

MAKİNE ÖĞRENMESİ İLE SİSMİK SIVILAŞMANIN DEVIATORİK GERİLME TARİHÇESİ CİNSİNDEN TAHMİN EDİLMESİ

PREDICTION OF DEVIATORIC STRESS GENERATION FOR LIQUEFIABLE SOILS WITH MACHINE LEARNING

Ömer Tuğşad BİRİNCİ¹, Mehmet Barış Can ÜLKER²

ÖZET

Deprem kaynaklı zemin sıvılaşması, aniden gerçekleşmesi ve toptan göçmelere sebep olabilmesi sebebiyle araştırmacılar tarafından hem deneysel hem de teorik olarak uzun zamandır incelenen önemli bir konudur. Zeminlerin tekrarlı yüklemeye sonucunda davranışlarını ve sıvılaşma özelliklerini belirlemek için, yapılan deneylerin sonuçlarını kullanarak plastisite teorisine dayalı çok sayıda teorik bünye modeli geliştirilmiştir. Ancak bu bünye modelleri çok sayıda zemin parametresine, ön kabullere ve kullanımları için uzman mühendislere ihtiyaç duymaktadır. Bununla birlikte bu teorik modeller kısıtlı bir zemin grubu için geçerli olmakta ve geniş zemin davranış özelliklerini temsil etmekte zorlanmaktadır. Bu bildiride, makine öğrenmesinin bir alt dalı olan derin öğrenme yardımıyla ve sadece tekrarlı zemin deney sonuçlarından öğrenen bir "akıllı bünye modeli" geliştirilmiştir. Üç farklı kaynaktan şekil değiştirme kontrollü tekrarlı üç eksenli deney verisi toplanmıştır. Deney süresi, çevrimsel şekil değiştirme oranı, başlangıç görelisi sıklık, başlangıç boşluk oranı ve başlangıç efektif çevre basıncı girdi özellikleri olarak kullanılmış ve deviatorik gerilme tarihçesi tahmin edilmiştir. Pencereleme yöntemiyle hem veriler daha etkili şekilde ifade edilebilmiş hem de daha doğru tahminler yapılmıştır. Derin öğrenme mimarisi olarak şifreleyici-Çözücü, yinelemeli sinir ağı olarak da Uzun Kısa Dönemli Bellek katmanları kullanılmıştır. Modelin optimizasyonu Hyperband algoritması ile yapılmış ve model dayanıklılığı K-Katmanlı Çapraz Doğrulama ile sınanmıştır. Sonuç olarak, modelin test seti üzerinde ortalama mutlak hata cinsinden %1 civarında hata ile deviatorik gerilme tahmini yapabildiği görülmüştür. Kullanılan deneylerin şekil-değiştirme kontrollü olmaları sebebiyle, nihai modelin bir sonlu elemanlar programına aktarımı sağlanabilecektir. Bu sayede teorik bir bünye modeline ihtiyaç duymadan ilgili zemin dinamiği problemlerinin çözümü mümkün olacaktır.

Anahtar Kelimeler: Sıvılaşma, makine öğrenmesi, temiz kumlar, tekrarlı üç eksenli deney, derin öğrenme, efektif gerilme.

¹ Yüksek Lisans Öğrencisi, İstanbul Teknik Üniversitesi, birinci17@itu.edu.tr

² Prof. Dr., İstanbul Teknik Üniversitesi Afet Yönetimi Enstitüsü, mbulker@itu.edu.tr (Sorumlu Yazar)



ABSTRACT

Seismic-induced soil liquefaction is an important topic that has been extensively studied both experimentally and theoretically by researchers, due to its sudden occurrence and potential to cause total collapse. To determine the behavior of soils under dynamic loading and their liquefaction characteristics, numerous theoretical constitutive models based on plasticity theory have been developed, utilizing the results of experimental studies. However, these constitutive models require numerous soil parameters, assumptions, and the expertise of specialized engineers for their application. Moreover, these theoretical models are often valid only for a limited range of soil types and struggle to represent the broader spectrum of soil behavior characteristics. In this paper, a "smart constitutive model" has been developed using deep learning, a branch of machine learning, which learns solely from dynamic soil test results. Strain-controlled cyclic triaxial test data were collected from three different sources. Test duration, cyclic strain rate, initial relative density, initial void ratio, and initial effective confining pressure were used as input features, while the deviatoric stress was predicted. By using the windowing method, the data were expressed more effectively, leading to more accurate predictions. An Encoder-Decoder architecture was employed as the deep learning model, with Long Short-Term Memory (LSTM) layers used as the recurrent neural network. The model was optimized using the Hyperband algorithm, and its robustness was tested through K-Fold Cross-Validation. As a result, the model was able to predict deviatoric stress with an average absolute error of approximately 1% on the test set. Due to the use of strain-controlled tests, the final model can be integrated into a finite element analysis program. This allows for the solution of related soil dynamics problems without the need for a theoretical constitutive model.

