

SPT-CPT İlişkisinin Yapay Zeka Desteğiyle Çeşitli Zemin Tipleri İçin Araştırılması

Arda Burak EKME¹ 

*¹ Harran Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği Bölümü, ŞANLIURFA

(Alınış / Received: 15.04.2023, Kabul / Accepted: 19.06.2023, Online Yayınlanma / Published Online: 31.08.2023)

Anahtar Kelimeler

Koni Penetrasyon Testi
Standart Penetrasyon Testi
Yapay Zeka
SPT-CPT korelasyonu

Öz: Standart Penetrasyon Testi (SPT) ve Koni Penetrasyon Testi (CPT) zemin araştırmalarında en sık kullanılan yöntemler arasında yer almaktadır. Birçok zemin parametresi SPT ve/veya CPT ile ilişkilendirilmiştir. Bu testlerden herhangi birinin yokluğunda bir diğ erinin kullanılabilmesi için SPT-CPT arasında güvenilir bir korelasyonun elde edilmesi önem arz etmektedir. Bu çalışmada literatürden yararlanılarak çeşitli zemin tipleri için SPT-N verilerine karşılık gelen CPT ile elde edilmiş uç direnci (q_c) değerlerine ulaşılmıştır. SPT-N değerleri ile uç direnci (q_c) verileri arasında anlamlı bir ilişkinin var olup olmadığını araştırmak için varyans analizi gerçekleştirilmiştir. SPT-CPT korelasyonu için yapay sinir ağları ile simüle edilebilir ağlar oluşturularak her zemin tipine özgü yüksek dereceli korelasyon değerlerine sahip ayrı fonksiyonlar elde edilmiştir. Ulaşılan sonuçlar deneysel verilerle ve literatürdeki denklemlerle karşılaştırılmıştır. Böylece farklı zemin tipleri için yapay zeka desteğiyle oluşturulmuş iyi derecede korelasyon değerlerine sahip fonksiyonların yardımıyla SPT ile elde edilen sonuçların CPT ile anlamlı olarak ilişkilendirilmesine olanak sağlanmıştır. Farklı bölgelere ait çok sayıda verinin kullanılması durumunda yapay sinir ağları ile SPT-CPT korelasyonu oluşturmanın başarılı bir yöntem olacağı sonucuna varılmıştır.

Investigation of SPT-CPT Relationship for Various Soil Types with Artificial Intelligence Support

Keywords

Cone Penetration Test
Standard Penetration Test
Artificial intelligence
SPT-CPT correlation

Abstract: Among the most popular techniques for conducting soil investigations are the Standard Penetration Test (SPT) and Cone Penetration Test (CPT). Numerous soil characteristics are linked with SPT and/or CPT. It is essential to obtain a reliable correlation between SPT and CPT to use one of these tests individually. In this study, the tip resistance (q_c) values obtained with CPT corresponding to SPT-N data for various soil types were reached utilizing the literature. Analysis of variance was accomplished to establish whether there was a considerable relationship between SPT-N data and tip resistance (q_c) values. Separate functions with high-order correlation values were obtained for each soil type by creating simulatable networks with artificial neural networks for SPT-CPT correlation. The acquired outcomes were compared with experimental results and equations in the literature. As a result, functions in good correlation values created by the support of artificial intelligence for various soil types have provided the opportunity to correlate SPT and CPT outcomes significantly. It has been concluded that using a large number of data from various locations will enable in an effective way for generating SPT-CPT correlation with artificial neural networks.

*İlgili Yazar, email: ardaburakekmen@harran.edu.tr

1. Giriş

Standart Penetrasyon Testi ve Koni Penetrasyon Testi zeminlerin çeşitli parametreleri hakkında bilgi sahibi olmak amacıyla araştırmalarda en sık kullanılan yöntemler arasında yer almaktadır. Zeminlerin çeşitli parametrelerini tahmin etmek için birçok araştırmacı [1-11] SPT ve CPT değerleri ile ilişkiler kurmuştur. Uzun yıllardır yaygın bir saha testi olarak kullanılan SPT, diğer saha testlerine göre avantajlarından dolayı günümüzde hala popülaritesini sürdürmektedir. Dolayısıyla zemin parametrelerinin diğer arazi testleri yerine SPT verileri ile ilişkilendirilmesi daha yaygındır. SPT, diğer saha testlerine göre dış şartlara daha bağımlı bir testtir. Bu sebeple uygulanan prosedürün doğru bir şekilde işletilmesi önem arz etmektedir. SPT uygulamalarında dış etkenlere bağlı olarak anlamlı sonuçlar elde etmek için sahada ölçülen darbe sayısı dikkate alınan parametrelere göre düzeltilir.

