Zemin Mekaniği ve Geoteknik Mühendisliği
20. Ulusal Konferansı

15-16 Ekim 2026
Sakarya Üniversitesi

SIVILAŞMA İÇİN AKILLI BÜNYE MODELİ VE SAHA TEPKİ ANALİZLERİNDE KULLANIMI

THE SMART CONSTITUTIVE MODEL FOR LIQUEFACTION AND ITS APPLICATION TO SITE RESPONSE ANALYSIS

Muhammed Furkan YILMAZ[1], Ömer Tuğşad BİRİNCİ[2], Mehmet Barış Can ÜLKER[3]

ÖZET

Temiz kumların çevrimsel yükler altındaki sıvılaşma davranışını modellemek amacıyla, yalnızca şekil değiştirme kontrollü dinamik üç eksenli deney sonuçlarına dayalı ve derin öğrenme tabanlı bir "akıllı bünye modeli (ABM)" son haline getirilmiştir. ABM, deprem etkisiyle sahadaki sıvılaşma davranışını, geleneksel plastisite teorilerine başvurmadan tahmin edebilen yeni nesil bir yaklaşım önerir. Model, çok sayıda deneyden elde edilen şekil değiştirme-zaman değişimleri gibi vektörel büyüklüklerle, relatif sıkılık ve efektif düşey gerilme gibi skaler verileri girdi kullanarak boşluk suyu basıncı ve deviatorik gerilme tarihçesini tahmin eder. Geliştirilen özgün makine öğrenmesi modeli sıvılaşmayı davranışın tüm zaman geçmişi değişimleriyle öngörebilmekte, buna göre Uzun Kısa Dönem Hafıza (LSTM) modelini kullanarak, bir sonraki zamanda bilinmeyeni bir önceki zaman adımında elde edilen parametre değerine bağlı tahmin edebilmektedir. ABM tahminleri, tekrarlı üç eksenli verileri ve mevcut plastisite modelleriyle doğrulandıktan sonra, Python ortamında yazılan bir sonlu elemanlar programına aktarılmıştır. Geliştirilen özgün sonlu elemanlar-derin öğrenme arayüzü ile entegre edilen ABM, deprem yükleri altında bir boyutlu ve tek tabakalı saha tepki analizlerine başarıyla uygulanmıştır. Ardından model 6 Şubat 2023 Kahramanmaraş depremlerinde Hatay'da sıvılaşan gerçek zemin profillerine vaka analizi olarak uygulanmıştır. Sonuçlarda, düşük relatif sıkılık ve efektif çevre gerilmeleri hariç farklı sıkılık ve derinliklerdeki temiz kumların boşluk suyu basıncı artışı ve efektif gerilme azalımı başarıyla modellenmiştir.

Anahtar Kelimeler: *Bünye modeli, LSTM, makine öğrenmesi, sıvılaşma, sonlu elemanlar, temiz kumlar*

ABSTRACT

A deep learning-based "intelligent constitutive model (ICM)" is developed to model the liquefaction behavior of clean sands under cyclic loading, using exclusively strain-controlled cyclic triaxial test data. The study proposes a next-generation approach for predicting field-scale liquefaction under earthquake loading without relying on conventional plasticity-based constitutive models. The ICM predicts excess pore-water pressure and deviatoric stress histories using vector inputs, such as strain-time histories obtained from numerous experiments, together with scalar variables including relative density and effective confining stress. Unlike conventional machine-learning approaches that predict liquefaction through a single parameter, the proposed model captures the complete time-history response using a Long Short-Term Memory (LSTM) architecture, where each unknown state is predicted based on information from preceding time steps. Following validation against cyclic triaxial test data and established plasticity models, the ICM is implemented in a finite element (FE) program developed in Python. Through a novel FE–deep learning interface, ICM is successfully applied to 1-D, single-layer seismic site-response analyses and to liquefied soil profiles in Hatay during the February

[1] Doktora Öğrencisi, İstanbul Teknik Üniversitesi, yilmazmuha23@itu.edu.tr
[2] Yük. Müh., On Zemin Mühendisliği ve İnşaat Ltd. Şti., birinci17@itu.edu.tr
[3] Prof. Dr., İstanbul Teknik Üniversitesi, mbulker@itu.edu.tr (Sorumlu yazar)

6th 2023 earthquakes. Results demonstrate accurate prediction of pore-pressure buildup and effective stress reduction across varying densities and depths, except at low relative densities and effective confining stresses.
Keywords: *Clean sands, constitutive model, finite elements, liquefaction, LSTM, machine learning*

1. GİRİŞ

Deprem etkisi altında sıvılaşabilen temiz kum zeminlerin dinamik davranışlarının doğru modellenmesi, modern geoteknik deprem mühendisliğinin oldukça kritik problemlerinden biridir. Geleneksel plastisite temelli teorik bünye modelleri (örn. tekrarlı plastisite modelleri), karmaşık gerilme–şekil değiştirme ilişkilerini ve boşluk suyu basıncı gelişimini tam anlamıyla temsil etmekte sınırlı kalmaktadır. Birçok model ya gözlenen davranışı bütünüyle modelleyememekte ya da çok fazla sayıda parametre gerektirdiklerinden; bu durum modelleri aşırı karmaşık ve pratik uygulamalar açısından elverişsiz hâle getirmektedir. Uygulamada ise mühendisler, karmaşık problemlerin çözümünde çoğunlukla hızlı, basit ve aynı zamanda yeterli doğrulukta yöntemleri tercih etmektedir. Ancak bu yaklaşım, problemin aşırı basitleştirilmesine veya hatalı kabullerin yapılmasına yol açabilmektedir. Bu tür basitleştirmeler, mühendisleri daha muhafazakâr güvenlik katsayıları kullanmaya yöneltebilmekte ve buna rağmen zemin göçmesi riskinin yeterince doğru değerlendirilememesine neden olabilmektedir. Bu nedenle kullanılan sayısal yöntemlerle (örn. Sonlu Elemanlar Yöntemi, SEY) gerçekleştirilen saha tepki analizlerinin doğruluğu büyük ölçüde kullanılan bünye modelinin güvenilirliğine bağlıdır. Bu nedenle, yapay zekâ çağında teorik kabullere dayanmaksızın doğrudan laboratuvar verilerinden öğrenebilen ve "akıllı bünye modelleri (ABM)" olarak adlandırılabilecek yeni nesil modellerin geliştirilmesine duyulan ihtiyaç giderek artmaktadır.

