

MAKİNE ÖĞRENMESİ İLE SIVILAŞMA POTANSİYELİ: RASTGELE ORMAN VE ADABOOST MODELLERİNİN KARŞILAŞTIRILMASI

POTENTIAL OF LIQUEFACTION WITH MACHINE LEARNING: COMPARISON OF RANDOM FOREST AND ADABOOST MODELS

Engin NACAROĞLU¹, Ayşe Tuba TUĞRUL², Berk YAĞCIOĞLU³, Selçuk TOPRAK⁴

ÖZET

Sıvılaşma potansiyelinin belirlenmesini bir sınıflandırma problemi olarak ele alan, konik penetrasyon testi verilerinden öğrenen makine öğrenmesi modelleri ile literatürde sıkça karşılaşılmaktadır. Rastgele orman, AdaBoost ve diğer karar ağacı tabanlı topluluk modelleri, çeşitli karar ağacı yapılarını bir araya getirerek, genelleme başarısı yüksek (tahmin doğruluğu yüksek ve eğitim verilerine aşırı uyum göstermeyen) ve veri setindeki karmaşıklıklara uyum sağlayabilen modeller oluşturan güçlü ve esnek yaklaşımlardır. Bu çalışma, sıvılaşma potansiyelinin belirlenmesi amacıyla eğitilmiş bagging tabanlı rastgele orman ile boosting tabanlı AdaBoost sınıflandırıcılarının kullanılabilirliğini incelerken, genelleme başarılarını karşılaştırmıştır. Çalışmadaki modellerin oluşturulmasında literatürden derlenmiş 18 depremin sıvılaşma gözlemleri, konik penetrasyon testi sonuçları ve diğer zemin verilerinden oluşan 321 örneklili bir veri seti kullanılmıştır. Veri setinde öznitelik olarak her örneğe ait, deprem büyüklüğü, maksimum yer ivmesi, ölçüm derinliği, konik uç direnci, sürtünme direnci, döngüsel stres oranı, zemin davranış tipi indeksi, ince dane içeriği, toplam ve efektif gerilmeler kullanılmıştır. Sınıflandırıcılar, doğruluk, hassaslık, duyarlılık, F1 skoru ve ROC eğrisi altında kalan alan ölçütleri açısından değerlendirilip, permütasyon önemi yöntemi ile özniteliklerin önem değerleri incelenmiştir. İki modelin de sıvılaşma potansiyelinin belirlenmesi açısından kullanılabileceği sonucuna varılmıştır. Ölçütler detaylı değerlendirildiğinde bagging tabanlı rastgele orman modeli, doğruluk ve genelleme başarısı açısından, boosting tabanlı AdaBoost modeline göre daha üstün bulunmuştur. Her iki model tahminlerinde de en etkili özniteliklerin konik uç direnci ve döngüsel stres oranı olduğu belirlenmiştir.

Anahtar Kelimeler: sıvılaşma, makine öğrenmesi, konik penetrasyon testi, rastgele orman, AdaBoost, öznitelik önemi

¹ Dr. Öğr. Üyesi, Pamukkale Üniversitesi, enacaroglu@pau.edu.tr (Sorumlu yazar)

² Doktora Öğrencisi, Pamukkale Üniversitesi, atugrul09@posta.pau.edu.tr

³ Doktora Öğrencisi, Pamukkale Üniversitesi, byagcioglu13@posta.pau.edu.tr

⁴ Profesör Dr., Gebze Teknik Üniversitesi, stoprak@gtu.edu.tr

ABSTRACT

Machine learning models that treat the determination of liquefaction potential as a classification problem and learn from cone penetration test data are frequently encountered in the literature. Random forest, AdaBoost, and other decision tree-based ensemble models are powerful and flexible approaches that combine various decision tree structures, creating models with high generalization performance (high predictive accuracy without overfitting to the training data) and the ability to adapt to complexities in the dataset. This study investigates the usability of bagging-based random forest and boosting-based AdaBoost classifiers trained for the purpose of determining liquefaction potential and compares their generalization performances. A dataset consisting of 321 samples, compiled from liquefaction observations of 18 earthquakes, cone penetration test results, and other soil data obtained from the literature was used in the creation of the models in this study. The features used for each sample in the dataset included earthquake magnitude, maximum ground acceleration, measurement depth, cone tip resistance, friction resistance, cyclic stress ratio, soil behavior type index, fines content, total and effective stresses. The classifiers were evaluated in terms of accuracy, precision, recall, F1 score and ROC AUC values, and the importance values of the features were examined using the permutation importance method. It was concluded that both models can be used to determine liquefaction potential. When the evaluation criteria were examined in detail, the bagging-based random forest model was found to be superior to the boosting-based AdaBoost model in terms of accuracy and generalization performance. It was determined that the most influential features in the predictions of both models were cone tip resistance and cyclic stress ratio.

