toplandığı ancak, ortalamanın "sıfır hata" değerinden bir miktar sağa saptığı görülmüştür.

Şekil 11-b'de ise regresyon analizinin sonuçları gösterilmektedir. Regresyon analizi de model performansının değerlendirilmesinde sıklıkla kullanılan bir başka tekniktir. Bu analiz sayesinde "ağın kestirimi" ile "zaman serisi" arasındaki korelasyon tespit edilmektedir. Grafiklerde "eğri uydurma" doğrusu, (hedef, çıkış) noktalar kümesinin tümünün üzerine birinci dereceden regresyon yapıldığında elde edilen fonksiyonu göstermektedir. Bu fonksiyon $çıkış = a * hedef + b$ türündeki bir doğrudur. Burada a , regresyon doğrusunun eğimi ve b ise doğrunun "çıkış" isimli eksenini kestiği noktadır. Bu doğrunun korelasyonu ise R ile gösterilmektedir. 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 gösterirken 0,3-0,7 arasında aldığı değerler orta seviyede bir ilişkiyi, 0,71-0,99 arasındaki değerler ise veriler arasında yüksek seviyede bir ilişki olduğunu ortaya koymaktadır. Sıfır değeri, ilişki olmadığını gösterirken, negatif değerler, ters bir doğrusal ilişki anlamına gelmektedir. Mutlak değerce R 'nin artması, ilişkinin daha belirgin hâle geldiğini göstermektedir. "Hedef" olarak belirtilen ekseninde, veri setindeki değerler mevcutken, "çıkış" olarak gösterilen ekseninde ise ağın kestirdiği değer verilmiştir. Umulan ise bunların birbirlerine eşit olmasıdır ki bu hâlde $R=1$ olacak ve tüm noktalar 45° doğrusu (----- Çıkış=hedef hattı) üzerinde olacaktır.

Görülebileceği üzere ağ, kestirim verisi üzerinde yüksek korelasyona sahiptir, $R=0,857$. Ağın kestirim esnasındaki ortalama kare hatasının kökü 472,697 N olmaktadır. Ortalama mutlak yüzde hatası ise %3,123 olduğu tespit edilmiştir. Bu durum ağın kestiriminin başarısını göstermektedir.

3.3. Tartışma

Fıstık sınıflandırmada işlem parametrelerinin modellenmesinde ML nadiren kullanılmıştır. Sıklıkla eğri uydurma tekniği kullanılmaktadır [18]. Fakat eğri uydurma yapılacakken işlemi öncesi veriye bazı ön işlemler uygulandığı, bunun da verinin doğallığını bir miktar bozduğu görülmektedir. Ansys Rocky DEM© simülasyonundan elde edilen veri üzerine LSTM ağının oluşturulması, fıstık boyutlandırma konusunda umut verici sonuçlar ortaya koymuştur.

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. Bu çalışmada LSTM ağı kullanarak fıstık sınıflandırma sistemine ait işlem parametrelerinin verisine bir ön işlem yapmaya gerek olmadan 0,857 korelasyonla ve 472,697 (N) RMSE ile kestirim yapabilen bir ağ oluşturulmuştur. Ağ kestirimlerindeki varyans sabittir. Kestirim eğrileri incelendiğinde hem genel eğri hem de tepe (pik)-çukur (dip) şekilleri yüksek hassasiyetle kestirebildiği görülmüştür.

AR(4) modeli için AIC değeri 1,5817, ARMA(4,2) modeli için 0,9237, ANFIS yöntemi için 1,3568 ve MLP modeli için 1,4068 olarak rapor edilmiştir [19]. Shi ve arkadaşları (2019), geriye yayılım (BP) algoritması ile RMSE hata değerini 0,0135 °C, SVM yöntemi ile 0,0151 °C ve LSTM yöntemi ile 0,0112 °C olarak belirlemiştir [20]. Wang ve arkadaşları (2022), BP, kapılı tekrarlayan birim (GRU), LSTM ve BILSTM ağlarını kullanarak simülasyon ve deney sonuçlarını karşılaştırmışlardır. Yapılan analizler, BILSTM ağının kestirim doğruluğunun diğer modellere kıyasla daha yüksek olduğunu göstermiştir [21]. Kacar ve Korkmaz (2022), tarımsal kurutma kestiriminde regresyon, NAR ve LSTM modellerini kullanarak, 0,015 g gibi çok düşük bir RMSE değeri elde edebildiklerini rapor etmişlerdir [22]. Ayrıca, N25P5K5 türü organomineral gübre kurutulmasında, çok tabakalı algılayıcı ağı ve LSTM yöntemleriyle 0,99-1,00 arasında bir korelasyon elde edilirken, YSA (Yapay Sinir Ağı) ile 0,201 mg'lık bir RMSE değeri elde edilmiştir [23].