Veri odaklı yöntemlerle zeminlerin çevrimsel davranışının tahmin edilmesine yönelik çalışmaların sayısı halen sınırlıdır. Bu çalışmaların bir kısmı yapay olarak üretilmiş verilerden yararlanırken, diğerleri gerçek laboratuvar deney sonuçlarını kullanmaktadır. Örneğin Zhang vd. (2021), Guan ve Yang (2023) ve Drakos (2008) yapay veriler kullanırken; Chen vd. (2021), Choi ve Kumar (2023) geliştirdikleri modelleri deneysel verilere dayandırmıştır. Yapay Sinir Ağı (YSA) tabanlı modeller, plastisite, viskoelastisite ve göçme gibi yükleme geçmişine bağlı malzeme davranışlarının modellenmesinde oldukça gelişmiş ve başarılı yöntemlerdir. Geleneksel SEY'de bu davranışlar, iteratif çözüm yöntemleri gerektiren karmaşık bünye denklemleri kullanılarak modellenmektedir. Buna karşılık YSA'lar, söz konusu davranışları doğrudan veriden öğrenebilmektedir. Son yıllarda sıvılaşmanın modellenmesi amacıyla çeşitli sayısal araçlar ve bünye modelleri kullanılmış olmakla birlikte, bu modeller için gerekli parametrelerin belirlenmesi zaman alıcı bir süreç hâline gelmiştir. Makine öğrenmesi algoritmalarının geleneksel sayısal yöntemlerle bütünleştirilebilmesi için YSA modellerinin sonlu elemanlar ortamına uygulanması gerekmektedir. Geleneksel malzeme modelleri önceden tanımlanmış bünye bağıntılarına dayanırken, YSA tabanlı modeller daha esnek ve veri odaklı bir yaklaşım sunmaktadır. Bu esneklik, açık matematiksel fonksiyonların tanımlanmasına duyulan gereksinimi ortadan kaldırarak karmaşık gerilme–şekil değiştirme ilişkilerinin doğrudan öğrenme süreci aracılığıyla modellenmesine olanak sağlar (Wu ve Ghaboussi, 1995). Eğitilmiş YSA'nın sonlu elemanlar ortamına aktarılmasıyla, geleneksel bünye modeli yerine ABM kullanılabilmekte ve ABM, sonlu elemanlar çözümünde kullanılan klasik malzeme alt programının işlevini üstlenmektedir. Burada önemli olan, ABM'nin kullanımı sırasında eleman integrasyon noktalarında çalışarak doğru şekil değiştirme vektörleri için doğru gerilme karşılıklarını tahmin etmesidir. Zira analizin devamında bu gerilme vektörü, tanjant rijitlik matrisi hesabında kullanılacaktır. Ghaboussi (2018), tanjant rijitlik matrisinin elde edilmesi için iki farklı yöntem önermiştir: YSA tabanlı yapısal modelde matrisin doğrudan

sinir ağının bağlantı ağırlıklarından hesaplanması ve YSA mimarisindeki her bir katman için fonksiyonların tanımlandığı ağırlıklara dayalı açık bir bünye formülasyonu kullanımıdır.

Liang vd. (2023), YSA modellerini SEY ile bütünleştirmek amacıyla PyTorch gibi derin öğrenme araçlarından yararlanmıştır. PyTorch derin öğrenme altyapısı, büyük ölçekli sayısal analizlerde makine öğrenmesi tabanlı yaklaşımın avantajlarını ortaya koymakta ve şekil değiştirmeye bağlı olarak bünye modellerinin eş zamanlı güncellenmesine olanak sağlamaktadır. YSA tabanlı modeller, plastisite, viskoelastisite ve yenilme davranışı gibi gerilme izine bağlı malzeme davranışlarını ele almada oldukça gelişmiştir. Geleneksel SEA'da bu davranışlar, iteratif çözüm yöntemleri gerektiren karmaşık bünye denklemleri kullanılarak modellenir. Ancak YSA'lar bu davranışları doğrudan verilerden öğrenebilir. Örneğin, Mozaffar vd. (2019) derin öğrenme yöntemlerinin, malzemenin çevrimsel yükleme ve boşaltma davranışını modelleyerek yükleme yoluna bağlı plastisiteyi tahmin etme kabiliyetini göstermiştir. Son dönemde Birinci vd. (2023) tekrarlı yükler altında artık boşluk suyu basıncı artışlarını LSTM yöntemiyle ve dinamik basit kesme deney verilerinden tahmin etmiş, Birinci ve Ülker (2024) tahminlere dinamik üç eksenli deney verileriyle oluşturduğu veritabanıyla efektif gerilme tarihçesini de eklemiştir. Birinci vd. (2025), bu iki veritabanından gelen tahminleri birleştirdikten sonra geniş kapsamlı gerçek tekrarlı basit kesme ve tekrarlı üç eksenli deney verilerini kullanarak zemin sıvılaşmasını geniş bir relatif sıkılık ve efektif düşey gerilme aralığında modelleyecek hale getirmiştir. Devam niteliğindeki bu çalışmada ise ABM, Python tabanlı bir arayüz aracılığıyla doğrudan sonlu elemanlar algoritmasına entegre edilmiştir.

Özetle, deprem etkisinde temiz ve gevşek kumlarda meydana gelen sıvılaşma davranışını tahmin eden ABM, şekil değiştirme kontrollü tekrarlı üç eksenli deney verileri ve mevcut plastisite modellerinden UBCSAND ile doğrulandıktan sonra, yine bu çalışmada yazılan ve zemini iki fazlı geçirimli ortam olarak kabul eden bir poro-elasto-plastik sonlu elemanlar programına aktarılmıştır. Çalışmada özgün bir sonlu elemanlar-derin öğrenme arayüzü geliştirilmiş, SEY'e entegre edilen ABM, deprem yükleri altında bir boyutlu ve tek tabakalı saha tepki analizlerinde kullanılmıştır. Sonra model, 6 Şubat 2023 Kahramanmaraş depremlerinde Hatay ve çevresinde meydana gelen sıvılaşma bölgelerinden elde edilen zemin profillerinin saha tepki analizlerine uygulanmıştır.

2. AKILLI BÜNYE MODELİ

Bu çalışma kapsamında sıvılaşabilir kumların çevrimsel yükleme altındaki davranışını tahmin etmek amacıyla makine öğrenmesi tabanlı bir ABM geliştirilmiştir. Model veri tabanı, üç farklı kaynaktan derlenen toplam 56 deformasyon kontrollü tekrarlı üç eksenli (CTX) deneyden oluşmaktadır (Tablo 1). Deneylerin tamamı temiz kumlar üzerinde yapılmaktadır; ancak relatif sıkılık, başlangıç boşluk oranı, çevre basıncı, deformasyon seviyesi ve deney süresi bakımından geniş bir aralık kapsanmaktadır. Model girdileri zaman (t), birim şekil değiştirme (ε), başlangıç relatif sıkılık ($D_{r,0}$), başlangıç boşluk oranı (e_0) ve başlangıç efektif çevre basıncı ($\sigma'_{3,0}$); çıktıları ise artık boşluk suyu basıncı oranı (r_u) ve deviatorik gerilmenin (σ_d) zamanla değişimleri olarak tanımlanmıştır. Zaman serisi biçimindeki deney verilerinin daha etkin öğrenilebilmesi için "windowing" adı verilen bir veri ön işleme yöntemi uygulanmıştır. Girdi ve çıktı dizileri sabit uzunluklu parçalara ayrılırken pencere boyutu 50 olarak seçilmiş ve her giriş penceresi için bir adımlı tahmin üretilmiştir. Bu seçim, deneylerdeki veri toplama sıklığı ile modelin çevrimsel davranış ayrıntılarını yakalayabilme başarısı dikkate alınarak yapılmıştır. Artık boşluk suyu basıncı ve deviatorik gerilmenin zamana bağlı tahmini bir zaman serisi problemi olduğundan, çalışmada tekrarlayan sinir ağları içerisinden Uzun Kısa Dönem Hafıza (Long Short-Term

Memory, LSTM) mimarisi tercih edilmiştir. LSTM, önceki zaman adımlarındaki bilgiyi sonraki adımlara aktarabilmesi ve tahminler sırasında kaybolan gradyan problemine karşı dayanıklı olması nedeniyle uygun görülmüştür.