Keywords: *Liquefaction, machine learning, clean sands, cyclic triaxial test, deep learning, effective stress.*

1. GİRİŞ

Depremlerde yaşanan can ve mal kayıplarının önemli sebeplerinden birisi zemin sıvılaşmasıdır. Zemin sıvılaşması, gevşek granüler zeminlerin dinamik yükleme sonucunda boşluk suyu basıncının artması ve efektif gerilmelerinin sıfıra yaklaşması sonucunda zeminin mukavemet özelliğini yitmesidir. 1964 Niigata depreminin ardından deneysel ve teorik olarak araştırmanın yoğunlaştığı bu konu, gerek temiz kumlarda relatif sıkılık cinsinden gerek ince dane içeren zeminlerde ince dane içeriği ve zemin plastisitesi üzerinden çalışılmaktadır. Bu çalışmada temiz kum davranışı üzerinde durulmuştur. Depremlerde zeminin davranışını temsil etmek ve önlem alabilmek amacıyla, Tekrarlı Basit Kesme Deneyi ve Tekrarlı Üç Eksenli Deneyi gibi laboratuvar zemin deneyleri bulunmaktadır. Bu deney sonuçlarından yola çıkarak teorik bünye modelleri geliştirilmektedir ve literatürde plastisite teorisi ile geliştirilen pek çok model mevcuttur. Bunlara örnek olarak Pekleşen Zemin Modeli (Schanz vd., 1999), Genelleştirilmiş Plastisite Modeli (Zienkiewicz, 1982; Pastor vd., 1990), ve Sınırlayan Yüzey Modelleri (Dafalias, 1986; Wang vd., 1990) verilebilir. Bu modeller çok sayıda zemin parametresine, ön kabullere, pratik basitleştirmelere ve kullanım için de deneyimli mühendislere ihtiyaç duymaktadır. Bu da endüstrinin talebi olarak hızlı ve yeterli doğrulukta sonuç veren, kullanımı basit modellerden uzaklaşılmasına sebep olmaktadır. Sonuç olarak güvenli olmayan tasarımlar



ve ekonomik olmayan çözümler ortaya çıkmaktadır. Tüm bu sebeplerle, teorik bünye modellerine alternatif olarak doğrudan gerçek verilerden öğrenen "akıllı" bünye modellerinin (ABM) oluşturulması önemli bir ihtiyaç haline gelmektedir. Çünkü, analizlerde kullanılan bünye modelinin başarısı analizin sonucunu etkileyen en önemli faktörlerden birisidir. Burada 'gerçek veri''den kastımız laboratuvar deney sonuçlarıdır. Öğrenme yoluyla geliştirilecek model ise makine öğrenmesi yöntemine dayalı olmaktadır.

Geoteknik mühendisliğinde makine öğrenmesi kullanarak zeminin statik ve tekrarlı yüklere karşı davranışının araştırılması konusunu ele alan çalışmalar incelendiğinde, çalışmaların temel olarak aşağıdaki gibi şekillendiği görülmüştür:

- Zeminin gerilme-şekil değiştirme ve/veya boşluk suyu basıncı değişiminin monotonik yükleme durumunda, sentetik (suni) verilerle eğitilen makine öğrenmesi modelleri yardımıyla tahmin edilmesi. Sentetik veriler, teorik bünye modellerini kullanarak oluşturulmaktadır. Wang vd. (2022), Ma vd. (2022), Zhang vd. (2023) bu konuda çalışmalara örnektir.
- Zeminin gerilme-şekil değiştirme ve/veya boşluk suyu basıncı değişiminin çevrimsel yükleme durumunda, sentetik verilerle eğitilen makine öğrenmesi modelleri yardımıyla tahmin edilmesi. Zhang vd. (2020), Guan ve Yang (2022), Drakos (2008) bu tipte çalışmalardır.
- Zeminin gerilme-şekil değiştirme ve/veya boşluk suyu basıncı değişiminin monotonik yükleme durumunda, gerçek deney verileriyle eğitilen makine öğrenmesi modelleri yardımıyla tahmin edilmesi. Ellis vd. (1995), Ghaboussi ve Sidarta (1998), Teng vd. (2023) bu tipte çalışmalardır.
- Zeminin gerilme-şekil değiştirme ve/veya boşluk suyu basıncı değişiminin çevrimsel yükleme durumunda, gerçek deney verileriyle eğitilen makine öğrenmesi modelleri yardımıyla tahmin edilmesi. Choi ve Kumar (2022), Meng ve Pei (2023), Chen vd. (2021) bu çalışma türüne örnektir.

Literatür taraması sonucunda, yapılan çalışmaların büyük çoğunluğunda daha önceden yayınlanmış bünye modellerinden girdi-çıkı setleri oluşturulup, bunların model eğitiminde kullanılması yolu izlendiği görülmüştür. Ayrıca, zeminlerin çevrimsel yükleme sonucu davranışı ile ilgili monotonik yüklemeye oranla daha az çalışma yapıldığı görülmektedir. Bu çalışmanın konusu olan çevrimsel yükleme için gerçek veri kullanılarak zemin davranışının araştırılması konusunda hem çalışma sayısı hem de bu çalışmalarda kullanılan veri sayısı oldukça kısıtlıdır. Bu bildiride, üç farklı kaynaktan çok sayıda tekrarlı üç eksenli deney verisi toplanmıştır. Yapılan tahminlerde makine öğrenmesi yöntemlerinden en uygun derin öğrenme yöntemi kullanılmış ve deviatorik gerilmenin zamanla değişimi temiz kumlar için farklı başlangıç rölatif sıklıklar için tahmin edilmiştir. Boşluk suyu basıncı tahmini bu bildiri konusunun dışında tutulmuştur.