Koni penetrasyon testi, zemin parametrelerinin çeşitli verilerle ilişkilendirilebildiği popüler bir diğer arazi uygulamasıdır. Teknolojinin ilerleyişine bağlı olarak bu test zaman içinde gelişerek günümüzdeki halini almıştır. Güncel CPT uygulamalarında uç direnci (q_c), sürtünme direnci (f_s) ve boşluk suyu basıncı parametrelerinin ölçülmesi mümkün hale gelmiştir. CPT uygulamasının SPT'ye göre çok kanaldan veri sağlama, daha güvenilir veri elde etme ve sürekli bir profil sağlama gibi çeşitli avantajları vardır. Ancak belirtilen özelliklerden dolayı CPT testinin kullanımı artmış olsa da cihazın maliyetinin yüksek olması, cihazı kullanacak uzman operatör yetersizliği, cihazın her yerde bulunmaması gibi nedenlerden dolayı SPT uygulamasının sık kullanımı günümüzde devam etmektedir [12]. Bu kapsamda SPT ve CPT verilerinin birbirlerine güvenli korelasyonlar ile dönüşümlerinin yapılabilmesi önem arz etmektedir. SPT ve CPT değerlerini birbirine dönüştürmek amacıyla literatürde çeşitli çalışmalar yer almıştır [12-20]. Bu kapsamda kurulan ilişkilerin hata paylarının düşük ve korelasyon katsayılarının yüksek olması iyi tahminler elde etmek için önemli bir noktadır. Çeşitli yöntemlerle elde edilebilen tahmin fonksiyonlarının iyi derecede korelasyonlarla oluşturulması için birçok faktör duruma etki etmektedir. Ancak bu faktörlerden en önemlisi anlamlı derecedeki veri sayısıdır. Anlamlı veri sayısı arttıkça arazideki duruma daha yakın sonuçların elde edilmesi mümkün olmaktadır. Bu çalışma kapsamındaki araştırmalarda verileri dikkate alınan Jarushi ve ark. [20], SPT-N değerlerine bağlı olarak CPT ile elde edilen q_c değerlerini tahmin ettikleri çalışmalarında birçok zemin tipi için çok sayıda veri kullanarak regresyon analizleri gerçekleştirmişlerdir. SPT ve CPT verilerinin farklı noktalardan alınması iyi derecede korelasyonların elde edilmesinde önemlidir.


Teknolojinin gelişimine bağlı olarak bilgisayarların bellek ve işlemci kapasitelerinin gelişmesiyle veri tahmin yöntemleri için yapay sinir ağlarının kullanımı popülerleşmiştir. Yapay zekanın çalışma sistemi insan beyninin bilgi işleme yöntemine benzer niteliktedir. Yapay sinir ağları sistemlerinde yer alan nöronlar birbirlerine bağlanarak öğrenme özelliğine sahip yapılar oluştururlar [7]. Bu sistemde yer alan her nöron kendisine bağlı nöronlara gönderilen sinyaller sayesinde iletişim sağlar. Böylece katmanlar arası bağlantının sağlanması mümkün hale gelir. Yapay zeka sistemlerinde veriler yeterli düzeyde eğitilerek çıktı katmanının veri tahmini yapmasını sağlar. Bu bağlamda yapay sinir ağları kullanılarak iyi derecede veri tahminleri yapılabilmesi için yeterli verinin bulunması önemli bir etkidir. Literatürde geoteknik mühendisliği kapsamında yapay sinir ağlarının kullanıldığı çalışmalar mevcuttur [21-27]. Bu çalışmalar yapay zeka uygulamalarının geoteknik mühendisliği kapsamında işlevsel olduğunu göstermektedir. Ayrıca inşaat mühendisliğinin diğer alanlarında da yapay zeka destekli çalışmalar yürütülmektedir [28-29].

Bu çalışma kapsamında, literatürde yer alan deneysel verilerden yararlanılarak farklı noktalardaki çok sayıda düzeltilmemiş SPT-N verisine karşılık gelen çeşitli zeminlerin CPT uç direnci (q_c) değerleri elde edilmiştir. SPT ile CPT verileri arasında tahmin fonksiyonları oluşturmak için bu veriler kullanılarak yapay sinir ağları ile simüle edilebilen ağlar oluşturulmuş ve elde edilen korelasyonlar değerlendirilmiştir. Yapay sinir ağı oluşturmada kullanılan SPT ile CPT verilerinin arasında anlamlı bir ilişkinin var olup olmadığını araştırmak için varyans analizi gerçekleştirilmiştir. CPT uç direnci (q_c) değerlerini SPT verileri aracılığıyla tahmin edebilmek için yapay sinir ağları kullanılarak simülasyonlar yapılmıştır. Yapay sinir ağları ile elde edilen sonuçlar, literatürdeki denklemler ve deneysel sonuçlarla karşılaştırılmıştır.

2. Materyal ve Metot

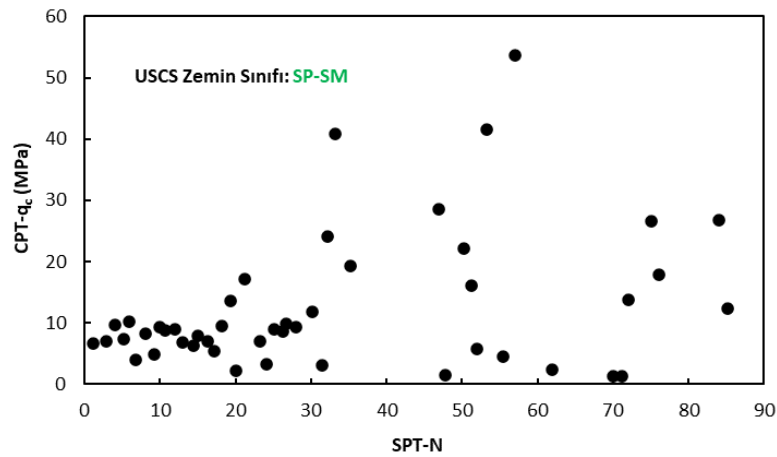
2.1. Simülasyonlarda kullanılan verilerle ilgili detaylar

Bu çalışma kapsamında SPT-N verilerine karşılık gelen çeşitli zeminlerin CPT uç direnci (q_c) değerlerinin tahmini için iyi derecede korelasyon katsayılarına sahip ağlar oluşturabilme özelliğinden dolayı geoteknik mühendisliğinde başarılı simülasyon örnekleri bulunan yapay sinir ağları kullanılmıştır. Bu çalışmada yapay sinir ağlarında simüle edilmek üzere seçilen veri seti, Jarushi ve ark. [20] tarafından sunulan çalışmada yer alan farklı zemin tipleri için SPT-N verilerine karşılık deneysel olarak elde edilmiş CPT uç direnci (q_c) değerlerinden oluşmuştur. Şekil 1'de Jarushi ve ark. [20] tarafından çalışılan bölge (Florida, Amerika Birleşik Devletleri) gösterilmiştir.