Keywords: Liquefaction, machine learning, cone penetration test, random forests, AdaBoost, feature importance

1. Giriş

Zemin sıvılaşması, Niigata ve Alaska depremleri (1964) ile dikkatleri üzerine çeken geoteknik deprem mühendisliğinin temel konularından biridir. Sıvılaşma terimi, kohezyonsuz zeminlerde drenajsız şartlardaki tekdüze, dengesiz ve tekrarlamalı örselenmeden kaynaklanan zemin deformasyonları ile ilgili değişik olayları nitelemek üzere tarihsel olarak ilk kez Mogami ve Kubo (1953) tarafından kullanılmıştır (Kramer, 1996). Sıvılaşma ile ilgili literatürde aralarında 2023 Kahramanmaraş depremlerinin tetiklediği sıvılaşma da dahil olmak üzere birçok çalışma bulunmaktadır (Toprak ve Holzer, 2003; Cetin vd., 2004; Boulanger ve Idriss, 2014; Cetin vd., 2024; Ozener vd., 2024; Bol vd., 2023). Son yıllarda ise makine öğrenmesi ile sıvılaşma potansiyelinin değerlendirilmesi yaygın olarak kullanılmaya başlanmıştır (Livingston vd., 2008; Zhao vd., 2022; Duan vd., 2023; Jas vd. 2024; Özsağır vd., 2022).

Makine öğrenmesi yöntemleri veri madenciliği ile elde edilen verilerden gelecek durumlarla ilgili sonuçlar elde etmek için kullanılır. Tahmin amaçlı makine öğrenmesi ile etiketli (sonuçları belli) verilerden öğrenen bir model geliştirilmesi ve bu model ile etiketsiz (sonuçları belli olmayan) veri tabanları için sonuç tahmin edilmesi hedeflenir. Makine öğrenmesinin temelini oluşturan yapay sinir ağları, insan beyninin çalışma prensiplerini araştıran Walter Pitts ve Warren McCulloch'ın 1943 yılında ilk yapay sinir ağının

matematiksel modelini oluşturmasıyla ortaya çıkmıştır. Makine öğrenmesinin uzman sistemlerin yerini almasının ardından, sinir ağlarından oluşan gizli katmanlar ile büyük miktarda veriden öğrenebilen derin öğrenme yöntemleri geliştirilmiştir. Derin öğrenme ve makine öğrenmesi günümüzde deprem araştırmaları ve geoteknik mühendisliği gibi birçok araştırma alanında sıkça kullanılmaktadır.

Bu çalışma, sıvılaşma potansiyelinin belirlenmesi amacıyla eğitilmiş iki ağaç topluluğu olan bagging tabanlı rastgele orman (RF) ile boosting tabanlı AdaBoost modellerinin kullanılabilirliğini incelemiş, genelleme başarılarını karşılaştırmıştır. İki modelin oluşturulmasında kullanılan literatürden derlenmiş 18 depremin sıvılaşma gözlemleri, konik penetrasyon testi sonuçları ve diğer zemin verilerinden oluşan 321 örnekle veri seti modellerin eğitimi ve genelleme başarısını değerlendirmek amacıyla %80 (eğitim veri seti) ve %20 (test veri seti) olarak iki alt veri setine ayrılmıştır. Gözlemlerde sıvılaşma görülüp görülmemeye durumu kategorik hedef değişken olarak veri setine eklenmiştir. Modellerde genelleme başarısını arttırmak ve veri setine en uygun hiperparametre kombinasyonlarını belirlemek amacıyla çapraz doğrulama ile hiperparametre optimizasyonu yapılmıştır. Elde edilen modellerin performansları doğruluk, hassaslık, duyarlılık, F1 skoru (hassaslık ve duyarlılığın harmonik ortalaması), ve ROC eğrisi altında kalan alan (ROC AUC) değerleri elde edilip karşılaştırılmıştır. Modellerin karar verme mekanizmalarında özniteliklerin etkisini karşılaştırmak amacıyla permütasyon önemi yöntemi uygulanarak, her özneliğin önem değerleri belirlenip değerlendirilmiştir.

2. MATERYAL VE YÖNTEM

Makine öğrenmesi ile sıvılaşma potansiyelinin belirlenmesinde mevcut çalışmalar, zemine ait standart penetrasyon testi, konik penetrasyon testi ve kayma dalgası hızı gibi geçmiş verilerden yararlanmaktadır. Sıvılaşma potansiyeli tahmininde lineer yöntemler, yapay sinir ağları, k-en yakın komşu, karar ağaçları gibi yöntemlerin yanı sıra, tekil modellerin birlikte karar vermesine dayalı topluluk modelleri ve destek vektör makineleri de makine öğrenmesi ile sıvılaşma araştırmalarında kullanılıp, karar başarıları değerlendirilmiştir.