2. TEKRARLI ÜÇ EKSENLİ DENEY VERİLERİ

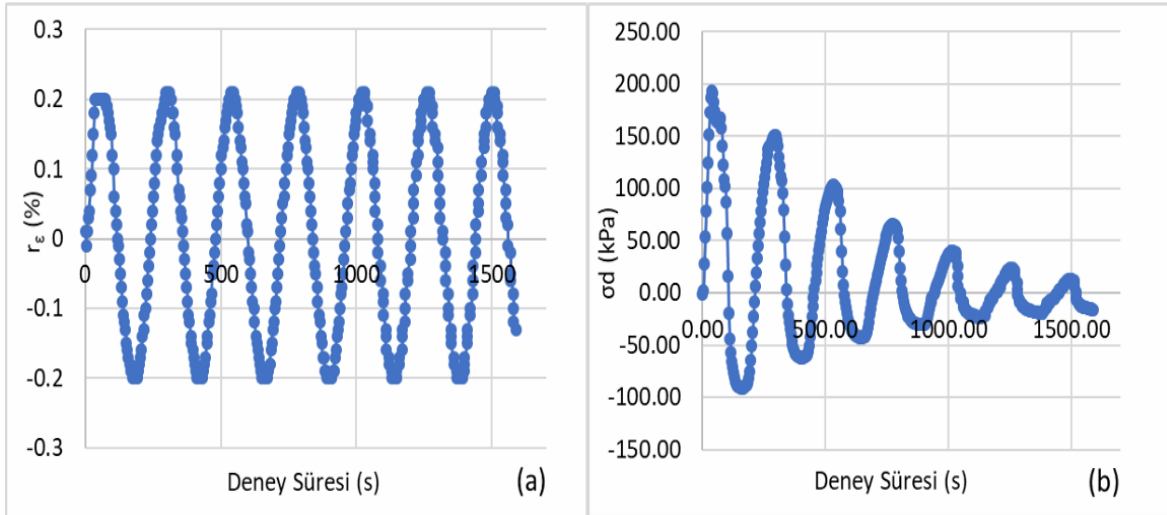
Kullanılan verinin miktarı ve niteliği, makine öğrenmesi modellerinde başarıyı etkileyen en önemli faktörlerden birisidir. Az sayıda verinin kullanılması problemin kısıtlı bir aralıkta ifade edilmesine ve modelin anlamlı ilişkiler öğrenememesine neden olabilmektedir. Buna



karşın, çok sayıda ancak düzensiz, gürültü oranı yüksek veri ise modelin anlamsız çıkarımlar yapmasına ve ezberle yönelmesine yol açabilmektedir. Bu sebeple toplanan verinin problemi açıklama noktasında yeterli ve yüksek kalitede olması gerekmektedir. İlgilenilen konu sıvılaşabilen temiz kum zeminlerin şekil-değiştirme kontrollü tekrarlı üç eksenli deney ile belirlenen deviatorik gerilme değişiminin tahmin edilmesidir. Toplanan tüm deneyler yayınlanan bilimsel kaynaklardan alınmış ve deneylerde yüksek frekansta veri alan cihazlar kullanıldığı için çok sayıda veri noktası elde edilebilmiştir. Toplanan verilerin kaynakları ve öznitelik aralıkları Tablo 1’de verilmiştir. Tablo 1’den, oldukça geniş bir öznitelik aralığında deney verisi toplandığı görülebilmektedir. Buna göre deney süresi (t), birim şekil değiştirmenin % cinsinden ifadesi olan çevrimsel şekil değiştirme oranı (r_ϵ), başlangıç göreceli sıkılığı ($D_{r,0}$), başlangıç boşluk oranı (e_0) ve başlangıç efektif çevre basıncı ($\sigma'_{3,0}$) girdi öznitelikleri olarak belirlenmiş, deviatorik gerilme (σ_d) değişimi tahmin edilmiştir. Deneylerdeki tipik bir girdi ve bu girdiye karşılık oluşan deviatorik gerilme çıktısı, sırasıyla Şekil 1’de verilmiştir.

Tablo 1. Tekrarlı Üç Eksenli Test Veritabanı

Kaynak	r_ϵ (%)	$D_{r,0}$ (%)	e_0	$\sigma'_{3,0}$ (kPa)	t (s)	Zemin Türü	Numune Sayısı
ElGhoraiby ve Manzari (2020)	0.041-0.301	40-76	0.58-0.67	100	600-6000	Ottawa Kumu	36
Vasko vd. (2018)	0.061-0.497	55-55	0.60-0.60	50-200	456-9000	Ottawa Kumu	11
Wichtmann ve Triantafyllidis (2016)	0.062-1.01	29-101	0.50-0.72	100-700	8960-218000	Karlsruhe İnce Kumu	9

Şekil 1. Girdi ve Çıktı Verileri ($D_{r,0}=\%55$, $\sigma'_{3,0}= 200$ kPa, $e_0=0.604$).