Tablo 1. CTX veri tabanında kullanılan deney kaynakları ve parametre aralıkları

Veritabanı	ε (%)	$D_{r,0}$(%)	e_0	$\sigma'_{3,0}$ (kPa)	t (s)	Zemin türü
ElGhoraiby ve Manzari (2018)	0.041–0.301	40–76	0.58–0.67	100	600–6000	Ottawa kumu
Wichtmann & Triantafyllidis(2016)	0.062–1.01	29–101	0.50–0.72	100-700	8960–218000	Karlsruhe ince kumu
Vasko vd. (2018)	0.061–0.497	55	0.60	50–200	456–9000	Ottawa kumu

Nihai ABM, iki LSTM katmanından oluşmaktadır. İlk katman üç boyutlu giriş tensörlerini işlerken ikinci katman bu tensörleri kullanarak r_u ve σ_d tahminlerini üretmektedir. Toplamda 56 deneyin 35'i eğitim, 9'u doğrulama ve 12'si test kümesine ayrılmıştır. Kayıp fonksiyonu, ortalama karesel hata (MSE), hata metriği ise ortalama mutlak hata (MAE) ile hesaplanmıştır. Model mimarisinin ihtiyaç duyduğu hiperparametrelerin belirlenmesinde Hyperband arama yöntemi kullanılmış ve model Keras kütüphanesi üzerinden Python ortamında eğitilmiştir. Şekil 1'de modelin kayıp fonksiyonu görülebilir. Eğitim, eksik öğrenme–aşırı öğrenme dengesi dikkate alınarak 11. epoch'ta sonlandırılmıştır. Hiperparametreler ve uygun epoch sayısı belirlendikten sonra doğrulama verileri eğitim verilerine eklenmiş ve nihai model yeniden eğitilmiştir. Model daha önce hiç görmediği test kümesi üzerinde değerlendirilmiştir.

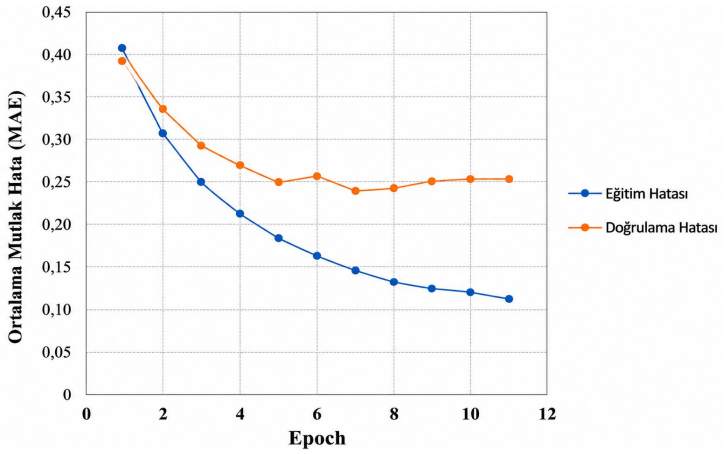

Şekil 1. Nihai modelde eğitim ve doğrulama kayıplarının epoch sayısına bağlı değişimi

Şekil 2'de ABM'nin boşluk suyu basıncı oranındaki artışı ve deviatorik gerilmenin çevrimsel sönümlenmesini genel olarak başarılı ürettiği görülebilir. Bununla birlikte, yüksek çevrimsel birim şekil değiştirme oranı, daha uzun deney süresi ve daha yüksek çevre basıncına sahip No. 3 testinde performansın diğer testlere göre düştüğü görülmüştür. Bu durum, eğitim veri setinin miktarı ve çeşitliliğinin modelin genelleme başarısı açısından kritik olduğunu ortaya koymaktadır. Bütün testlere ait performans verileri Tablo 3'te özet olarak sunulmuştur.

Tablo 3. Test veri setindeki giriş özellikleri ve hata metrikleri

Test	ε (%)	$D_{r,0}$ (%)	$\sigma'_{3,0}$ (kPa)	e_0	MAE (r_u)	R^2 (r_u)	MAE (σ_d)	R^2 (σ_d)
No. 1	0.11	63.8	100	0.61	0.012	0.96	1.534	0.97
No. 2	0.05	40.0	100	0.67	0.036	0.92	2.439	0.93
No. 3	0.50	63.0	200	0.62	0.069	0.54	8.737	0.73
No. 4	0.10	63.8	100	0.61	0.016	0.97	1.749	0.98

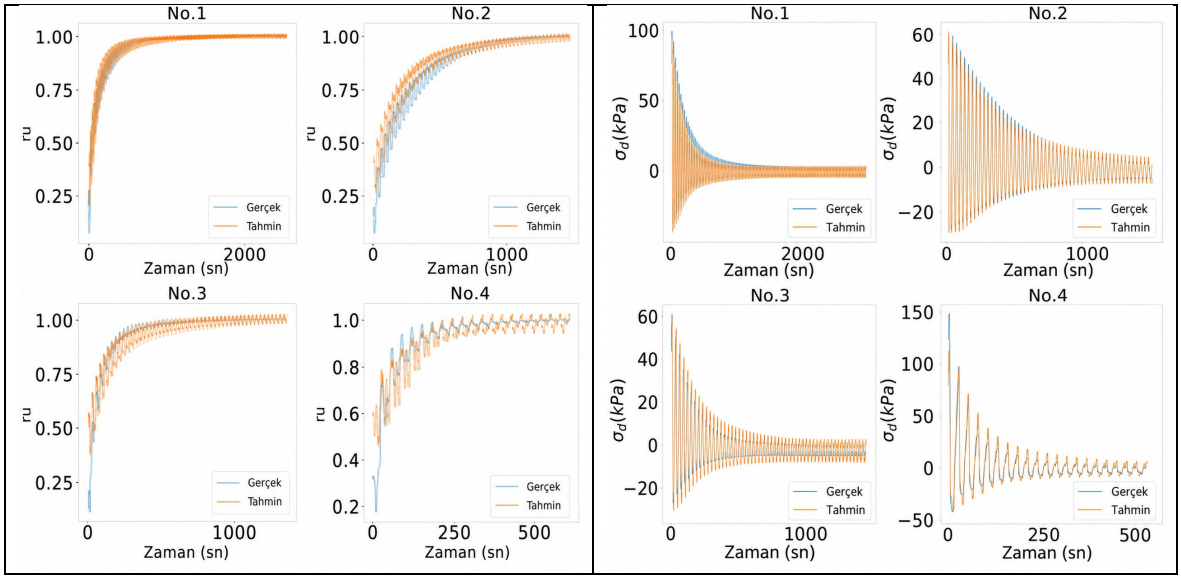

Şekil 2. Test kümesinde ABM tarafından tahmin edilen r_u ve σ_d

2.1. Plastisite Modeli ile ABM Doğrulanması

ABM'nin performansını değerlendirmek için farklı zemin koşullarında elde edilen zamana bağlı şekil değiştirme değişimleri hesaplanmıştır. Bunun için önce Loma Prieta depreminin Gilroy #2 istasyonunda kaydedilen deprem kaydı alınmış ve PLAXIS-2D ile bir dizi zemin tepki analizi yapılmıştır. Analizlerde sıvılaşmayı modelleyebilmek için UBCSAND modeli kullanılmış, model parametreleri Beaty and Byrne (2011)'in önerdiği SPT darbe sayısına bağlı yaklaşımla kalibre edilmiştir. Buna göre sonlu elemanlar analizlerinden elde edilen birim şekil değiştirme serileri, gerilme ve boşluk basıncı oranı tahminlerinde kullanılmak üzere ABM'ye girdi vektörü olmuştur. Ardından ABM ile tahmin edilen σ_d ve r_u, analiz sonuçları ile Şekil 3 ve Şekil 4'te gösterildiği üzere kıyaslanmıştır.