Şekil 1. Simülasyonlarda kullanılan verilerin bulunduğu bölge

Jarushi ve ark. [20], dikkate alınarak altı farklı zemin tipi için deneysel veriler değerlendirmeye alınmıştır. Şekil 2'de USCS sistemine göre SP-SM sınıfında yer alan zemin için fonksiyon oluşturmada kullanılan deneysel veriler [20] sunulmuştur.



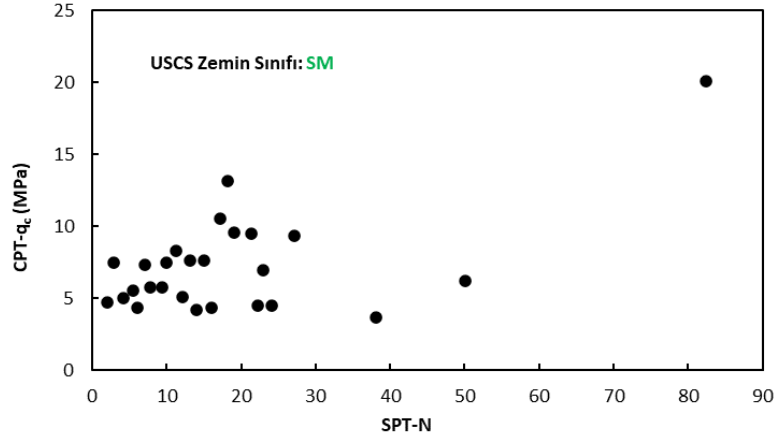
Şekil 2. USCS sistemine göre SP-SM sınıfında yer alan zemin için fonksiyon oluşturmada kullanılan deneysel veriler [20]

Şekil 3'te USCS sistemine göre SP sınıfında yer alan zemin için fonksiyon oluşturmada kullanılan deneysel veriler [20] sunulmuştur.




Şekil 3. USCS sistemine göre SP sınıfında yer alan zemin için fonksiyon oluşturmada kullanılan deneysel veriler [20]

Şekil 4'te USCS sistemine göre SM sınıfında yer alan zemin için fonksiyon oluşturmada kullanılan deneysel veriler [20] sunulmuştur.




Şekil 4. USCS sistemine göre SM sınıfında yer alan zemin için fonksiyon oluşturmada kullanılan deneysel veriler [20]

Şekil 5'te USCS sistemine göre SC sınıfında yer alan zemin için fonksiyon oluşturmada kullanılan deneysel veriler [20] sunulmuştur.



Şekil 5. USCS sistemine göre SC sınıfında yer alan zemin için fonksiyon oluşturmada kullanılan deneysel veriler [20]

Şekil 6'da USCS sistemine göre SM-SC sınıfında yer alan zemin için fonksiyon oluşturmada kullanılan deneysel veriler [20] sunulmuştur.



Şekil 6. USCS sistemine göre SM-SC sınıfında yer alan zemin için fonksiyon oluşturmada kullanılan deneysel veriler [20]

Şekil 2-6'da sunulan veriler için yapay sinir ağları kullanarak fonksiyon oluşturmada önce verilerin istatistiksel olarak anlamlı olup olmadıklarını incelemek amacıyla tüm veri setlerine varyans analizi yapılmıştır.

2.2. Varyans Analizi

SPT verilerinin değişiminin CPT uç direnci (q_c) değerleri üzerinde istatistiksel olarak anlamlılığını araştırmak için ilgili verilerle varyans analizi yapılmıştır. Varyans analizinde Genelleştirilmiş Doğrusal Model kullanılmıştır. Bu çalışmada düzeltilmemiş SPT-N değerleri bağımsız değişken olarak işleme alınırken CPT uç direnci (q_c) değerleri ise bağımlı değişken olarak belirlenmiştir. Gerçekleştirilen varyans analizi çalışmasının sonuçları Bölüm 3.1'de sunulmuş ve değerlendirilmiştir.