3. DERİN ÖĞRENME YÖNTEMLERİ VE MODELLERİ

Çalışmada derin öğrenme yöntemlerinden Uzun Kısa Süreli Bellek (Long Short Term Memory-LSTM), veri ön işleme yöntemi olarak Pencereleme Yöntemi ile birlikte kullanılmıştır. Tüm verinin %80’i eğitim, %20’si test seti olarak ayrılmıştır. Eğitim verisinin %20’si ise doğrulama seti olarak kullanılmıştır. Model mimarisi olarak LSTM katmanlarının



kullanıldığı Şifreleyici-Çözücü (Encoder-Decoder) mimarisi kullanılmıştır. Modelde kapsamlı şekilde hiperparametre optimizasyonu yapılmış, modelin dayanıklılığı K-Katmanlı Çapraz Doğrulama ile sınanmıştır.

3.1. Uzun Kısa Süreli Bellek (LSTM)

Tekrarlı üç eksenli deney yapılarak zemin numunesinde oluşan deviatorik gerilme değişiminin tahmin edilmesi problemi, makine öğrenmesi literatüründe zaman serisi problemi sınıfına girmektedir. Bu problem tipinde, zamansal ilişki önem kazanmakta ve önceki zaman adımları gelecek zaman adımlarını etkilemektedir. Zaman serileri için özel olarak Yinelemeli Sinir Ağları (Recurrent Neural Networks-RNN) kullanılmaktadır. Bu sinir ağları hafıza özelliğine sahiptir ve veriyi zaman boyutunu dikkate alarak işlemektedir. LSTM ve Geçitli Tekrarlayan Birim (GRU), en yaygın RNN çeşitlerinden ikisidir. LSTM, uzun zaman serilerini işleyebilmesi ve gradyan yok olması problemini çözmesi sebebiyle ilk ortaya çıktığı 1997 yılından beri yaygın olarak kullanılmaktadır. LSTM katmanı girdi verilerini üç boyutlu olarak kabul ederek işlemektedir. LSTM mimarisi ile ilgili daha detaylı bilgiye Hochreiter ve Schmidhuber (1997)'den erişilebilir.

3.2. Pencereleme (Windowing) Yöntemi


Uzun zaman serilerinin herhangi bir ön işleme yapılmadan modelde eğitim için kullanılması genellikle tercih edilmeyen bir yöntemdir. Bunun sebebi, uzun zaman serilerinde işlenen veri arttıkça modelin örüntüleri hatırlamasının zorluğudur. Pencereleme (windowing) yöntemi, bu sorunu çözmek için kullanılan başarılı bir ön işleme yöntemidir. Bu yöntem temel olarak bütün bir girdi ve çıktı matrisinin, daha küçük parçalara ayrılması ve model eğitiminde bu parçaların kullanılmasıdır. Seçilen pencere boyutu, bütün girdi ve çıktı matrisleri üzerinde kaydırılarak anlamlı girdi-çıkıtı setleri oluşturulur. Girdi setindeki parçanın etkilediği tek zaman adımı çıktı olarak kullanılıyorsa problem tek değer tahmin problemi olarak, girdi setindeki parçanın etkilediği birden fazla zaman adımı çıktı olarak kullanılıyorsa, problem dizi problemi olarak sınıflandırılmaktadır. Pencereleme yöntemi ile zaman serisi daha küçük ve anlamlı parçalara ayrılabilir ve modelin global ve lokal değişimleri daha başarılı saptaması sağlanabilir.

3.3. Model Mimarisi

Sıvılaşmanın tahmini problemi, dizi problemi olarak ele alınmıştır. Tüm laboratuvar deney verileri, 50 zaman adımından oluşan girdiler ve bu zaman adımlarında karşılık gelen çıktılar olarak ifade edilmiştir. Pencereleme arasında sadece bir zaman adımı atlama yapılarak modelin örüntüyü kaçırmaması hedeflenmiştir. Toplam 56 deney verisinin 35 tanesi eğitim setine, 9 tanesi doğrulama setine ve 12 tanesi test setine dahil edilmiştir. Tüm girdi ve çıktı öznitelikleri 0 ile 1 arasında ölçeklenerek model eğitimi kolaylaştırılmıştır. Modelin kayıp fonksiyonu olarak karesel ortalama hata (mean squared error-MSE) kullanılmıştır. Model mimarisi olarak dizi problemleri için yaygın kullanılan Şifreleyici-Çözücü (Encoder-Decoder) mimarisi, yinelemeli sinir ağlarından Uzun Kısa Dönemli Bellek (LSTM) katmanları kullanılarak oluşturulmuştur. Bu mimari iki kısımdan oluşur. Şifreleyici kısmında verilen girdiler işlenerek "context vector" adı verilen yeni bir gösterim oluşturulur. Bu gösterim çözücü kısmında kullanılarak modelin tahminleri şekillenir. Şekil 2'de, şifreleyici çözücü mimari görülmektedir. Üst kısım şifreleyici kısımdır ve girdileri alıp yeni bir ifade oluşturur.