AEY ve LSTM'nin yer fıstığı ayıklama süreçlerine entegrasyonunun güçlü yönleri mevcuttur [24]. Bu teknolojiler, sınıflandırma işlemlerinin gerçek zamanlı olarak izlenmesini, otomasyonunu sağlayarak verimliliğin, doğruluğun ve ürün kalitesinin artmasını sağlamaktadır [25]. Ayrıca, gelişmiş simülasyonların ve veri odaklı modellerin kullanılması, israfın azaltılmasına, kaynak kullanımının iyileştirilmesine ve yer fıstığı endüstrisinin artan taleplerinin karşılanmasına yardımcı olabilmektedir [26]. Yer fıstığı endüstrisi, küresel gıda üretimi ve ticaretinde önemli bir rol oynamaktadır ve bu da yüksek kalite standartlarının korunması için doğru ve verimli sınıflandırmayı kritik hâle getirmektedir. Geleneksel el ile sınıflandırma süreci zaman, maliyet ve öznellik açısından sınırlamalara sahiptir. AEY esaslı simülasyon ve LSTM yöntemleri, gelecekteki çalışmalar için umut verici çözümler sunmaktadır.

Bununla birlikte, daha fazla araştırma ve geliştirme için hâlâ bazı eksiklikler de mevcuttur. Örneğin zaman serisi verisi üzerinde başarılı olan bir yöntemdir. Gradyan kaybolması ve patlaması problemleri, eğitmenin oldukça zor bir iş olması, aktivasyon fonksiyonu olarak tanh veya relu kullanıldığında çok uzun dizi işleyememeleri de bu yöntemin dezavantajlarıdır. Gelecekteki çalışmalar, bu yöntemlerin doğruluğunu ve hızını iyileştirme, diğer tekniklerle birlikte uygulamalarını keşfetme ve farklı yer fıstığı çeşitlerini ve işleme koşullarını ele alma potansiyellerini araştırmaya odaklanmalıdır. Ayrıca, maliyet etkinliği, uygulama kolaylığı ve mevcut sistemlerle entegrasyonu gibi faktörler de göz önünde bulundurularak bu yöntemlerin yer fıstığı endüstrisinde benimsenmesini teşvik etmek için çaba gösterilmelidir.

4. SONUÇLAR

Bu çalışmada, bir fıstık sınıflandırma işleminin AEY esaslı simülasyonu yapılarak tane ile elek yüzeyi arasında oluşan sürtünme kuvveti verisinin LSTM ağı ile modellenmesi ve kestirimi yapılmıştır. Tarım ve gıda endüstrilerinde kullanılan silindirik fıstık sınıflandırma makinalarının modellenmesi amaçlanmıştır. Ağın performansı araştırılmıştır. Ağın performansının değerlendirilmesinde istatistiki yöntemler kullanılmıştır. Çalışma sonunda elde edilmiş olan temel çıkarımlar aşağıda maddeler hâlinde sıralanmıştır.