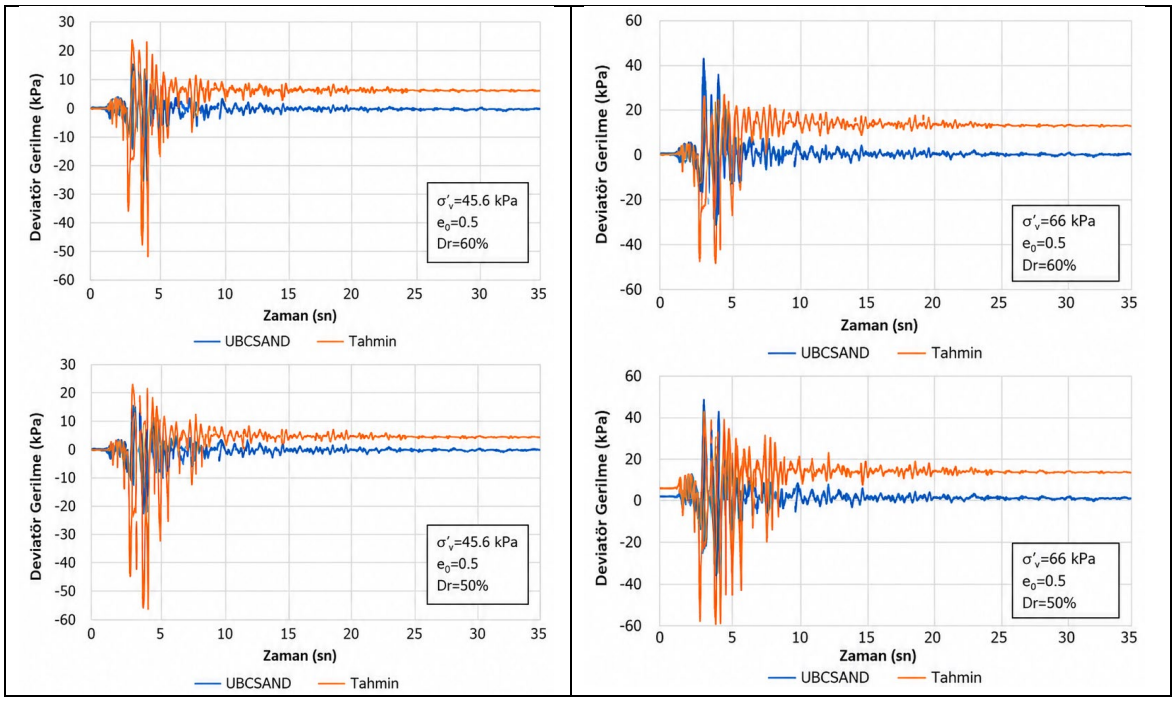

Şekil 3. Düzensiz deprem kaydı koşullarında deviatorik gerilme-zaman tarihçesi tahminleri

İncelenen tüm zemin durumlarında davranış eğilimleri oldukça iyi bir uyum gösterse de, tahmin edilen deviatorik gerilme büyüklüklerindeki farklılık, ABM tahminlerini elde etmek amacıyla kullanılan söz konusu analizler sonucunda elde edilen birim şekil değiştirmelerin zamana bağlı değişimleri ve mertebeleriyle ilişkilidir.

3. SONLU ELEMANLAR ENTEGRASYONU

Bu çalışmada ele alınan sıvılaşabilir suya doygun temiz kum zeminlerin dinamik davranışlarının matematiksel formülasyonu ve sayısal analizi bu bölümde sunulmuştur. Çalışma kapsamında geliştirilen ABM'nin, zeminin tekrarlı yükleme koşulları altındaki bünye davranışını temsil edebilmesi amacıyla poroelastisite teorisi ile kullanılması sağlanmıştır. Buna göre formülasyonda zeminin katı fazının (zemin iskeleti) hareketinden gelen atalet terimleri korunurken, boşluk suyunun hareketine bağlı ivme terimleri ihmal edilmiş ve kısmi dinamik formülasyon kullanılmıştır (Ülker ve Rahman, 2009). Böylece tekrarlı yüklemeler sırasındaki boşluk suyu basıncı değişimlerinin efektif gerilmeler ve buna bağlı zemin deformasyonları üzerindeki etkileri çözüm sürecine dahil edilmiştir. Denklemler doğrusal olmayan ve bağlaşık akış-deformasyon denklemleri halinde yazılır. Sonlu elemanlar modelinde bu doğrusal olmayan formülasyonun iki fazlı zemin için (poro-inelastik) yazılmış hali programlanmıştır. Formülasyon daha sonra SEY ile ayrıklaştırılıp, Python-Keras tabanlı hibrit bir sonlu elemanlar programı geliştirilmiştir. Bağlaşık hareket denkleminin zamanda integrasyonu için kapalı Newmark-β yöntemi uygulanmıştır. Doğrusal olmayan davranışın çözümünde tam Newton-Raphson yöntemi kullanılmıştır.

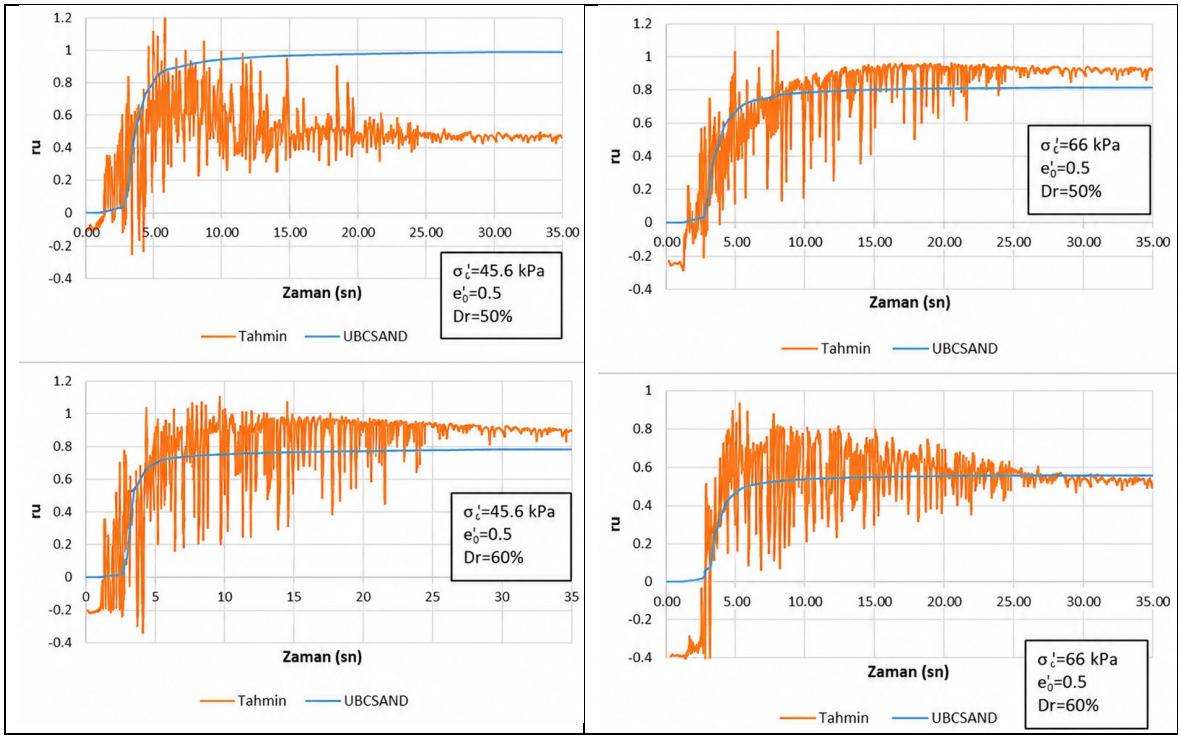

Şekil 4. Düzensiz yükleme (deprem kaydı) koşullarında r_u tahminleri

3.1 Sayısal Formülasyon

Formülasyonda ayrıklaştırılmış bağlaşık hareket denkleminin nihai biçimi:

$$\begin{bmatrix} M_s & 0 \\ M_f & 0 \end{bmatrix}\begin{bmatrix} \ddot{u} \\ \ddot{p} \end{bmatrix} + \begin{bmatrix} 0 & 0 \\ C^T & C_f \end{bmatrix}\begin{bmatrix} \dot{u} \\ \dot{p} \end{bmatrix} + \begin{bmatrix} K_s & -C \\ 0 & K_f \end{bmatrix}\begin{bmatrix} u \\ p \end{bmatrix} = \begin{bmatrix} F_1 \\ F_2 \end{bmatrix} \quad (1)$$