Zayıf öğrenici (karar ağacı) yapıların bir arada kullanılmasına dayalı bootstrap aggregating (bagging) ve boosting yöntemleriyle eğitilen ağaç topluluğu modelleri, yetersiz öğrenme (underfitting) ve aşırı öğrenme sorunlarıyla başa çıkmada etkili modellerdir. RF, extremely randomized trees, XGBoost, AdaBoost, CatBoost gibi ağaç topluluğu modelleri, karar verme mekanizmaları açısından sıvılaşma potansiyeli tahmini konusunda mevcut çalışmalarda yeterli bulunan makine öğrenmesi yöntemleridir. Çalışmada kullanılan RF ve AdaBoost algoritmaları, Breiman'ın RF algoritmasını ortaya koyduğu çalışmasında çeşitli veri setleriyle incelenmiş, RF'lerin doğruluk, aykırı değerlere ve gürültülü veriye dayanıklılık açısından, AdaBoost'a göre bazı durumlarda daha iyi olduğu sonucuna varılmıştır (Breiman, 2001).

Çalışmadaki RF ve AdaBoost modellerinin oluşturulmasında literatürden elde edilen (Boulanger vd. 1997; Boulanger ve Idriss, 2015; Green vd. 2014; Juang, 2003) 18 depremin sıvılaşma gözlemleri ve konik penetrasyon testi sonuçlarından derlenmiş bir veri seti kullanılmıştır. Modellemede öznitelik olarak her örneğe ait, deprem büyüklüğü, maksimum yer ivmesi, ölçüm derinliği, konik uç direnci, sürtünme direnci, döngüsel stres oranı, zemin davranış tipi indeksi, ince dane içeriği, toplam ve efektif gerilmeler göz önüne alınmıştır. Bu

çalışmada kullanılan 321 gözlemleri veri seti %80 (eğitim veri seti) ve %20 (test veri seti) olarak iki alt veri setine ayrılmıştır. Veri seti sıvılaşmış ve sıvılaşmamış gözlem sayılarının oranı açısından dengesizdir. Eğitim ve test verilerinde sıvılaşmış ve sıvılaşmamış gözlem sayılarının oranı, model genellemesinin doğru değerlendirilmesi açısından veri setini temsil edecek şekilde belirlenmiştir. Veri setine ait sıvılaşmış ve sıvılaşmamış gözlem oranları Tablo 1’de verilmiştir.

Tablo 1. Tüm veriler, eğitim ve test verilerinde sıvılaşmış ve sıvılaşmamış gözlem oranı

	Sıvılaşmış Gözlem (%)	Sıvılaşmamış Gözlem (%)
Tüm Veriler	71.34	28.66
Eğitim Verileri	71.48	28.52
Test Verileri	70.77	29.23

Permütasyon önemi, makine öğrenmesi ve istatistiksel modellemede modeldeki bir özneliğin önemini ölçmek için kullanılan bir yöntemdir. Bu yöntem, belirli bir özneliğin model tahminleri üzerindeki etkisini değerlendirmek için özneliğin değerlerini rastgele karıştırarak (permütasyon yaparak) yeni bir veri seti oluşturur. Bu veri seti ile model değerlendirildiğinde başarıda meydana gelen değişiklik, o özneliğin önemini gösterir. Eğer modelin başarısı belirgin bir şekilde düşerse o öznelik model için önemli kabul edilir. Çalışmada değerlendirilen RF ve AdaBoost modellerinin permütasyon önemi yöntemi ile öznelik önemleri değerlendirilmiş, önem değerleri karşılaştırılmıştır.

3. UYGULAMA


321 örneklili veri setinde verilerin bulunduğu aralıklar, ortalamalar ve standart sapma değerleri Tablo 2’de verilmiştir. Veri setinde bulunan 18 depreme ait sıvılaşmış ve sıvılaşmamış gözlem sayıları Şekil 1’de verilmiştir.

Tablo 2. Veri istatistikleri

Öznelik	Tanım	Veri Aralığı	Ortalama	Standart Sapma
M_w	Deprem moment büyüklüğü	5.9 – 9.0	6.964	0.566
a_{maks}	Maksimum yer ivmesi (g)	0.09 – 0.84	0.323	0.15
Derinlik	q_c ’nin ölçüldüğü derinlik (m)	1.4 – 12.7	4.719	2.262
q_c	Konik uç direnci (MPa)	0.78 – 25.0	5.788	3.71
f_s	Konik sürtünme direnci (MPa)	0.001 – 0.36	0.044	0.04
CSR	Döngüsel stres oranı	0.07 – 0.65	0.258	0.11
I_c	Zemin davranış tipi indeksi	1.4 – 3.42	2.282	0.385
FC	İnce dane içeriği	0 – 100.0	45.665	28.775
σ_v	Toplam gerilme (kPa)	24.0 – 235.5	87.677	43.08
σ'_v	Efektif gerilme (kPa)	19.0 – 161.6	62.445	28.496