- LSTM ağının, yer fıstığı sınıflandırma kestirimi yapılırken, hem genel eğri şekillerini hem de tepe (pik) ve çukurlarını (dip) başarılı bir şekilde yakalayabildiği gösterilmiştir. Ayrıca, LSTM'nin eğri uydurma yöntemlerinden farklı olarak, herhangi bir veri ön işleme gerektirmemesi de önemli bir avantaj sunmaktadır.
- Elde edilen iç yer fıstığı sınıflandırma modelinin korelasyon değeri 0,857 olup hesaplamaların tamamlanması 300 iterasyon sonrasında 37,934 saniye sürmüştür. Veri seti ve model çıktıları güçlü bir doğrusal ilişkiye sahiptir. Kullanılan ağ, ağın hiperparametreleri ve bu ağ ile elde edilen kestirim performansı çalışma içerisinde sunulmuştur.
- LSTM ağı 1 tabaka derinliğine sahiptir. Tabakada 128 adet gizli birim bulunmaktadır. Eğitim algoritması ADAM olup başlangıç öğrenme hızı 0,05 değerindedir. Bu değer her 100 iterasyonda bir kez azaltılmaktadır. Azalma katsayısı ise 0,1 olup gradyan eşiği 0,8 ve L2 düzeltme katsayısı 0,01 değerindedir.
- Simülasyon 60 saniyelik gerçek zamanı hesaplamak için 63 gün 18 saat 27 dakika sürmüştür. LSTM ağı ise hem eğitim-doğrulama-test hem de 12 saniyelik kestirim işlemi için toplamda 37,934 saniye harcamaktadır. Kıyaslandığında aradaki bariz fark dikkat çekicidir. Tüm hesaplamalar 8 GB RAM ve 2.8 GHz dört çekirdekli CPU'ya sahip aynı bilgisayar kullanılarak gerçekleştirilmiştir.
- AEY simülasyonundan elde edilen veriye LSTM yönteminin uygulanması, endüstriyel ölçekte üretim hattındaki otomasyonuna dâhil edilebilir bir esneklik sunmaktadır. Sürtünme kuvveti gibi dinamik olarak değişen verilerin, gerçek işletme şartlarında eş zamanlı olarak hızla analiz edilebilmesi, üretim süreçlerinde karşılaşılabilecek sorunların önceden kestirilmesi ve süreci iyileştirmek için üretim optimizasyonuna olanak sağlayabilecektir.

Bu çalışma sonunda oluşturulan ağ, müteakip çalışmalarda, diğer makine öğrenme yöntemleri ile oluşturulabilecek modellerle kıyaslanabilecektir. Ayrıca gelecekteki çalışmalar; bu teknolojilerin doğruluğunu ve hızını iyileştirmeye, yeni uygulamalarını keşfetmeye, farklı iç yer fıstığı sınıflandırma çeşitlerini ve işleme koşullarını araştırmaya odaklanmalıdır. Zaman serisinin gecikmeleri yanı sıra, aynı zamanda harici girişlerin de olabileceği ve bunlarla ağın beslenerek yeni modeller denenmesi müteakip çalışma potansiyeline sahiptir.

5. TEŞEKKÜR

Ayrık eleman yöntemi simülasyonları için kullanılan Ansys Rocky DEM®'in, makine öğrenme yönteminin kodlanmasında yararlanılan Matlab®'in eğitsel amaçlı kullanım imkânını sağlayan sırasıyla, Numesys® Genel Müdürü Sayın Ekin Ersan'a, Sayın Begüm Çifci'ye, Çukurova Üniversitesi Ziraat Fakültesi'ne, Karadeniz Teknik Üniversitesi'ne, Dr. Mehmet Seyhan'a teşekkür ederiz. Bu çalışmanın inceleme ve değerlendirme aşamasında yapmış oldukları değerli katkılardan dolayı editör, hakem ve emeği geçenlere içten teşekkür ederiz.