şeklindedir. Burada; $M_s = \int N^{u^T} \rho N^u d\Omega$ ve $M_f = \int B^{p^T} \frac{k}{g} N^u d\Omega$ matrisleri sırasıyla katı ve sıvı fazın kütle matrislerini; $K_s = \int B^{u^T} \underline{\underline{D}}\, B^u d\Omega$ ve $K_f = \int B^{p^T} \frac{k}{\rho_f g} B^p d\Omega$ matrisleri katı ve sıvı fazın rijitlik matrislerini; $C = \int B^{u^T} m\, N^p d\Omega$ deplasman ve boşluk suyu basıncı arasındaki bağlaşık matrisi, $C_f = \int N^{p^T} \frac{k}{K_f} N^p d\Omega$ sıvı fazın sıkışmazlık matrisi. N^u, N^p, B^u ve B^p sırasıyla katı ve sıvı fazların şekil fonksiyonlarını ve birim şekil değiştirme-yer değiştirme matrislerini ifade etmektedir. F_1 ve F_2 zati yük ve sınır etkilerini ifade eden vektörleri göstermektedir. Burada sıvı fazın, katı faz hareketi üzerindeki etkileriyle ilişkili kütle matrisi, M_f ihmal edilmiştir. Denklem (1)'i doğrusal olmayan şekliyle yazacak olursak:

$$\boldsymbol{M\ddot{X} + C\dot{X} + R_{int} = F} \quad (2)$$

elde edilir. $\boldsymbol{M}$ ve $\boldsymbol{C}$ nihai kütle ve sönüm matrislerini, $\boldsymbol{F}$ eşitliğin sağ tarafındaki yük vektörünü göstermektedir. $\boldsymbol{R_{int}}$ efektif gerilme terimlerini içeren dengelenmemiş iç kuvvet vektörünü ifade eder. Zamanda integre edilmiş denklem (2) şu hali alır:

$$\hat{k} = k + \frac{1}{\beta \Delta t^2}\boldsymbol{M} + \frac{\gamma}{\beta \Delta t}\boldsymbol{C} \quad (3)$$

$$\hat{F}_i = \boldsymbol{F}_i + \left[\frac{1}{\beta \Delta t^2}\boldsymbol{M} + \frac{\gamma}{\beta \Delta t}\boldsymbol{C}\right] X_{i-1} + \left[\frac{1}{\beta \Delta t}\boldsymbol{M} + \left(\frac{\gamma}{\beta} - 1\right)\boldsymbol{C}\right] \dot{\boldsymbol{X}}_{i-1} + \left[\left(\frac{1}{2\beta} - 1\right)\boldsymbol{M} + \left(\frac{\gamma}{2\beta} - 1\right)\boldsymbol{C}\right] \ddot{\boldsymbol{X}}_{i-1} \quad (4)$$

$$\hat{r}_i = \hat{F}_i - \boldsymbol{R}_{int,i} - \left[\frac{1}{\beta \Delta t^2}\boldsymbol{M} + \frac{\gamma}{\beta \Delta t}\boldsymbol{C}\right] X_i \quad (5)$$

Burada (3) ve (4) efektif algoritmik rijitlik matrisini ve yük vektörünü, (5) algoritmik dengelenmemiş yük vektörünü, Δt zaman adımını, γ ve β Newmark parametrelerini, i ise yükleme adımını göstermektedir. Bilinmeyen vektörünün çözümü denklem 3 ve 5 kullanılarak aşağıdaki gibi yapılır:

$$X_{i+1} = \hat{r}_i\, \hat{k}^{-1} \quad (6)$$

3.2 Algoritma

ABM, sonlu eleman çözücüsünden elde edilen birim kayma şekil değiştirmeleri ve diğer girdi özniteliklerini kullanarak, gerilme değişimlerini tahmin etmek üzere sonlu eleman modeline bir malzeme alt rutini olarak entegre edilmiştir. Her bir zaman adımı veya yük artımında sonlu eleman çözücüsü, deplasmanları ve diğer değişkenleri tahmin edebilmek için ABM'den teğetsel rijitlik matrisini güncellemesini ister. Bu süreç bir eleman için yerel malzeme davranışını tahmin etmek için her bir iterasyonda Gauss noktalarında tekrarlanır. İlgili kod algoritması Şekil 5'te sunulmuştur. Teğetsel rijitlik matrisini oluşturmak için teğetsel rijitlik modülü, D_{tan}, mevcut TensorFlow kütüphanesi aracılığıyla ve LSTM tahmin geçmişi kullanılarak, mevcut parametre tahmini (N_θ) ve son adımdaki deformasyon vektörü (γ_{n+1}) ile birlikte şu şekilde hesaplanır:

$$\tau = N_\theta(\gamma_1, \gamma_2, \ldots, \gamma_{50}, D_r, \sigma_c', e_0) \longrightarrow D_{tan} = \frac{\partial N_\theta}{\partial \gamma_{n+1}} \longrightarrow K_t = \int B^T\, D_{tan}\, B\, dV \quad (7)$$

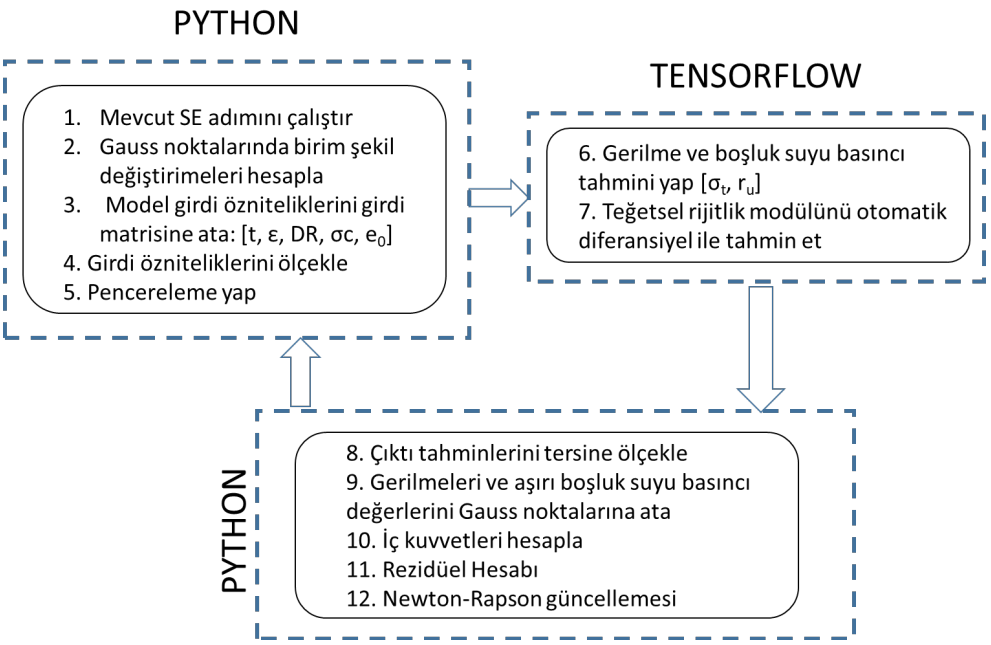

Şekil 5. Bağlaşık SEY-ABM algoritması

4. SEY-ABM BAĞLAŞIK ANALİZ SONUÇLARI

Bu bölümde, üniform bir zemin kolonuna, tabandan harmonik yük ve deprem ivme kaydı yüklenmiş, doğrusal olmayan davranış SEY ile Şekil 5'teki algoritma üzerinden analizler yapılmıştır. Sonuçlar aynı zemin ve sınır koşulları altında PLAXIS2D'de UBCSAND modeliyle yapılan analizlerle karşılaştırılmıştır. Böylece geliştirilen yeni sayısal yöntemin doğruluğu ve saha tepki analizindeki kabiliyeti araştırılmıştır. Analiz detayları Şekil 6'dadır.