RF modelinde eğitim verisi bölme ölçütü olarak gini impurity (gini kirliliği) kullanılmıştır. Ağaçların eğitiminde bagging (bootstrap aggregating) ile örnekleme yapılmıştır. Veri setinde sıvılaşma sınıfları (sıvılaşmış ve sıvılaşmamış) orantısız dağılıma sahip olduğundan sınıf ağırlıkları göz önüne alınmıştır. Her bir karar ağacında maksimum derinlik, bir yaprak düğümünde bulunacak minimum örnek sayısı, bir iç düğümün bölünmesi için gerekli minimum örnek sayısı hiperparametreleri optimize edilerek en başarılı RF modeli elde edilmiştir. AdaBoost modelinin temel sınıflandırıcısı olan karar ağaçlarında sınıf

dengelessikleri göz önüne alınmıştır. Her iterasyonun sonucunda hatalı sınıflandırılan örneklerin ağırlıkları arttırılarak boosting uygulanmıştır. Temel sınıflandırıcı türü, ağaç sayısı ve öğrenme oranı hiperparametreleri optimize edilerek en başarılı AdaBoost modeli elde edilmiştir.



Şekil 1. Veri setinde bulunan 18 depreme ait sınıvlanmış ve sınıvlanmamış gözlem sayıları

4. BULGULAR VE TARTIŞMALAR

Modeller ile sınıvlaşma potansiyeli tahminleri yapıp, doğru pozitif tahmin (TP), yanlış pozitif tahmin (FP), yanlış negatif tahmin (FN) ve doğru negatif tahmin sayıları (TN) ile diğer değerlendirme ölçütleri Tablo 3'te verilmiştir. Modellerin doğru tahmin oranları yanında, sınıvlaşma değişkenindeki sınıf dengesizliğine uygun olarak (Tablo 1) diğer ölçütler de değerlendirilmelidir.

Tablo 3. RF ve AdaBoost model değerlendirme sonuçları

Model	Veri Seti	TP	FP	FN	TN	Doğruluk	Hassaslık	Duyarlılık	F1 Skoru	ROC AUC
RF	Tüm V.	214	8	15	84	0.928	0.964	0.934	0.949	0.980
RF	Eğitim V.	171	6	12	67	0.930	0.966	0.934	0.950	0.983
RF	Test V.	43	2	3	17	0.923	0.956	0.935	0.945	0.967
AdaBoost	Tüm V.	214	24	15	68	0.879	0.899	0.934	0.916	0.937
AdaBoost	Eğitim V.	173	18	10	55	0.891	0.906	0.945	0.925	0.941
AdaBoost	Test V.	41	6	5	13	0.831	0.872	0.891	0.882	0.917

Doğruluk, bir modelin doğru sınıflandırdığı toplam örneklerin yüzdesini ifade eden bir model değerlendirme ölçütüdür. F1 skoru, bir modelin duyarlılık (recall) ve hassasiyetini (precision) dengede tutmak amacı ile bu iki ölçütün harmonik ortalamasını ifade eder. Adaboost sınıflandırıcısı, eğitim verilerinde 0.891 doğruluk, 0.925 F1 skoruna ulaşmıştır. Ancak test verilerinde elde ettiği 0.831 doğruluk ve 0.882 F1 skoru eğitim verilerine göre nispeten düşüktür. RF sınıflandırıcısı, eğitim verilerinde 0.930 doğruluk, 0.950 F1 skoruna ulaşmıştır. Test verilerinde ise 0.923 doğruluk ve 0.945 F1 skoruna ulaşmıştır. RF modelinin eğitim ve test veri setlerindeki başarısının tutarlılığı, genelleme yeteneğinin yüksek olduğuna işaret etmektedir. AdaBoost'un F1 skorundaki düşüş FP ve FN sayılarından kaynaklanabilir. Ancak test verilerindeki doğruluk düşüşü ile birlikte değerlendirilirse, eğitim verilerine aşırı uyum (aşırı öğrenme) ihtimalini de işaret eder. AdaBoost algoritması, eğitim prosedürü gereği ardışık tahminlemede en son yanlış sınıflandırılan verilerin ağırlıklarını yinelemeli olarak artırır. Yanlış sınıf etiketine sahip veriler, yanlış sınıflandırılmaya devam eder. Böylece AdaBoost bu gürültülü veriye giderek daha fazla ağırlık verir. Bu durum AdaBoost tahmin modelinin dengesinin bozulmasına yol açacaktır. Rastgele orman algoritması ise herhangi bir veri alt kümesi üzerinde ağırlık yoğunlaştırılmaz ve gürültü etkisi daha küçük olur (Breiman, 2001).