6. KAYNAKLAR

1. LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep learning. Nature, 521(7553), 436-444.

2. Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A.A., Veness, J., Bellemare, M.G., Graves, A., Riedmiller, M., Fidjeland, A.K., Ostrovski, G., 2015. Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529-533.
3. Yosinski, J., Clune, J., Bengio, Y., Lipson, H., 2014. How transferable are features in deep neural networks? *Advances in Neural Information Processing Systems*, 27.
4. Zhao, C., Hu, P., Liu, X., Lan, X., Zhang, H., 2023. Stock market analysis using time series relational models for stock price prediction. *Mathematics*, 11(5), 1130.
5. Cundall, P.A., Strack, O.D., 1979. A discrete numerical model for granular assemblies. *Geotechnique*, 29(1), 47-65.
6. Ansys Rocky DEM©, 2021. Particle Dynamics Simulation Software. 01.18.2024 [cited 2024 11.29.2024]; Available from: <https://www.ansys.com/products/fluids/ansys-rocky>.
7. Deist, T.M., Patti, A., Wang, Z., Krane, D., Sorenson, T., Craft, D., 2019. Simulation-assisted machine learning. *Bioinformatics*, 35(20), 4072-4080.
8. Saadallah, A., Finkeldey, F., Buß, J., Morik, K., Wiederkehr, P., Rhode, W., 2022. Simulation and sensor data fusion for machine learning application. *Advanced Engineering Informatics*, 52, 101600.
9. Ercan, U., 2012. Modeling of cylindrical helical sieve. Master Thesis. Çukurova University, Institute of Science and Technology, Mechanical Engineering, 84.
10. Ugurluay, S., Akcali, İ.D., 2021. Development of a vibrationless sorting system. *Spanish Journal of Agricultural Research*, 19(1), 204.
11. Akcali, İ.D., Mutlu, H., Ercan, U., 2014. Mathematical model of a sorting machine. *Journal of Agricultural Machinery Science*, 10(3), 229-234.
12. Zhang, C., Chen, Y., Wang, Y., Bai, Q., 2024. Discrete element method simulation of granular materials considering particle breakage in geotechnical and mining engineering: A short review. *Green and Smart Mining Engineering*.
13. Chouhan, K., Chavda, J.T., 2021. A review on numerical simulation of large deformation problems in geotechnical engineering. In *Indian Geotechnical Conference*, Springer.
14. Karaca, S., Uçar, A., 2024. Applications of DEM particle breakage models in mineral industrial. *Scientific Mining Journal*, 62(4), 183-190.
15. Korkmaz, C., Kacar, İ., 2024. Modelleme ve tahmin amaçlı veri ön işleme yöntemlerinin ürün kurutma örneği ile açıklanması. *Tekirdağ Ziraat Fakültesi Dergisi*, 21(2), 482-500.
16. Rahman, M.M., Shakeri, M., Khatun, F., Tiong, S.K., Alkahtani, A.A., Samsudin, N.A., Amin, N., Pasupuleti, J., Hasan, M.K., 2023. A comprehensive study and performance analysis of deep neural network-based approaches in wind time-series forecasting. *Journal of Reliable Intelligent Environments*, 9(2), 183-200.
17. MathWorks, 2023. Long short-term memory (LSTM) layer for recurrent neural network (RNN). 21.05.2024]; Available from: <https://www.mathworks.com/help/deeplearning/ref/nnet.cnn.layer.lstm.html>.
18. Huan, J., Deng, L., Zhu, Y., Jiang, S., Qi, F., 2024. Short-to-medium-term wind power forecasting through enhanced transformer and improved EMD integration. *Energies*, 17(10), 2395.
19. Kacar, İ., 2023. Uyarlamalı ağ tabanlı bulanık çıkarım sistemi kullanarak bir mekanik jiroskopun yalpalama kestirimi. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 10(21), 198-209.
20. Shi, H., Hu, S., Zhang, J., 2019. LSTM based prediction algorithm and abnormal change detection for temperature in aerospace gyroscope shell. *International Journal of Intelligent Computing and Cybernetics*, 12(2), 274-291.
21. Wang, J., Deng, Z., Shen, K., 2022. Virtual gyros construction and evaluation method based on BILSTM. *IEEE Transactions on Instrumentation and Measurement*, 71, 1-10.
22. Kacar, İ., 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.
23. Kacar, İ., Korkmaz, C., 2022. N25P5K5 türü yeni nesil bir bitki besininin kuruma kinetiğinin regresyon ve makine öğrenme yöntemleri ile belirlenmesi. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 37(4), 989-1004.
24. Kacar, İ., 2023. Mekanik tasarım ve analiz bilimsel esasları. Ankara: Akademisyen Kitabevi.
25. Korkmaz, C., 2023. The place of organic and organomineral fertilizer production in sustainable agriculture. In *Sustainable Agriculture Technologies – II*, A. Bayat, Editor. İksad., 184-206.
26. Zhao, X., Chen, J., Du, F., 2012. Potential use of peanut by-products in food processing: A review. *Journal of Food Science and Technology*, 49, 521-529.