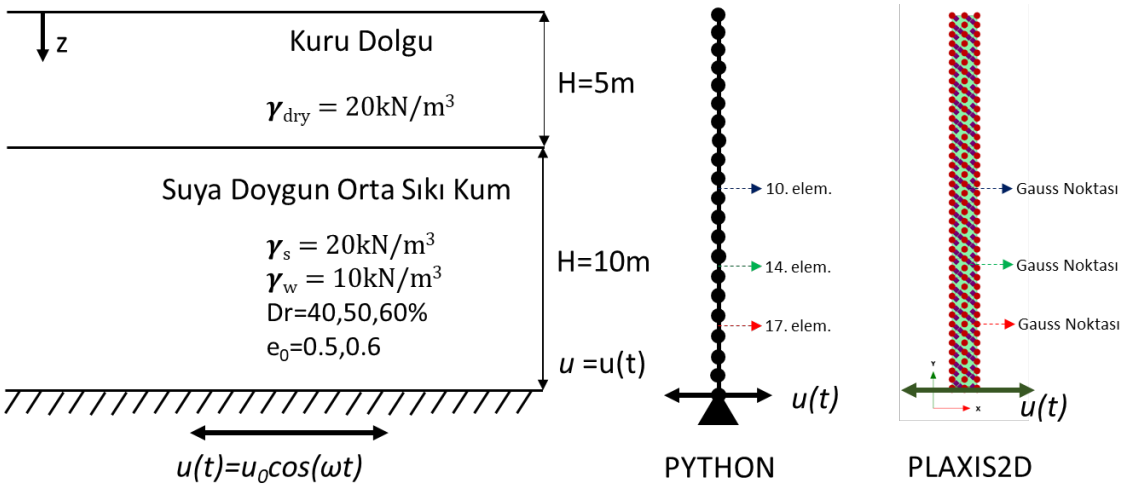

Şekil 6. Zemin tabakası parametreleri, yük ve sınır koşulları ve 1B modeli

Bulgulardan, özellikle 50 kPa'dan düşük çevre gerilmesi ve % 40'tan düşük relatif sıkılığa sahip gevşek kum zeminlerde modelin doğruluğunun azaldığı görülmüştür. Ayrıca ABM, UBCSAND modeline göre sıvılaşmayı daha erken zaman değerinde tahmin ederken, bunun ABM'nin eğitim setinde yer alan yükleme-zaman tarihçelerinin, sayısal analiz integrasyon hızına oranla daha büyük zaman adımına sahip olmasından kaynaklanabileceği değerlendirilmiştir.

4.1 1-B Zemin Tepki Harmonik Analizi Sonuçları

Harmonik yük altındaki analiz sonuçları Şekil 7'dedir. Model eğitim verisetindeki başlangıç çevre gerilmelerinin yüksek olmasından dolayı analiz modelinde 100kPa değerinde bir dolgu yükü olması için 5 m derinliğindeki üst tabaka, kuru dolgu tabakası olarak modellenmiştir.

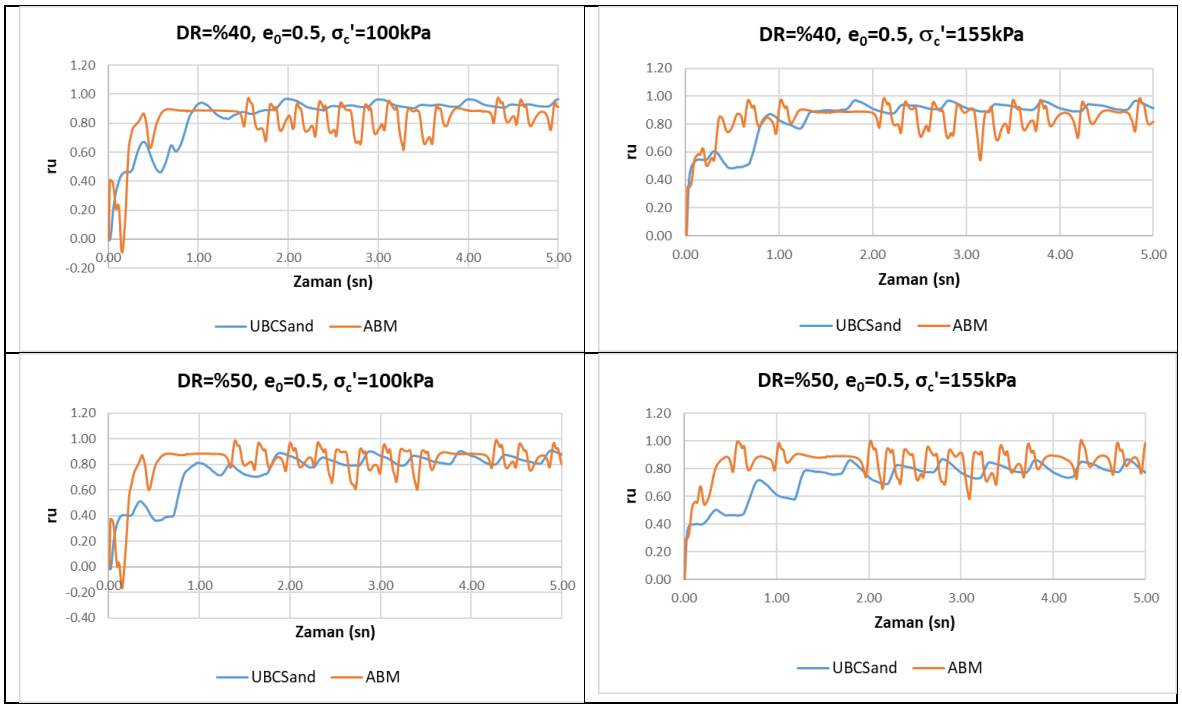

Şekil 7. Harmonik yükleme boşluk suyu basıncı oranı tahminleri

Elde edilen sonuçlar ABM'nin düzenli tekrarlı yükleme altında artık boşluk suyu basıncı birikimini doğru bir şekilde yansıttığını göstermektedir. ABM, UBCSAND modeline kıyasla daha hızlı boşluk suyu basıncı artışı göstermektedir; ancak model eğitim aralığı içinde yer alan durumlar için uzun vadeli boşluk suyu basıncı birikimi seviyesi, benzer seviyelerde bulunmaktadır.