Alt kısım çözücü kısmıdır ve gerçek çıktı değerleriyle veya özel bir anlamı olmayan doldurma (padding) sayılarıyla eğitilebilir. Çözücü kısmında gerçek çıktı değerlerinin kullanımına öğretici zorlaması (teacher forcing) denmektedir ve çeviri problemlerinde kullanımı avantajlı olabilmektedir. Ancak zaman serilerinde başarısız tahminlere ve eğitim setine fazla bağlı kalmaya sebep olabilmektedir. Bu sebeple bu çalışmada öğretici zorlaması kullanılmamıştır. Çözücü kısmı sadece şifreleyici kısmından aldığı bilgiyi işleyerek tahmin oluşturmuştur. Model Python dilinde, Keras kütüphanesi kullanılarak oluşturulmuştur.




Şekil 2. Şifreleyici Çözücü Model Mimarisi (InputLayer: Girdi katmanı, Dense: Tam bağlı katman).

Derin öğrenme modellerinde çok sayıda hiperparametre olduğu ve bu hiperparametreler için geniş bir aralıkta denemeler yapılması gerektiği için hiperparametre optimizasyonu algoritma kullanılarak yapılmıştır. Keras Tuner adlı Python kütüphanesinde Hyperband (Li vd., 2018) algoritması kullanarak hiperparametre optimizasyonu yapılmıştır. Bu algoritma, verilen değer aralığı için gittikçe daha iyi hiperparametre kombinasyonlarının bulunmasını hedefleyen bir yapıdadır. Aranılan hiperparametre uzayı, değer aralığı ve seçilen değerler Tablo 2'de verilmiştir.

Tablo 2. Hiperparametre Uzayı ve Değer Aralığı

Hiperparametre	Arama Şekli	Değer Aralığı	Seçim
LSTM Birim Sayısı (Birinci Katman)	Optimum Sayı	35, 25, 15	15
LSTM Birim Sayısı (ikinci Katman)	Optimum Sayı	20, 10, 5	10
Öğrenme Oranı	Optimum Sayı	En küçük: 0.0001, en büyük: 0.01 Logaritmik seçim	0.00322
Küme Sayısı (Batch Size)	Optimum Sayı	En küçük: 256, en büyük: 1024, Adım: 64	384
Optimizasyon Fonksiyonu	Optimum Seçim	RMSprop veya Adam	RMSprop

Tablo 2'de verilen seçimler ile model eğitimi gerçekleştirilmiştir. Eğitim sürecinde eğitim ve doğrulama başarılarının değişimi Şekil 3'te verilmiştir. Doğrulama hatasının azalma eğiliminden saptığı 10. epok'a kadar eğitim devam ettirilmiştir.



Şekil 3. Modelin Kayıp Fonksiyonu.