2.3. Yapay Sinir Ağları ile Modelleme ve Analiz

Yapay zeka günümüzde bir bilim alanı olarak kabul edilmektedir ve yapay zeka sistemlerinde makinelerin yaratıcı davranarak çözümler üretmesi hedeflenmektedir. Yapay zekanın bir ürünü olan yapay sinir ağları ile veri tahmin modelleri oluşturmak için ağı eğitebilecek düzeyde yeterli veri sayısına ulaşmak gerekmektedir. Kullanılan veri ve değişken sayısının artması işlem süresinin artmasına neden olmaktadır. Bu kapsamda veri seti ve değişken sayısı arttıkça gelişmiş bilgisayar sistemlerine duyulan ihtiyaç fazlalasmaktadır. Günümüzdeki bilgisayarların bellek ve işlemci sistemleri yapay zeka kullanımı için ihtiyaç duyulan sistem gereksinimlerini büyük oranda karşıladığından mühendislik problemlerinde yapay zeka araçlarının kullanımı artış göstermiştir. Yapay sinir ağları ile oluşturulan ağlar yeni ilişkiler kurma ve öğrenme kabiliyetine sahiptirler. Bu sistemde girdi olarak sunulan veriler eğitilir ve oluşturulan simülasyonda çıktılar için tahmin yapılması sağlanır. Standart eğri uydurma işlevlerine kıyasla yapay sinir ağları ile iyi derecede tahmin fonksiyonları oluşturmak mümkündür. Bu çalışmada SPT-N verileri ile CPT uç direnci (q_c) değerleri arasında yapay sinir ağları kullanılarak tahmin fonksiyonları Matlab yazılımında [30] üretilen kodlama aracılığıyla oluşturulmuştur. Tablo 1'de bu çalışma kapsamındaki tüm yapay sinir ağı modellerinde kullanılan seçenekler sunulmuştur.

Tablo 1. Bu çalışma kapsamındaki tüm yapay sinir ağı modellerinde kullanılan seçenekler

| | |
|---|-------------------------|
| Eğitim, test ve validasyon verilerinin seçimi | Rastgele |
| Eğitim, test ve validasyon verilerinin yüzdesel dağılışı | %70-%15-%15 |
| Gizli katman sayısı | 1 |
| Nöron denemeleri | 1 ile 16 arası |
| Performans fonksiyonu | Ortalama karesel hata |
| İterasyon Sayısı | Otomatik seçim |
| Seçilen yöntem | Bayesian Regularization |

Yapay sinir ağlarında girdi olarak düzeltilmemiş SPT-N değerleri, çıktı olarak CPT uç direnci (q_c) kullanılmıştır. Verilerin %70'i eğitim için ayrılırken %15'i test ve %15'i ise validasyon değerleri olarak rastgele bir şekilde ayrılmıştır. Rastgele ayrılan %70'lik eğitim setinde iyi tahminler yapılabilmesi için seçilen veriler ile yapay sinir ağları eğitilmiştir. Sistemin belirtilen kısıtlar dahilinde en iyi performansın olduğu noktayı yakalaması için otomatik iterasyon tercih edilmiştir. Validasyon verileri ile eğitim esnasında model performansı doğrulanmış ve eğitimin doğru şekilde gidip gitmediği belirlenmiştir. Böylece hatalı veri uydurma işlevi önlenmiştir. Test seti ise validasyondan farklı bir biçimde eğitim işlemi tamamladıktan sonra modeli test etmek için kullanılmış ve modelin ne kadar iyi performans sergilediği araştırılmıştır. Bu çalışma kapsamındaki tüm yapay sinir ağı modellerinde regresyon fonksiyonunun oluşturulması için iyi tahminler yapabilen Bayesian Regularization yöntemi kullanılmıştır. Değerlendirilen parametreler bir girdi ve bir çıktıdan oluştuğu için tek gizli katman seçilmiş olup nöron sayısı 1 ile 16 arasında değiştirilmiştir. Performans fonksiyonu olarak ortalama karesel hata seçilmiştir. Şekil 7'de bu çalışma kapsamındaki tüm yapay sinir ağı modellerinde kullanılan algoritma sunulmuştur.



Şekil 7. Bu çalışma kapsamındaki tüm yapay sinir ağı modellerinde kullanılan algoritma

Kullanılan algoritmada ağ seçimi yapılırken en uygun ağ elde edilene kadar döngü devam edecek şekilde bir yapı oluşturulmuştur. Varyans analizi sonucunda bağımlı ve bağımsız değişkenler arasında anlamlı bir ilişki bulunmuştur. Bu bağlamda anlamlı bulunan veriler yapay sinir ağları çözüm algoritmasına aktarılmıştır. Şekil 7'de gösterilen w , tüm ağırlıkları ve b eğilimleri ifade etmektedir. Her bir veri setini kapsayan her analiz için 16 farklı kombinasyon değerlendirilmiş ve istatistiksel anlamda en iyi sonucu veren kombinasyon ilgili algoritma tarafından seçilmiştir.

3. Bulgular

Çalışmanın Materyal ve Metot kısmında yer alan analizlerin sonuçları aşağıdaki alt bölümlerde sunulmuştur.

3.1. Varyans Analizi

Tablo 2’de bu çalışma kapsamında yürütülen tüm varyans analizlerinin sonuçları sunulmuştur.


Tablo 2. Varyans analizi sonuçları

| Zemin Sınıfı | Bağımsız Değişken | Bağımlı Değişken | Parametreler | | | | | Anlamlılık |
|--------------|-------------------|------------------|---------------------|-----------------|---------------|-------|-----------------------|------------|
| | | | Serbestlik Derecesi | Kareler Toplamı | Ortalama Kare | F | P-değeri | |
| SP-SM | SPT-N | q _c | 1 | 668.84 | 668.84 | 5.92 | 0.019 | Evet |
| | | Hata | 45 | 5081.49 | 112.92 | | | |
| SP | SPT-N | q _c | 1 | 427.03 | 427.03 | 35.15 | 4.8x10 ⁻⁰⁶ | Evet |
| | | Hata | 23 | 279.39 | 12.14 | | | |
| SM | SPT-N | q _c | 1 | 109.23 | 109.23 | 13.33 | 0.0013 | Evet |
| | | Hata | 24 | 196.59 | 8.19 | | | |
| SC | SPT-N | q _c | 1 | 45.39 | 45.39 | 4.29 | 0.045 | Evet |
| | | Hata | 38 | 401.55 | 10.56 | | | |
| SM-SC | SPT-N | q _c | 1 | 400.14 | 400.14 | 14.66 | 0.00076 | Evet |
| | | Hata | 25 | 681.99 | 27.27 | | | |