Duyarlılık değeri doğru pozitiflerin ne kadarının doğru bir şekilde pozitif olarak tahmin edildiğini kontrol etmek amacı ile doğru pozitiflerin (TP), doğru pozitifler ve yanlış negatiflerin toplamına (TP + FN) oranını ifade eden bir değerlendirme ölçütüdür. Sınıflandırma modellerinde duyarlılık değerlendirmesi FN sayısını azaltmayı hedefler. Gerçek durumda sıvılaşmış gözlemlerin, yanlış (sıvılaşmamış) tahmin edilmesinin önlenmesi (yanlış negatif tahminlerin önlenmesi) açısından duyarlılık ölçütü sıvılaşma potansiyeli tahmininde göz önünde bulundurulmalıdır. Bu çalışmada eğitilen RF sınıflandırıcısı test verilerinde 3 tane, AdaBoost ise 5 tane sıvılaşmış gözlemi sıvılaşmamış olarak yanlış tahmin etmiştir. AdaBoost sınıflandırıcısı test verilerinde, hem FN sayıları hem de duyarlılık değerleri açısından (Tablo 3) RF'ye göre daha kötü tahminlerde bulunmuştur.

Hassaslık değeri, modelin pozitif olarak sınıflandırdığı örneklerin gerçekten pozitif olma oranını ifade eder. Doğru pozitif sayısının, doğru pozitif ve yanlış pozitiflerin toplamına (TP + FP) oranını ifade eden bir değerlendirme ölçütüdür. Yüksek hassaslık, modelin yanlış pozitif sayısını düşük tuttuğunu ve pozitif olarak tahmin ettiği örneklerde daha doğru olduğunu işaret eder. Bu çalışmada eğitilen RF sınıflandırıcısı FP (gerçek durumda sıvılaşmamış gözlemlerin sıvılaşmış olarak tahmin edilmesi) sayılarına ve hassaslık değerlerine bakıldığında (eğitim ve test verilerinde) daha başarılıdır.

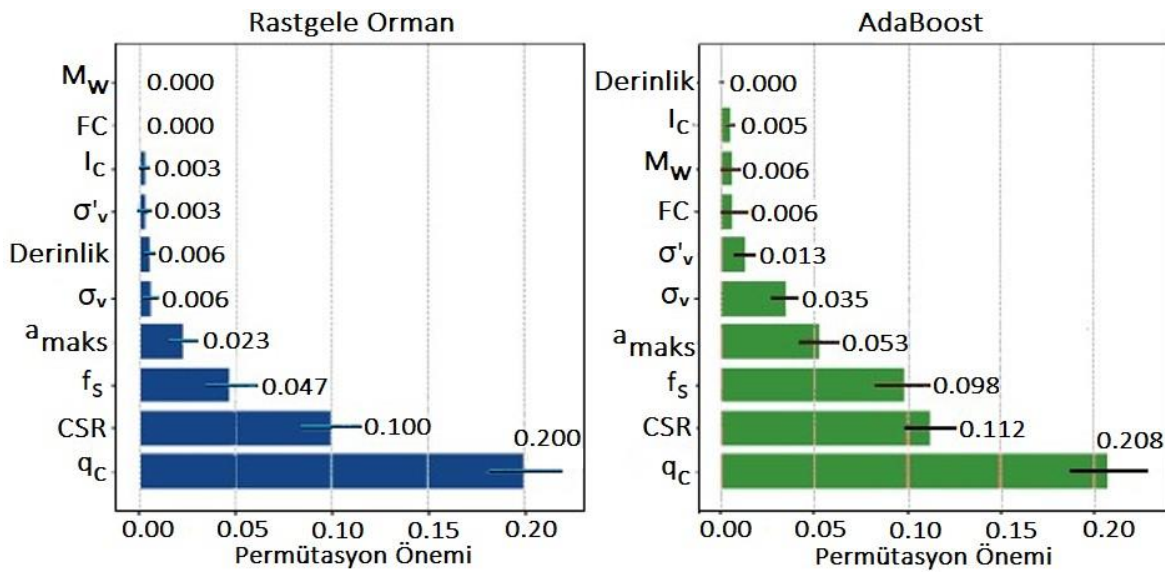
RF sınıflandırıcısının doğruluk ve diğer değerlendirme ölçütleri açısından (hassaslık, duyarlılık, F1 skoru ve ROC AUC) daha yüksek değerlere sahip olması, bu sıvılaşma potansiyeli modelinin AdaBoost modeline kıyasla daha başarılı olduğunu göstermektedir.

ROC grafiği, çeşitli eşiklerde doğru pozitif oranının, yanlış pozitif oranı karşısında değişimini gösteren grafiklerdir. ROC AUC değeri 0.5'ten düşükse, bu modelin bilgilendirici olmadığını veya rastgele bir modelden daha kötü bir uyum sağladığını gösterir. Bu çalışma kapsamında değerlendirilen RF ve AdaBoost modelleri, elde ettikleri yüksek ROC AUC değerleri

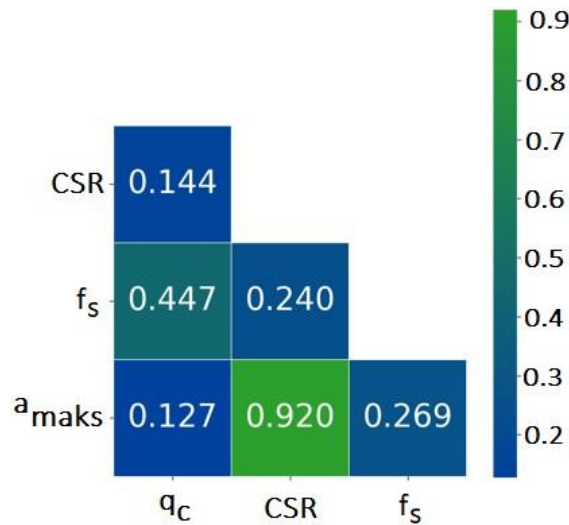
açısından rastgelelikten uzak, genelleme açısından başarılı ve uygulanabilir sınıflandırıcılardır.