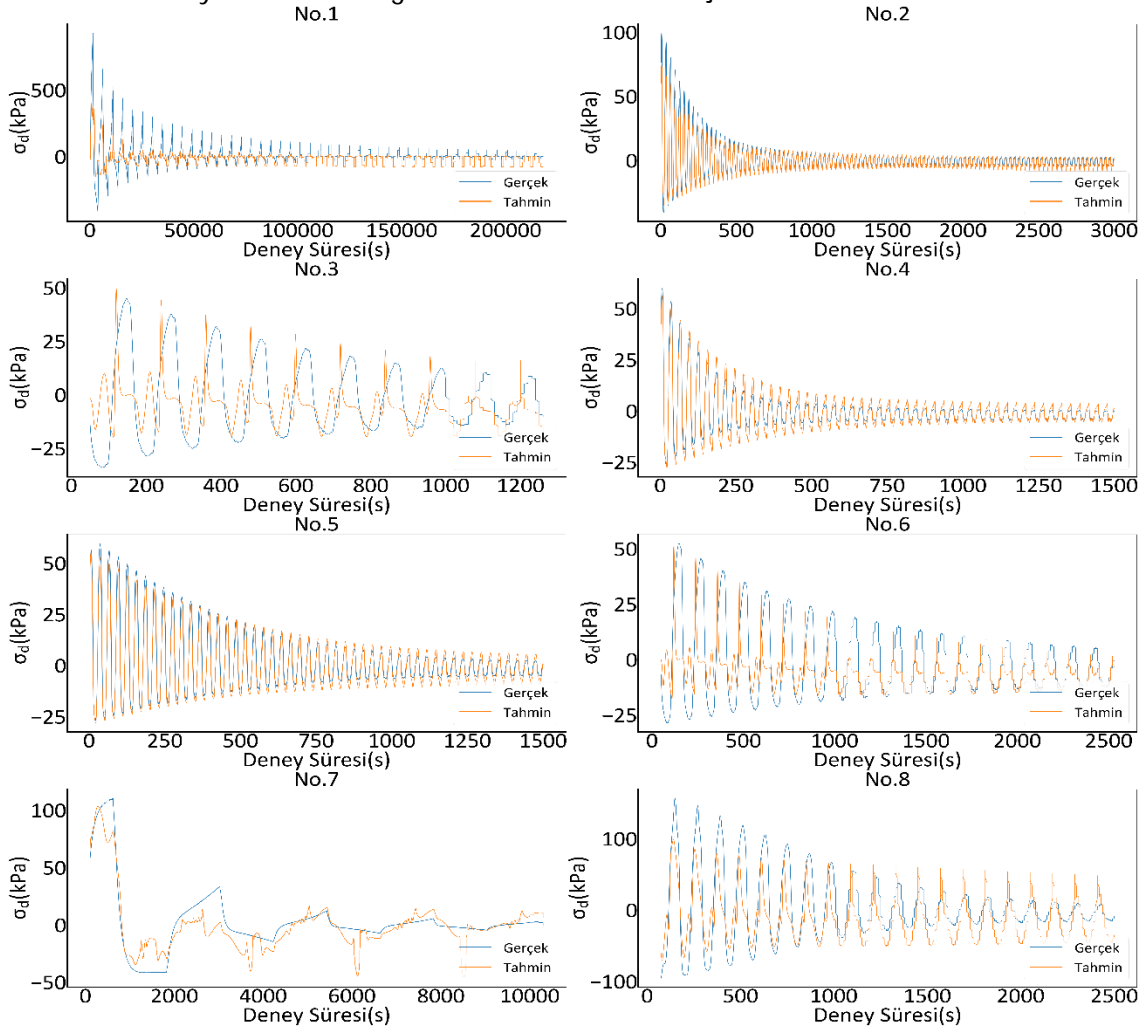
Modelde optimizasyon işleminden sonra ayrıca farklı eğitim ve doğrulama setlerinde model performansının nasıl değiştiği, dolayısıyla modelin dayanıklılığı K-Katmanlı Çapraz Doğrulama yöntemiyle sınanmıştır. K sayısı '5' olarak seçilmiştir. Tablo 3'te görüldüğü üzere, model farklı eğitim ve doğrulama setlerinde benzer sonuçlar vererek dayanıklılığını kanıtlamaktadır. Bu sonuç veri setinin tutarlı olduğunu ve Şekil 3'teki kayıp fonksiyonu ile birlikte eğitimin başarısını göstermektedir. Tüm öznitelikler 0 ve 1 arasında ölçeklendiği için modelin yaklaşık %1 hata ile tahmin yaptığı söylenebilir.

Tablo 3. K Katmanlı Çapraz Doğrulama Sonuçları

Katman	Eğitim Kaybı (MAE)	Doğrulama Kaybı (MAE)
1	0.005	0.016
2	0.007	0.006
3	0.006	0.007
4	0.006	0.007
5	0.007	0.009

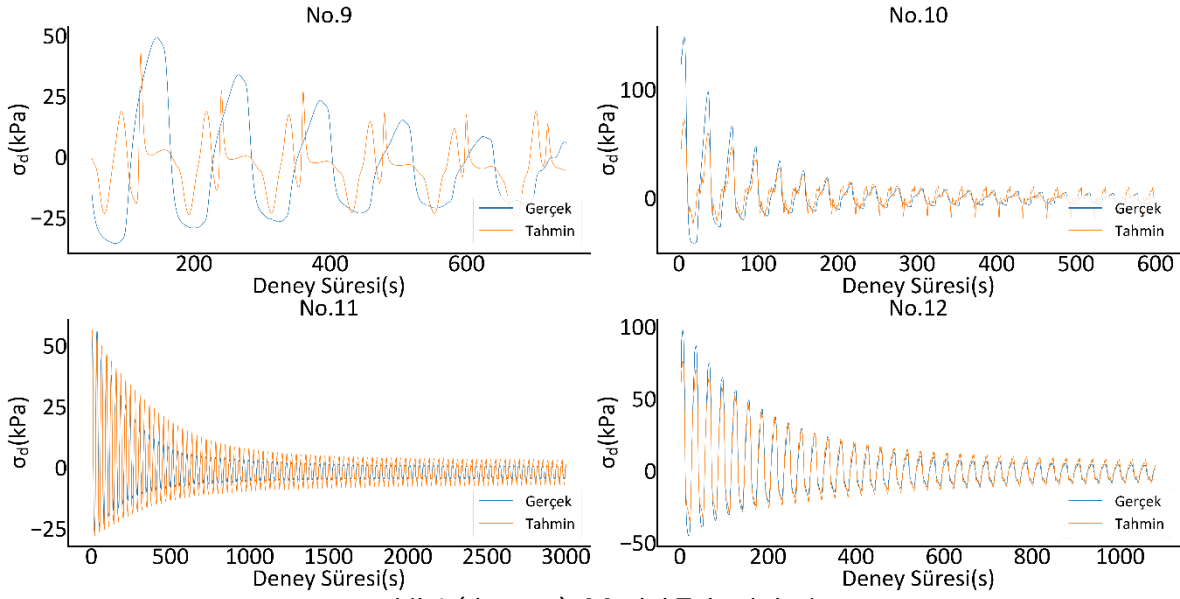
4. DEVIATORİK GERİLME DEĞİŞİMİ TAHMİNİ

Nihai modelin test seti üzerindeki performansı incelenmiştir. Şekil 4'te model tahminlerinin gerçek deney verisiyle karşılaştırılması, Tablo 4'te yapılan tahminlerin başarısı ve test setindeki deney verilerindeki girdi öznitelikleri verilmiştir.