%95 güven aralığında gerçekleştirilen varyans analizleri sonucunda P-değerleri tüm analizlerde 0.05’ten küçük olarak elde edilmiştir. Böylece Tablo 2’de sunulan SPT-N değerine bağlı olan CPT- q_c değerinin istatistiksel olarak anlamlı olduğu belirlenmiştir. Tüm zemin sınıfları için anlamlı ilişkiler elde edildiğinden tüm deneysel veriler yapay sinir ağlarında model oluşturmak için kullanılmıştır.

3.2. Yapay Sinir Ağları ile Gerçekleştirilen Simülasyonun Sonuçları


Şekil 7’de gösterilen algoritma kapsamında yapay sinir ağları kullanılarak tüm veri setlerinde 16 farklı nöron kombinasyonu ile oluşturulan ağlar arasından istatistiksel olarak en iyi sonucu veren seçenekler seçilmiştir. Bayesian Regularization yöntemiyle oluşturulan yapay sinir ağlarının simüle edilmesiyle veri tahminleri gerçekleştirilmiştir. Şekil 8’de çalışılan tüm veriler için elde edilmiş eğriler ve R değerleri sunulmuştur.



Şekil 8. Yapay sinir ağları ile oluşturulan regresyon fonksiyonlarının çeşitli zemin tipleri için istatistiksel verileri;


a) SP-SM, b) SP, c) SM, d) SC, e) SM-SC

Şekil 9'da çalışılan tüm zemin tipleri için seçilen tüm ağların fonksiyon eğri uydurma ve hata durumları gösterilmiştir. Hata oranlarının eğitim, test ve doğrulama (validasyon) verileri için düşük ve birbirlerine yakın olması elde edilen fonksiyonların geçerliliğini göstermektedir.




Şekil 9. Çalışılan tüm zemin tipleri için seçilen tüm ağların fonksiyon eğri uydurma ve hata durumları

Şekil 10'da SP-SM zemin sınıfı için SPT-N değerlerine karşılık gelen CPT- q_c deneysel verileri, Jarushi ve ark. [20] tarafından oluşturulan denklem ile elde edilen sonuçlar ve bu çalışma kapsamında yapay sinir ağları kullanarak elde edilen değerlerin karşılaştırılması sunulmuştur.




Şekil 10. SP-SM zemin sınıfı için SPT-N değerlerine karşılık gelen CPT- q_c deneysel verileri, Jarushi ve ark. [20] tarafından oluşturulan denklem ile elde edilen sonuçlar ve bu çalışma kapsamında yapay sinir ağları kullanarak elde edilen değerlerin karşılaştırılması

Şekil 11'de SP zemin sınıfı için SPT-N değerlerine karşılık gelen CPT- q_c deneysel verileri, Jarushi ve ark. [20] tarafından oluşturulan denklem ile elde edilen sonuçlar ve bu çalışma kapsamında yapay sinir ağları kullanarak elde edilen değerlerin karşılaştırılması sunulmuştur.



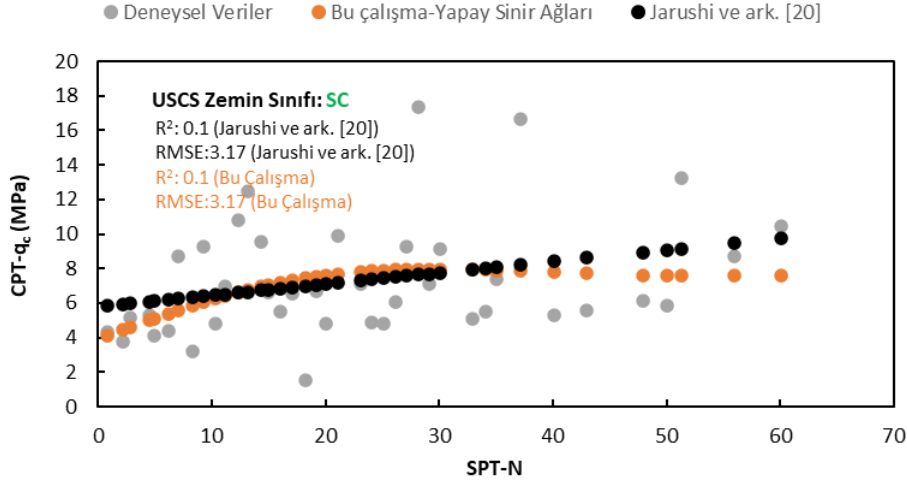
Şekil 11. SP zemin sınıfı için SPT-N değerlerine karşılık gelen CPT- q_c deneysel verileri, Jarushi ve ark. [20] tarafından oluşturulan denklem ile elde edilen sonuçlar ve bu çalışma kapsamında yapay sinir ağları kullanarak elde edilen değerlerin karşılaştırılması

Şekil 12’de SM zemin sınıfı için SPT-N değerlerine karşılık gelen CPT- q_c deneysel verileri, Jarushi ve ark. [20] tarafından oluşturulan denklem ile elde edilen sonuçlar ve bu çalışma kapsamında yapay sinir ağları kullanarak elde edilen değerlerin karşılaştırılması sunulmuştur.