4.1. Model Kararlarında Öznitelik Önemlerinin Değerlendirilmesi

RF ve AdaBoost sınıflandırıcıları için elde edilen permütasyon önemi değerleri (Şekil 2), veri setindeki gözlemlerin özniteliklerinin modelin tahmin başarısına olan katkılarının farklı önem değerlerine sahip olduğunu göstermiştir. İki model için de en önemli öznitelikler, q_c , CSR, f_s ve a_{maks} olmuştur. Bu öznitelikler arasındaki korelasyon değerleri Şekil 3'te verilmiştir. Önem değerleri yüksek öznitelikler olan CSR ve a_{maks} arasındaki yüksek korelasyon, hata analizleri ve veri setinin değerlendirilmesi açısından göz önünde bulundurulmalıdır. Diğer özniteliklerin (örneğin, M , FC, I_c , σ_v , Derinlik) önem değerleri her iki modelde de oldukça düşük çıkmıştır.

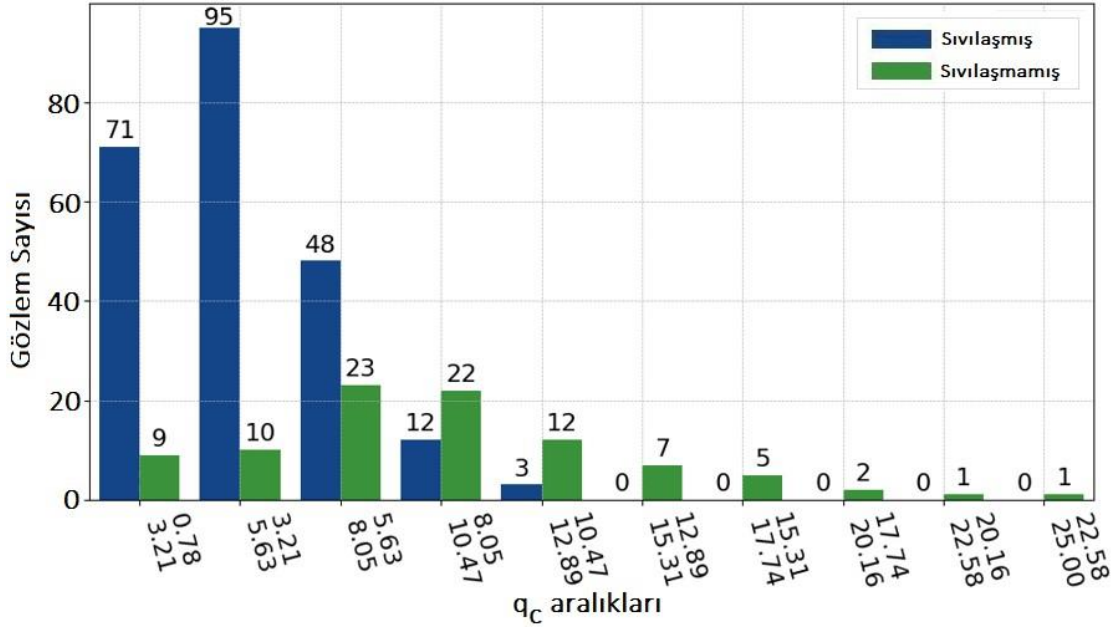


Şekil 2. Permütasyon önemi değerleri



Şekil 3. q_c , CSR, f_s ve a_{maks} arasındaki korelasyonlar

Tahminlerde en önemli öznelik olan konik uç direnci RF ve AdaBoost'ta da yaklaşık 0.20 permütasyon önem değerine sahiptir. Veri setindeki konik uç direnci verisi geniş dağılıma sahip olup farklı zemin koşullarını temsilciliği açısından yeterli varyasyona sahiptir (Tablo 2, Şekil 4). Konik uç direncinin tahminlere katkısının yüksekliğinde bu dağılım ve varyasyon özelliklerinin katkısı olmuştur. Tahminlerdeki öznelik önemleri açısından ikinci sırada gelen CSR verisi, yaklaşık 0.10 permütasyon önem değerine sahiptir.