Şekil 4. Model Tahminleri.





Şekil 4 (devamı). Model Tahminleri.

Tablo 4. Test Seti Öznitelikleri ve Hata Metrikleri

Test No.	r_e (%)	$D_{r,0}$ (%)	$\sigma'_{3,0}$ (kPa)	e_0	MAE	r^2
No.1	1.00	101.0	700	0.500	0.082	0.18
No.2	0.11	63.8	100	0.608	0.004	0.91
No.3	0.12	54.5	50	0.604	0.025	-0.01
No.4	0.08	40.0	100	0.668	0.004	0.89
No.5	0.05	40.0	100	0.668	0.005	0.94
No.6	0.10	54.5	50	0.604	0.019	0.13
No.7	0.50	63.0	200	0.614	0.016	0.77
No.8	0.11	54.5	200	0.604	0.049	0.44
No.9	0.18	54.5	50	0.604	0.029	0.02
No.10	0.30	75.6	100	0.576	0.011	0.72
No.11	0.06	40.0	100	0.668	0.005	0.83
No.12	0.10	63.8	100	0.608	0.005	0.96

12 adet deneyden, 5 tanesi 0.01'in altında ortalama mutlak hata (MAE) ile tahmin edilmiştir. 3 tane deneyde MAE 0.01 ile 0.02 arasındadır. Kalan 4 deneyde 0.02'den yüksek MAE ile tahmin yapılmıştır. Her deney serisi farklı veri adedi ve genişliğinden oluştuğu için, korelasyon katsayısı, r^2 ile MAE değerleri arasında birebir bir ilişki olmamakta, bu nedenle de bazı yüksek r^2 'li testlerin MAE değerleri de daha yüksek olabilmektedir. Model test setinde deviatorik gerilme değişimini yüksek başarıyla tahmin edebildiği görülmektedir.

5. SONUÇLAR

Bu çalışmada temiz kumlar üzerinde yapılan tekrarlı üç eksenli deneylerden elde edilen veritabanıyla eğitilen derin öğrenme yöntemlerini kullanarak yapılan deviatorik gerilme değişimi tahminleri yer almıştır. Çok sayıda gerçek deney verisinin, farklı kaynaklardan toplanması ile kapsamlı bir veritabanı oluşturulmuştur. Sonuçta, sıvılaşmanın tahmini için en geçerli derin öğrenme ve veri işleme yöntemleri ile optimum ve kararlı bir "Akıllı Bünye Modeli" geliştirilmiştir. Model ortalama mutlak hata cinsinden yaklaşık % 1 hata ile test tahmini yapabilmektedir. Bu da modelin temiz kumların sıvılaşmasını deviatorik gerilme



azalımı cinsinden iyi bir doğrulukla modelleyebildiğini göstermektedir. Boşluk suyu basıncı tahmini de yapılmış ancak bu bildirinin konusu dışında bırakılmıştır. Modelde şekil-değiştirme girdi, gerilme çıktı olarak yer aldığı için, nihai modelin sonlu elemanlar tabanlı programlara aktarılarak bir makro ölçek zemin dinamiği probleminde, klasik bünye modellerinin yerini alarak kullanılması mümkün olacaktır. Bu konuyla ilgili çalışma halen devam etmektedir.

TEŞEKKÜR

Bu çalışma TÜBİTAK 1001 "Deprem" çağrısı kapsamında 121M736 nolu araştırma projesi ile desteklenmiştir. Yazarlar TÜBİTAK'a teşekkürü bir borç bilir.