Şekil 12. SM zemin sınıfı için SPT-N değerlerine karşılık gelen CPT- q_c deneysel verileri, Jarushi ve ark. [20] tarafından oluşturulan denklem ile elde edilen sonuçlar ve bu çalışma kapsamında yapay sinir ağları kullanarak elde edilen değerlerin karşılaştırılması

Şekil 13’te SC zemin sınıfı için SPT-N değerlerine karşılık gelen CPT- q_c deneysel verileri, Jarushi ve ark. [20] tarafından oluşturulan denklem ile elde edilen sonuçlar ve bu çalışma kapsamında yapay sinir ağları kullanarak elde edilen değerlerin karşılaştırılması sunulmuştur.



Şekil 13. SC zemin sınıfı için SPT-N değerlerine karşılık gelen CPT- q_c deneysel verileri, Jarushi ve ark. [20] tarafından oluşturulan denklem ile elde edilen sonuçlar ve bu çalışma kapsamında yapay sinir ağları kullanarak elde edilen değerlerin karşılaştırılması

Şekil 14'te SM-SC zemin sınıfı için SPT-N değerlerine karşılık gelen CPT- q_c deneysel verileri, Jarushi ve ark. [20] tarafından oluşturulan denklem ile elde edilen sonuçlar ve bu çalışma kapsamında yapay sinir ağları kullanarak elde edilen değerlerin karşılaştırılması sunulmuştur.



Şekil 14. SM-SC zemin sınıfı için SPT-N değerlerine karşılık gelen CPT- q_c deneysel verileri, Jarushi ve ark. [20] tarafından oluşturulan denklem ile elde edilen sonuçlar ve bu çalışma kapsamında yapay sinir ağları kullanarak elde edilen değerlerin karşılaştırılması

Veri tahmini için kullanılan yöntemlerin tahmin başarısını karşılaştırmak için Şekil 10-14'te sunulan grafikler çizilmiştir. Elde edilen grafikler için korelasyon katsayıları (R^2) ve ortalama karesel hataların kökleri (RMSE) hesaplanmıştır. İlgili grafiklerde görüldüğü üzere bu çalışma kapsamında yapay sinir ağları kullanarak yapılan veri tahminleri deneysel verilere oldukça iyi düzeyde yaklaşmış olup hiçbir analizde Jarushi ve ark. [20] tarafından yapılan veri tahmini istatistiksel başarısının altında kalmamıştır. Beş farklı zemin tipi için yapılan analizlerin dördünde Jarushi ve ark. [20] tarafından yapılan tahminlere göre çok iyi düzeyde korelasyon katsayısı elde edilmiştir. SC zemin tipi için ise her iki yöntemin tahmin başarısı neredeyse aynıdır. Bu çalışma kapsamında yapay sinir ağları ile deneysel verilere en çok yaklaşılan en iyi tahminler ise SM-SC zemin tipinde gerçekleşmiştir. Tablo 3'te tüm zemin tipleri için bu çalışma kapsamındaki yapay sinir ağları ile oluşturulan fonksiyonların ve Jarushi ve ark. [20] tarafından yapılan veri tahminlerinin istatistiksel değerlendirmeleri sunulmuştur.

Tablo 3. Tüm zemin tipleri için bu çalışma kapsamındaki yapay sinir ağları ile oluşturulan fonksiyonların ve Jarushi ve ark. [20] tarafından yapılan veri tahminlerinin istatistiksel değerlendirmeleri

| Zemin Sınıfı | R ² : (Jarushi ve ark. [20]) | R ² : (Bu Çalışma) | RMSE: (Jarushi ve ark. [20]) | RMSE: (Bu Çalışma) |
|--------------|---|-------------------------------|------------------------------|--------------------|
| SP-SM | 0.11 | 0.48 | 10.39 | 8.29 |
| SP | 0.60 | 0.81 | 3.34 | 2.46 |
| SM | 0.35 | 0.73 | 2.75 | 1.97 |
| SC | 0.10 | 0.10 | 3.17 | 3.17 |
| SM-SC | 0.37 | 0.89 | 5.02 | 2.07 |
| Ortalama | 0.30 | 0.60 | 4.93 | 3.59 |

Tablo 3'te görülebileceği üzere bu çalışma kapsamında yapay sinir ağları simülasyonları ile tüm zemin tipleri için elde edilen ortalama R² değeri 0.6 iken Jarushi ve ark. [20] tarafından yapılan veri tahminlerinde ortalama R² değeri 0.3'tür. Benzer şekilde hatayı tanımlayan RMSE değerlerinde bu çalışma kapsamında yapay sinir ağları simülasyonları ile tüm zemin tipleri için elde edilen ortalama değer 3.59 iken Jarushi ve ark. [20] tarafından yapılan veri tahminlerinde ortalama değer 4.93'tür. İstatistiksel veriler hem ortalama bazlı hem de zemin tipi bazlı ayrı ayrı değerlendirildiğinde bu çalışma kapsamında yapay sinir ağları ile yapılan veri tahminlerinin diğer yöntemlere göre çok daha iyi sonuçlar verdiği belirlenmiştir.