Şekil 4. Konik uç direnci (MPa) verisinin dağılımı

Deprem büyüklüğü verisinin RF ve AdaBoost modellerinde düşük önem değerinde olması, verideki dengesizlikten kaynaklanmaktadır. 18 depremlili veri setindeki 321 gözlemin 158'inin 1989 Loma Prieta (M_w : 7.1) ve 2010 Canterbury (M_w : 7.1) depremlerine ait olması ağaç tabanlı modellerin eğitim prosedürleri gereği, deprem büyüklüğünü sıvılaşma değişkeniyle çok düşük oranda ilişkilendirmelerine sebep olmuştur (Şekil 1).

Makine öğrenmesi modellerinde özneliklerin önem değerleri, modellerin öğrenme algoritmalarının özneliklerin etkisini nasıl değerlendirdiğine bağlıdır. Örneğin RF modeli, özneliklerin bölünme noktalarını belirlerken daha çeşitli ağaçlar oluşturabilirken, AdaBoost modeli yanlış sınıflandırmaları düzeltmeye çalışarak öznelik önemlerini belirler. Öznelik önemi yöntemleri, modelin genelleme başarısını arttırmak için optimizasyonu açısından etkili yöntemlerdir. Ayrıca elde edilen öznelik önemi bilgilerinden veri setinin geliştirilmesi amacıyla hangi özneliklerin dikkatle incelenmesi gerektiği ve hangi özneliklerin ağırlıklarının düşürülebileceği konusunda faydalanılabilir.

5. SONUÇLAR

Bu çalışmada sıvılaşma potansiyeli tahmini için oluşturulan bagging tabanlı RF ile boosting tabanlı AdaBoost sınıflandırıcılarının genelleme başarıları doğruluk, hassaslık ve duyarlılık, F1 skoru ve ROC AUC değerleri açısından karşılaştırılmış ve permütasyon önemi yöntemi ile öznelik önem değerleri değerlendirilmiştir. Modellerin eğitimi ve değerlendirilmesinde

literatürden derlenmiş 18 depremin sıvılaşma gözlemleri, konik penetrasyon testi sonuçları ve diğer zemin verilerinden oluşan 321 örneklili bir veri seti kullanılmıştır.

RF ve AdaBoost sınıflandırıcılarının doğruluk, hassaslık, duyarlılık, F1 skoru ve ROC AUC değerleri göz önüne alındığında sıvılaşma potansiyeli değerlendirmelerinde kullanılabilir oldukları değerlendirilmiştir. İki model de kullanılabilir olsa da bagging tabanlı RF modelinin boosting tabanlı AdaBoost modeline göre daha başarılı olduğu sonucuna varılmıştır.

Modellerin eğitim ve test verilerindeki başarıları ayrı ayrı göz önünde bulundurulduğunda RF modelinin eğitim ve test verileri üzerinde dengeli ve yüksek performans göstermesi, modelin genelleme yeteneğinin daha güçlü olduğunu göstermektedir. AdaBoost sınıflandırıcısı sıvılaşma sınıflandırıcısı olarak kıyaslanabilir başarıya sahip olsa da test verisi başarısının nispeten düşük olması modelin yeni verilerde genelleme davranışı göstermeme durumuna (aşırı öğrenme ihtimali) işaret etmektedir.

AdaBoost sınıflandırıcısı, FP (sıvılaşmamış iken sıvılaşmış tahmin edilen) sayılarında genel olarak daha düşük başarıya sahiptir. FN (sıvılaşmış iken sıvılaşmamış tahmin edilen) sayıları açısından ise test verilerinde düşük başarı göstermiştir. Hatalı tahmin sayıları, modeller sıvılaşma potansiyeli değerlendirmelerinde kullanıldığında göz önünde bulundurulmalıdır.

Bagging ve boosting tabanlı bu iki topluluk algoritmasında doğrudan karşılaştırma yapılırken, tahminlerin literatürden elde edilmiş bazı zemin tiplerini ve depremleri temsil eden bir veri seti ile eğitilmiş modellerden elde edildiği unutulmamalıdır.

Öznitelik önemi değerlendirmeleri sonucunda, RF ve AdaBoost modelleri için en önemli özniteliklerin, q_c , CSR, f_s ve a_{maks} olduğu sonucuna varılmıştır. Deprem büyüklüğü verisinin RF ve AdaBoost modellerinde düşük önem değerinde olması, verideki dengesizlikten kaynaklanmıştır. Öznitelik önemi değerlendirmesi, model optimizasyonlarını geliştirmek ve sıvılaşma potansiyeli açısından daha anlamlı modeller elde etmek için önemli bir temel oluşturmaktadır.