KAYNAKLAR

- Chen, W., Peña Olarte, A. A., ve Cudmani, R. (2021), "Modelling The Monotonic And Cyclic Behaviour Of Sands Using Artificial Neural Networks", EPJ Web of Conferences, Vol 249, doi:10.1051/epjconf/202124911015.
- Choi, Y., ve Kumar, K. (2022), "A Machine Learning Approach To Predicting Pore Pressure Response In Liquefiable Sands Under Cyclic Loading", doi:10.48550/arXiv.2206.07780.
- Dafalias, Y. F. (1986), "Bounding Surface Plasticity. I: Mathematical Foundation And Hypoplasticity", Journal Of Engineering Mechanics, Vol. 112(9), 966-987.
- Drakos, S. (2008), "Applications Of Artificial Intelligence In Constitutive Modelling Of Soils", (Yüksek Lisans Tezi), Swansea Üniversitesi.
- Elghoraiby, M. A., Park, H., ve Manzari, M. T. (2020), "Stress-Strain Behavior And Liquefaction Strength Characteristics Of Ottawa F65 Sand", Soil Dynamics and Earthquake Engineering, Vol. 138.
- Ellis, G. W., Yao, C., Zhao, R., ve Penumadu, D. (1995), "Stress-Strain Modeling Of Sands Using Artificial Neural Networks", Journal of Geotechnical Engineering, Vol 121(5), 429-435, doi:10.1061/(ASCE)0733-9410(1995)121:5(429).
- Ghaboussi, J., ve Sidarta, D. E. (1998), "New Nested Adaptive Neural Networks (NANN) For Constitutive Modeling", Computers and Geotechnics, Vol 22(1), 29-52.
- Guan, Q.Z., ve Yang, Z.X. (2022), "Hybrid Deep Learning Model For Prediction Of Monotonic And Cyclic Responses Of Sand", Acta Geotechnica, doi:10.1007/s11440-022-01656-9.
- Hochreiter, S., ve Schmidhuber, J. (1997), "Long Short-Term Memory", Neural Computation, Vol 9(8), 1735-1780, doi:10.1162/neco.1997.9.8.1735.
- Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., ve Talwalkar, A. (2018), "Hyperband: A Novel Bandit-Based Approach To Hyperparameter Optimization", Journal of Machine Learning Research, Vol. 18(185), 1-52.



- Ma, G., Guan, S., Wang, Q., Feng, Y. T., ve Zhou, W. (2022), "A Predictive Deep Learning Framework For Path-Dependent Mechanical Behavior Of Granular Materials", Acta Geotechnica, Vol. 17, 3463–3478, doi:10.1007/s11440-021-01419-y.
- Meng, F., ve Pei, H. (2023), "Cyclic Shear Stress-Strain Prediction Of Saturated Sand Based On The Unrolled Seq2seq Model And Scheduled Sampling", Soil Dynamics and Earthquake Engineering, Vol. 165, doi:10.1016/j.soildyn.2022.107665.
- Pastor, M., Zienkiewicz, O.C., ve Chan, A.H.C. (1990), "Generalized Plasticity And The Modelling Of Soil Behaviour", Int. J. Numer. Anal. Meth. Geomech., Vol. 14: 151-190, doi:10.1002/nag.1610140302.
- Schanz, T., Vermeer, P.A., ve Bonnier, P.G. (2019), "The Hardening Soil Model: Formulation And Verification", Beyond 2000 in Computational Geotechnics, Balkema, Rotterdam.
- Teng, Z.-C., Teng, Y.-C., Liu, J.-L., Zhou, Y.-D., Liu, X.-Y., Li, Z.-W., ve Tao, C.-Y. (2023), "Study On Triaxial Test And Constitutive Prediction Model Of Frozen Silty Clay", Frontiers in Earth Science, Vol. 10, doi:10.3389/feart.2022.1069182.
- Vasko, A., ElGhoraiby, M., ve Manzari, M. (2018), "LEAP-GWU-2015 Laboratory Tests", DesignSafe-CI, doi:10.17603/DS2TH7Q.
- Wang, M., Qu, T., Guan, S., Zhao, T., Liu, B., ve Feng, Y. (2022), "Data-Driven Strain–Stress Modelling Of Granular Materials Via Temporal Convolution Neural Network", Computers and Geotechnics, Vol. 152, 105049, doi:10.1016/j.compgeo.2022.105049.
- Wang, Z. L., Dafalias, Y. F., ve Shen, C. K. (1990), "Bounding Surface Hypoplasticity Model For Sand", Journal Of Engineering Mechanics, Vol. 116(5), 983-1001.
- Wichtmann, T., ve Triantafyllidis, T. (2016), "An Experimental Data Base For The Development, Calibration And Verification Of Constitutive Models For Sand With Focus To Cyclic Loading. Part II - Tests With Strain Cycles And Combined Loading", Acta Geotechnica, Vol. 11, 763-774, doi:10.1007/s11440-015-0412-x.
- Zhang, N., Zhou, A., Jin, Y.-F., Yin, Z.-Y., ve Shen, S.-L. (2023), "An Enhanced Deep Learning Method For Accurate And Robust Modelling Of Soil Stress–Strain Response", Acta Geotechnica, Vol. 18, 1-23, doi:10.1007/s11440-023-01813-8.
- Zhang, P., Yin, Z., Jin, Y., ve Ye, G. (2020), "An AI-Based Model For Describing Cyclic Characteristics Of Granular Materials", International Journal for Numerical and Analytical Methods in Geomechanics, doi:10.1002/nag.3063.
- Zienkiewicz, O. C. (1982), "Generalized Plasticity And Some Models For Geomechanics", Applied Mathematics and Mechanics, Vol. 3(3), 303-318.

SEMBOL LİSTESİ

Sembol	Açıklama	Sembol	Açıklama
t	Deney süresi	ϵ	Çevrimsel şekil değiştirme oranı
$D_{r,0}$	Başlangıç rölatif sıklığı	e_0	Başlangıç boşluk oranı
$\sigma'_{3,0}$	Başlangıç efektif çevre basıncı	σ_d	Deviatorik gerilme