4. Tartışma ve Sonuç

Zemin mekaniği kapsamındaki çalışmalarda birçok zemin parametresinin SPT ve CPT ile ilişkilendirildiği bilinmektedir. SPT-CPT arasında iyi derecede bir korelasyonun elde edilmesi belirtilen testlerden herhangi birinin uygulanmaması durumunda diğer testin kullanılabilmesi adına gerekli bir durumdur. Bu çalışma kapsamında SPT-CPT arasında iyi derecede bir korelasyon elde edebilmek için literatürden yararlanılarak çeşitli zemin tipleri için deneysel verilere ulaşılmıştır. Ulaşılan deneysel verilerin anlamlılığı istatistiksel olarak belirlendikten sonra yapay sinir ağları ile SPT-CPT ilişkisine ait yüksek dereceli korelasyonlarda her bir veri seti için ayrı fonksiyonlar elde edilmiştir. Koni Penetrasyon Testi ile elde edilen q_c değerleri Standart Penetrasyon Testi verilerine bağlı olarak yapay sinir ağları ve literatürde sunulan denklemler kullanılarak hesaplanmıştır. Her iki yöntem birbiri ile kıyaslanmış ve istatistiksel olarak en iyi sonucu veren yöntem belirlenmiştir. Veri tahmininde kullanılan yöntemleri karşılaştırmak için deneysel verileri ve her iki yöntemin de tahmin sonuçlarını içeren grafiksel çözümler yapılmıştır. Oluşturulan grafiklerde tüm yöntemler deneysel verilerle kıyaslanarak korelasyon katsayıları (R²) ve ortalama karesel hataların kökleri (RMSE) hesaplanmıştır. Elde edilen grafiklerden ve istatistiksel çözümlerden bu çalışma kapsamındaki yapay sinir ağları ile yapılan veri tahminlerinin deneysel verilere iyi düzeyde yaklaştığı olduğu ve hiçbir analizde dikkate alınan literatürdeki veri tahmin yönteminin istatistiksel başarısının altında kalmadığı belirlenmiştir. SP-SM, SP, SM, SC, SM-SC sınıflarındaki farklı zemin tipleri için yapılan analizlerin dördünde dikkate alınan literatürdeki veri tahmin yöntemine göre çok iyi düzeyde korelasyon katsayılarına ve düşük hata oranlarına ulaşılmıştır. Yapay sinir ağlarıyla yapılan tahminlerde SC zemin tipi için diğer yöntemle oldukça benzer korelasyon katsayıları ve hata oranları elde edilirken bu çalışma kapsamındaki simülasyonlarda deneysel verilere en çok yaklaşılan SM-SC zemin tipinde gerçekleştirilen analizler olmuştur. Dikkate alınan literatürdeki tahmin yöntemi ile gerçekleştirilen veri tahminlerinde ortalama R² değeri 0.3 iken yapay sinir ağları simülasyonları kullanılarak bu çalışma kapsamında dikkate alınan tüm zemin sınıfları için elde edilen ortalama R² değeri 0.6'dır. Ayrıca hata göstergesi olan RMSE değerlerinde dikkate alınan literatürdeki tahmin yöntemi ile yapılan veri tahminlerinde ortalama değer 4.93 iken bu çalışma kapsamında yapay sinir ağları simülasyonları ile tüm zemin tipleri için elde edilen ortalama değer 3.59 olmuştur. İstatistiksel veriler açısından hem zemin tipine hem de ortalama değerlere göre ayrı ayrı değerlendirme yapıldığında bu çalışma kapsamında yapay sinir ağları ile yapılan veri tahminlerinin literatürde yer alan yöntemlere göre çok daha anlamlı sonuçlar verdiği görülmüştür. Böylece yapay sinir ağları ile elde edilen istatistiksel başarı dikkate alındığında çeşitli zemin sınıfları için yapay zeka ile oluşturulmuş iyi derecede korelasyon değerlerine sahip fonksiyonlar aracılığıyla SPT ile elde edilen sonuçların CPT ile anlamlı olarak ilişkilendirilmesine olanak sağlandığı söylenebilir. Bu kapsamda farklı çalışma sahalarına ait çok sayıda veri setinin kullanılması durumunda yapay sinir ağları ile SPT-CPT korelasyonu elde etmenin başarılı bir yöntem olacağı sonucuna varılmıştır.