KAYNAKLAR

- Bol, E., Özocak, A., Sert, S., Çetin, K. Ö., Arslan, E., Kocaman, K., Ayhan, B. U. (2024), "Evaluation of Soil Liquefaction in the City of Hatay Triggered After the February 6, 2023 Kahramanmaraş-Türkiye Earthquake Sequence", *Engineering Geology*, 107648.
- Boulanger, R. W., Mejia, L. H., Idriss, I. M. (1997), "Liquefaction at Moss Landing during Loma Prieta earthquake", *J. Geotechnical and Geoenvironmental Eng.*, ASCE 123(5), 453-67.
- Boulanger, R. W., Idriss, I. M. (2014), "CPT and SPT Based Liquefaction Triggering Procedures", Report No. UCD/CGM.-14, 1, 134.
- Boulanger, R. W., Idriss, I. M. (2016), "CPT-based Liquefaction Triggering Procedure", *Journal of Geotechnical and Geoenvironmental Engineering*, 142(2), 04015065.
- Breiman, L. (2001), "Random Forests", *Machine Learning*, 45, 5-32.
- Cetin, K. O., Soylemez, B., Guzel, H., Cakir, E. (2024), "Soil Liquefaction Sites Following the February 6, 2023, Kahramanmaraş-Türkiye Earthquake Sequence", *Bulletin of Earthquake Engineering*, 1-24.

- Cetin, K. O., Youd, T. L., Seed, R. B., Bray, J. D., Stewart, J. P., Durgunoglu, H. T., Lettis, W., Yilmaz, M. T. (2004), "Liquefaction-induced Lateral Spreading at Izmit Bay During the Kocaeli (Izmit)-Turkey Earthquake", *Journal of Geotechnical and Geoenvironmental Engineering*, 130(12), 1300-1313.
- Chan, J. C. W., Paelinckx, D. (2008), "Evaluation of Random Forest and AdaBoost Tree-Based Ensemble Classification and Spectral Band Selection for Ecotope Mapping Using Airborne Hyperspectral Imagery", *Remote Sensing of Environment*, 112(6), 2999-3011.
- Çelik, M., (2009), "Veri Madenciliğinde Kullanılan Sınıflandırma Yöntemleri ve Bir Uygulama", Yüksek Lisans Tezi, İstanbul Üniversitesi, İstanbul.
- Duan, W., Zhao, Z., Cai, G., Wang, A., Wu, M., Dong, X., Liu, S. (2023), " V_s -based Assessment of Soil Liquefaction Potential Using Ensembling of GWO-KLEM and Bayesian Theorem: A Full Probabilistic Design Perspective", *Acta Geotechnica*, 18(4), 1863-1881.
- Freund, Y., & Schapire, R. E. (1996), "Experiments with a New Boosting Algorithm", *icml*, Vol. 96, pp. 148-156.
- Green, R. A., Cubrinovski, M., Cox, B., Wood, C., Wotherspoon, L., Bradley, B., & Maurer, B. (2014), "Select Liquefaction Case Histories from the 2010–2011 Canterbury Earthquake Sequence", *Earthquake Spectra*, 30(1), 131-153.
- Jas, K., Mangalathu, S., Dodagoudar, G. R. (2024), "Evaluation and Analysis of Liquefaction Potential of Gravelly Soils Using Explainable Probabilistic Machine Learning Model", *Computers and Geotechnics*, 167, 106051.
- Juang, C. H., Yuan, H., Lee, D. H., & Lin, P. S. (2003), "Simplified Cone Penetration Test-Based Method for Evaluating Liquefaction Resistance of Soils", *Journal of Geotechnical and Geoenvironmental Engineering*, 129(1), 66-80.
- Kramer, S. L. (1996), "Geotechnical Earthquake Engineering", Pearson Education India.
- Livingston, G., Piantedosi, M., Kurup, P., Sitharam, T. G. (2008), "Using Decision-Tree Learning to Assess Liquefaction Potential from CPT and V_s ", *Geotechnical Earthquake Engineering and Soil Dynamics IV*, (pp. 1-10).
- McCulloch, W. S., Pitts, W. (1943), "A Logical Calculus of the Ideas Immanent in Nervous Activity", *The Bulletin of Mathematical Biophysics*, 5, 115-133.
- Ozener, P., Monkul, M. M., Bayat, E. E., Ari, A., Cetin, K. O. (2024), "Liquefaction and Performance of Foundation Systems in Iskenderun During 2023 Kahramanmaraş-Türkiye Earthquake Sequence", *Soil Dynamics and Earthquake Engineering*, 178, 108433.
- Özsağır, M., Erden, C., Bol, E., Sert, S., Özocak, A. (2022), "Machine Learning Approaches for Prediction of Fine-Grained Soils Liquefaction", *Computers and Geotechnics*, 152, 105014.
- Toprak, S., Holzer, T. L. (2003), "Liquefaction Potential Index: Field Assessment", *Journal of Geotechnical and Geoenvironmental Engineering*, 129(4), 315-322.
- Zhao, Z., Duan, W., Cai, G., Wu, M., Liu, S. (2022), "CPT-Based Fully Probabilistic Seismic Liquefaction Potential Assessment to Reduce Uncertainty: Integrating Xgboost Algorithm with Bayesian Theorem", *Computers and Geotechnics*, 149, 104868.