4.2 1-B Zemin Tepki Analizi Deprem Kaydı Yüklemesi Sonuçları

Deprem kaydı yüklemesi altındaki zemin tepki analizi sonuçları bu bölümde sunulmuştur (Şekil 8). Deprem yüklemelerinde serbest saha koşullarında model performansını görmek amacıyla 15 m'lik üniform bir zemin kolonu sıvılaşabilir tabaka olarak dikkate alınmıştır. Analizlerde 1999 Kocaeli deprem kaydı kullanılmıştır. Sonuçlar incelendiğinde, ABM'nin r_u'nun zamanla gelişimine ilişkin genel eğilimi, UBCSAND modeliyle uyumlu biçimde temsil edebildiği görülmektedir. UBCSAND çözümünde r_u değeri zamanla kademeli olarak artıp bir süre sonra kararlı hâle gelirken, ABM sonuçlarında bu ortalama eğilimin üzerine belirgin çevrimsel ve kısa süreli dalgalanmalar binmektedir. Özellikle bazı zaman adımlarında gözlenen yüksek pik değerler, ABM'nin anlık tepkiyi UBCSAND modeline göre daha değişken tahmin ettiğini göstermektedir. Bununla birlikte, uzun dönem r_u seviyelerinin birbirine yaklaşması, ABM'nin genel olarak aşırı boşluk suyu basıncı birikimi davranışını yakalayabildiğine işaret etmektedir.

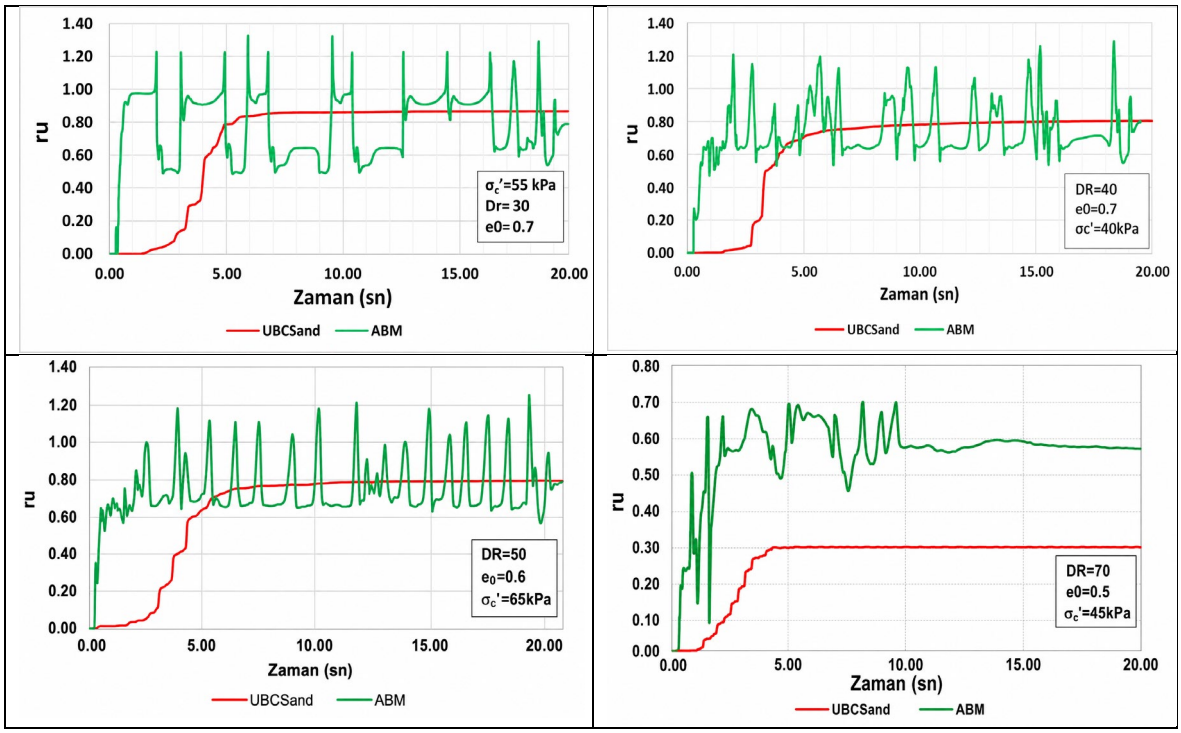

Şekil 7. Deprem yüklemesi boşluk suyu basıncı oranı tahminleri

5. SAHAYA ÖZGÜ VAKA ÇALIŞMASI

Bu çalışma kapsamında, 6 Şubat 2023 Kahramanmaraş depremleri sonrası Hatay ili İskenderun ilçesinde gerçekleştirilen saha araştırmaları sonucunda sıvılaşmanın tespit edildiği bölgelerden elde edilen geoteknik veriler doğrultusunda bir vaka analizi yapılmıştır. Tabakalaşma özellikleri, zemin parametreleri ve yeraltı su seviyesi dikkate alınarak 15 m derinliğinde bir adet zemin profili tanımlanmıştır. ABM'nin gerçek arazi koşullarındaki temsil kabiliyetini değerlendirmek amacıyla söz konusu profil için tek boyutlu saha tepki analizleri gerçekleştirilmiş; taban seviyesinden uygulanan deprem deplasman kaydı, taban hareketi olarak tanımlanmıştır. Analizlerde, deprem etkisi altında zemin kolonunda meydana gelen efektif gerilme azalım davranışı ile boşluk suyu basıncı gelişimi ABM ile tahmin edilmiştir. SPT ve presiyometre verileriyle, yapılan CPT ve laboratuvar deneylerinden zeminin indeks parametreleri ve modül değerleri belirlenmiştir. Ayrıca elde edilen verilere göre relatif sıkılık değerleri Idriss ve Boulanger (2008) tarafından sıvılaşabilir kum zeminler için önerilen eşitlik ile hesaplanmıştır. Analizde kullanılan parametreler Tablo 4'tedir. Sonuçlarda r_u'nun birikerek artışı güvenilir doğrulukla tahmin edilmiş, sıvılaşmaya giden zaman adımlarında ve belli derinliklerde r_u=1 koşulu yakalanabilmiştir (Şekil 9). Trendlerde ise gerçekte olduğundan daha yüksek genlikli osilatif davranış gözlenmiştir. Bu durum analiz parametrelerinin, eğitim setindeki veri aralıklarının dışında kalmasından kaynaklıdır.

Tablo 2. Hatay zemin profili ve ABM girdi öznitelikleri

Zemin Tipi	Derinlik (m)			Model	Dr (%)	e_0	G (MPa)
Siltli Kum-1	0.0	-	1.5	ABM	29	0.7	0.0
Siltli Kum-2	1.5	-	3.0	ABM	29	0.714	1.5
Kum-1	3.0	-	4.5	ABM	21	0.93	3.0
Kum-2	4.5	-	6.0	ABM	42	0.97	4.5
Kum-3	6.0	-	6.75	ABM	64	0.54	6.0
Kumlu Çakıl -1	6.75	-	10.5	Elastik	-	-	6.75
Kumlu Çakıl -2	10.5	-	15.0	Elastik	-	-	10.5