Kaynakça

- [1] Hettiarachchi, H., & Brown, T. (2009). Use of SPT blow counts to estimate shear strength properties of soils: energy balance approach. *Journal of Geotechnical and Geoenvironmental Engineering*, 135(6), 830-834.
- [2] Zhou, H., Wotherspoon, L. M., Hayden, C. P., Stolte, A. C., & McGann, C. R. (2023). Applicability of existing CPT-Vs correlations to shallow Holocene Christchurch soils based on direct Push crosshole testing. *Engineering Geology*, 313, 106927.
- [3] Anagnostopoulos, A., Koukis, G., Sabatakakis, N., & Tsiambaos, G. (2003). Empirical correlations of soil parameters based on cone penetration tests (CPT) for Greek soils. *Geotechnical & geological engineering*, 21, 377-387.
- [4] Jianguo, C. H. E. N. G. (2012). Correlation Analysis of SPT \sqrt{N} Values and Cohesion c and International Angle of a Clay. *Soil Engineering and Foundation*, 26(4), 91.
- [5] Lu, Y. C., Liu, L. W., Khoshnevisan, S., Ku, C. S., Juang, C. H., & Xiao, S. H. (2022). A new approach to constructing SPT-CPT correlation for sandy soils. *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards*, 1-17.
- [6] Kumar, R., Bhargava, K., & Choudhury, D. (2016). Estimation of engineering properties of soils from field SPT using random number generation. *INAE Letters*, 1(3), 77-84.
- [7] Ekmen, A. B. (2023). Evaluation of SPT-N values and internal friction angle correlation using artificial intelligence methods in granular soils. *Soil Research*.
- [8] Cubrinovski, M., & Ishihara, K. (1999). Empirical correlation between SPT N-value and relative density for sandy soils. *Soils and Foundations*, 39(5), 61-71.
- [9] S Dalai, S., & Patra, C. (2021). Prediction of Angle of Internal Friction Based on SPT N Values. In *Proceedings of the Indian Geotechnical Conference 2019* (pp. 471-477). Springer, Singapore.
- [10] Hatta, K. A., & Syed Osman, S. B. A. (2015). Correlation of electrical resistivity and SPT-N value from standard penetration test (SPT) of sandy soil. In *Applied Mechanics and Materials* (Vol. 785, pp. 702-706). Trans Tech Publications Ltd.
- [11] Poor, M. M., Azarafza, M., & Derakhshani, R. (2023). A correlation based on pressuremeter, SPT and CPT tests for characterizing of coastal alluvium: A study for phase 14 South Pars, Iran. *MethodsX*, 10, 101938.
- [12] Bol, E. (2023). A new approach to the correlation of SPT-CPT depending on the soil behavior type index. *Engineering Geology*, 106996.
- [13] Faivre, Y., Mirzaghobanali, A., Nourizadeh, H., Shokri, B. J., McDougall, K., & Aziz, N. (2023). SPT-CPT correlation in Southeast Queensland, Australia.
- [14] Robertson, P. K., Campanella, R. G., & Wightman, A. (1983). Spt-Cpt Correlations. *Journal of Geotechnical Engineering*, 109(11), 1449-1459.
- [15] Chin, C. T., Duann, S. W., & Kao, T. C. (1990). SPT-CPT correlations for granular soils. In *International Journal of Rock Mechanics and Mining Sciences and Geomechanics Abstracts* (Vol. 27, No. 2, pp. A91-A91). Elsevier Science.
- [16] Akca, N. (2003). Correlation of SPT-CPT data from the United Arab Emirates. *Engineering Geology*, 67(3-4), 219-231.
- [17] Lu, Y. C., Liu, L. W., Khoshnevisan, S., Ku, C. S., Juang, C. H., & Xiao, S. H. (2022). A new approach to constructing SPT-CPT correlation for sandy soils. *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards*, 1-17.
- [18] Kruizinga, J. (2021, February). SPT-CPT correlations. In *Penetration Testing* (pp. 91-94). Routledge.

- [19] Zhou, H., Wotherspoon, L. M., Hayden, C. P., McGann, C. R., Stolte, A., & Haycock, I. (2021). Assessment of Existing SPT-CPT Correlations Using a New Zealand Database. *Journal of Geotechnical and Geoenvironmental Engineering*, 147(11), 04021131.
- [20] Jarushi, F., AlKaabim, S., & Cosentino, P. (2015). A new correlation between SPT and CPT for various soils. *International Journal of Geological and Environmental Engineering*, 9(2), 101-107.
- [21] Park, H. I., & Lee, S. R. (2011). Evaluation of the compression index of soils using an artificial neural network. *Computers and Geotechnics*, 38(4), 472-481.
- [22] Lai, J., Qiu, J., Feng, Z., Chen, J., & Fan, H. (2016). Prediction of soil deformation in tunnelling using artificial neural networks. *Computational Intelligence and Neuroscience*, 2016.
- [23] Luat, N. V., Lee, K., & Thai, D. K. (2020). Application of artificial neural networks in settlement prediction of shallow foundations on sandy soils. *Geomechanics and Engineering*, 20(5), 385-397.
- [24] Amini, O., Khoshghalb, A., & Etemadifar, M. (2021). Investigation of the geotechnical properties and estimation of the relative density from the standard penetration test in sandy
- [25] Zakharov, A., Shenkman, R., Ofrikhter, I., & Ponomaryov, A. (2022). Estimation of soil properties by an artificial neural network. *Magazine of Civil Engineering*, 110(2), 11011.
- [26] Shahin, M. A., Jaksa, M. B., & Maier, H. R. (2001). Artificial neural network applications in geotechnical engineering. *Australian geomechanics*, 36(1), 49-62.
- [27] Ekmen, A. B., & Avci, Y. (2023). Artificial Intelligence-Assisted Optimization of Tunnel Support Systems Based on the Multiple Three-Dimensional Finite Element Analyses Considering the Excavation Stages. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 47(3), 1725-1747.
- [28] Işık, E., Ademović, N., Harirchian, E., Avci, F., Büyüksaraç, A., Hadzima-Nyarko, M., ... & Antep, B. (2023). Determination of Natural Fundamental Period of Minarets by Using Artificial Neural Network and of the Impact of Different Materials on Their Seismic Vulnerability. *Applied Sciences*, 13(2), 809.
- [29] Bülbül, M. A., Harirchian, E., Işık, M. F., Aghakouchaki Hosseini, S. E., & Işık, E. (2022). A hybrid ANN-GA model for an automated rapid vulnerability assessment of existing RC buildings. *Applied Sciences*, 12(10), 5138.
- [30] Matlab, (2017). Matlab, version R2017a, MathWorks.