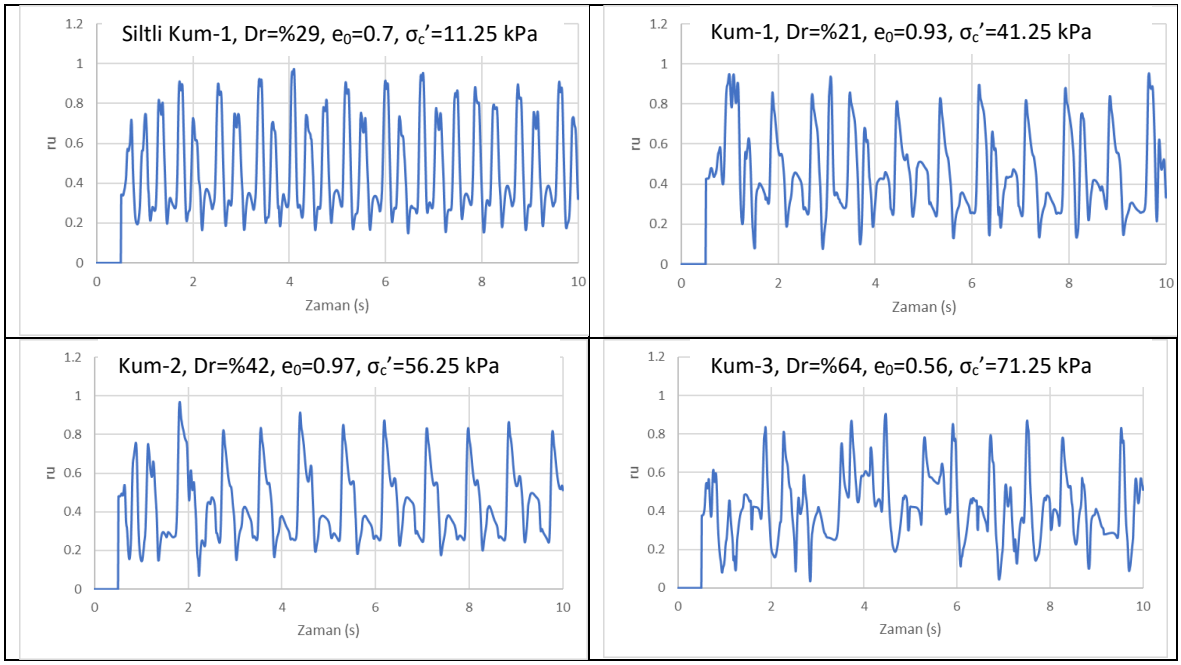

Şekil 9. Sahaya özgü vaka analizi tahmin sonuçları

6. KAPANIŞ ve DEĞERLENDİRME

Çalışmada suya doygun temiz kumlarda sıvılaşma gelişimini başarıyla tahmin eden, yalnızca şekil değiştirme kontrollü dinamik üç eksenli deney sonuçlarına dayalı ve derin öğrenme tabanlı bir Akıllı Bünye Modeli'nin (ABM) son versiyonu geliştirilmiştir. ABM tahminleri, tekrarlı üç eksenli deney verileri ve UBCSAND modeliyle doğrulandıktan sonra, Python ortamında yazılan ve zemini iki fazlı bağlaşık akış-deformasyon teorisi ile modelleyen bir sonlu elemanlar programına aktarılmıştır. Geliştirilen özgün sonlu elemanlar-derin öğrenme arayüz algoritması ile ABM, deprem yükleri altında bir boyutlu saha tepki analizlerine başarıyla uygulanmıştır. ABM'nin eğitim veri setiyle uyumlu koşullar altında gerçeğe yakın tahminler yapabildiği, buna karşın eğitim setinde yer almayan ya da az miktarda yer alan efektif gerilme ve relatif sıkılık aralıklarında daha sınırlı bir performans sergilediği görülmüştür. Çalışmada ayrıca 6 Şubat 2023 depremleri sonrası Hatay ve çevresinde tespit edilen sıvılaşmış zemin tabakaları üzerinde yapılan saha tepki analizlerine yer verilmiştir. ABM ve geliştirilen hibrit algoritma bu analizlerde genel olarak zeminin sıvılaşmasına dair gözlemsel verileri doğrular nitelikte tahmin sonuçları vermiştir.

TEŞEKKÜR

Bu çalışma üçüncü yazarın yürütücülüğünü yaptığı 121M736 no'lu TÜBİTAK 1001 projesi kapsamında gerçekleştirilmiştir. Yazarlar TÜBİTAK'a teşekkürü bir borç bilirler.

KAYNAKLAR

Birinci, Ö. T. ve Ülker, M.B.C. (2023). "Temiz Kumlarda Dinamik Yükleme Sonucu Aşırı Boşluk Suyu Basıncı Oranı Değişiminin LSTM Sinir Ağı ile Tahmin Edilmesi" 9. Geoteknik Sempozyumu. İstanbul Teknik Üniversitesi, İstanbul. pp. 183-188.

Birinci, Ö. T. ve Ülker, M.B.C. (2024). "Makine Öğrenmesi ile Sismik Sıvılaşmanın Deviatorik Gerilme Tarihçesi Cinsinden Tahmin Edilmesi" 19. Ulusal Zemin

Mekaniği ve Geoteknik Mühendisliği Konferansı, 16-18 Ekim, Hacettepe Üniversitesi, Ankara.

Birinci, Ö. T., Ülker, M.B.C. ve Taşkın, G. (2025). "Prediction of Pore Water Pressure Generation of Liquefiable Clean Sands under Cyclic Shear Loading through Deep Learning", Geomechanics and Geoengineering, Vol. 20(5), 1006-1027.

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 Conf. 249, 11015.

Choi, Y., ve Kumar, K. (2023). "A Machine Learning Approach to Predicting Pore Pressure Response In Liquefiable Sands Under Cyclic Loading". ASCE Geo-Congress Geotechnical Data Analysis and Computation, 202–210.

Drakos, S. (2008). "Applications of Artificial Intelligence in Constitutive Modelling of Soils", Doktora Tezi, Swansea University, Swansea UK.

ElGhoraiby, M., M. Manzari (2018). "Cyclic Direct Simple Shear Tests", in LEAP-2018 - Stress-strain response of Ottawa F65 sand in Cyclic Simple Shear. DesignSafe-CI.

Ghaboussi, J. (2018). Soft Computing in Engineering, CRC Press, Taylor & Francis Group.

Guan, Q.Z., ve Yang, Z.X. (2023). "Hybrid Deep Learning Model for Prediction of Monotonic and Cyclic Responses of Sand". Acta Geotechnica, Vol. 18(3), 1447–1461.

Idriss, I. M., & Boulanger, R.W. (2008). *Soil liquefaction during earthquakes*. Monograph MNO-12. Oakland, CA: Earthquake Engineering Research Institute (EERI), 261 pp.

Liang, L., Liu, M., Elefteriades, J., and Sun, W. 2023. PyTorch-FEA: Autograd-enabled finite Element Analysis Methods with Applications for Biomechanical Analysis of Human Aorta. bioRxiv: The preprint server for biology.

Mozaffar, M., Bostanabad, R., Chen, W., Ehmann, K., vd. (2019). "Deep learning predicts path-dependent plasticity." Proc. Nat. Acad. Sci. Vol. 116(52), 26414-420.

Ülker, M.B.C., ve Rahman, M.S. (2009). "Response of saturated porous media: Different formulations and their applicability". Int. J. Analy. Numer. Mthds in Geomech. Vol. 33(5), 633-664.

Vasko, A., ElGhoraiby, M., ve Manzari, M. (2018). "LEAP-GWU-2015 Laboratory Tests".

Wichtmann, T., & Triantafyllidis, T. (2016). "An experimental database for the development, calibration and verification of constitutive models for sand with focus to cyclic loading: Part I". Acta Geotechnica, 11(4), 739-761.

Wu, X. ve Ghaboussi, J. (1995). Civil engineering studies: Neural network-based material modeling (UILU-ENG-95-2002). Dept. Civil Eng., Univ. Illinois Urbana-Champaign.

Zhang, H., Yang, Y. ve Yu, H-S. (2021). "Liquefaction and Post-Liquefaction of Granular Material Under Multi-Directional Cyclic Loading", Marine Georesources & Geotechnology, Vol. 39(11), 1261–1272.