



## Farklı arazi kullanım türlerinde sınırlandırılmış su aralığının değerlendirilmesi ve makine öğrenme algoritmalarıyla tahmini

✉ Pelin ALABOZ\*<sup>1</sup>, ✉ Orhan DENGİZ<sup>2</sup>, ✉ Serkan İÇ<sup>3</sup>, ✉ Fikret SAYGIN<sup>4</sup>

<sup>1</sup>Isparta Uygulamalı Bilimler Üniversitesi, Toprak Bilimi ve Bitki Besleme Bölümü, Isparta

<sup>2</sup>Ondokuz Mayıs Üniversitesi, Ziraat Fakültesi, Toprak Bilimi ve Bitki Besleme Bölümü, Samsun

<sup>3</sup>Karadeniz Tarımsal Araştırma Enstitüsü, Toprak ve Su Kaynakları Bölümü, Samsun

<sup>4</sup>Sivas Bilim ve Teknoloji Üniversitesi, Bitkisel Üretim ve Teknolojileri Bölümü, Sivas

### Özet

Küresel ısınma ve kuraklık ile suyun önemi artmaktadır. Suyun etkin kullanımı için teknolojik gelişmeler takip edilerek gelecek senaryolar ve tahminler dikkate alınmalıdır. Günümüzde her alanında var olan algoritmalar, teknolojik gelişmeler ile birlikte yaşantımızın merkezi haline gelmiştir. Tarımsal alandaki yeni gelişmelerle birlikte makine öğrenme algoritmalarının kullanımları araştırılmaktadır. Bu çalışmada; farklı arazi kullanım türleri üzerindeki (orman, mera ve tarım arazisi) toprakların, sınırlandırılmış su aralığı (SSA) içeriklerinin belirlenmesi sonucu alandaki sıkışma ve havalanma problemleri değerlendirilmiştir. Ayrıca, SSA'nın farklı makine öğrenme algoritmaları (rastgele orman, yapay sinir ağları ve destek vektör makinaları) ile tahmin edilebilirliği dağılım haritaları ile ortaya konmuştur. Tarım yapılan toprakların SSA içerikleri oldukça geniş olup 0.03-0.21 cm<sup>3</sup>cm<sup>-3</sup> aralıklarında değişim göstermiştir. Çalışma alanında incelenen mera topraklarının %43.63'ünde optimum koşullar, % 36'sında havalanma, %14.54'ünde sıkışma, %5.45'inde hem havalanma hem sıkışma problemleri tespit edilmiştir. Orman örtüsü altında toprakların %37.03'ünde optimum koşullar yani yarayıslı su içeriği SSA ya eşit olarak tespit edilmiştir. İncelenen algoritmalar arasında en başarılı tahmin rastgele orman (RO) algoritmasıyla elde edilmiştir. RO algoritması ile SSA'nın tahmin edilmesinde RMSE değeri 0.039 cm<sup>3</sup> cm<sup>-3</sup>, olarak belirlenmiştir. RO ile SSA'nın tahmininde kum ve kil en iyi tahmin edici parametre olarak tespit edilmiştir. Elde edilen gerçek ve tahmin değerlerinin dağılım haritalarında en düşük RMSE Simple Kriging yöntemi ile SSA için Spherical ve RO için ise Exponential model olarak belirlenmiştir. Çalışma sonucunda RO algoritması ile SSA'nın düşük hata oranı ile tahmin edilebileceği ve dağılım haritalarının oluşturulabileceği ortaya konmuştur. Ayrıca tarım üretimde özellikle fındık arazilerinde dağılım gösteren topraklarda, mera ve orman topraklarına göre daha fazla sıkışma ve havalanma problemlerinin olduğu tespit edilmiştir.

**Anahtar Kelimeler:** Toprak su dinamiği, pedotransfer fonksiyonlar, jeostatistik

### Evaluation of least limiting water range in different land use types and estimation with machine learning algorithms

#### Abstract

The importance of water is increasing with global warming and drought. For the effective use of water, technological developments should be followed and future scenarios and predictions should be taken into account. Algorithms that exist in every field today have become the center of our lives with technological developments. With the new developments in the agricultural field, the uses of machine learning algorithms are being investigated. In this study; As a result of determining the least limiting water range (LLWR) contents of soils on different land-use types (forest, pasture, and agricultural land), compaction and aeration problems in the area were evaluated. In addition, the predictability of SSA with different machine learning algorithms (random forest, artificial neural networks, and support vector machines) is demonstrated with distribution maps. The LLWR contents of the cultivated soils varied in the range of 0.03-0.21 cm<sup>3</sup> cm<sup>-3</sup>. Optimum conditions were determined in 43.63% of the pasture lands examined in the study area, aeration problems in 36%, compaction in 14.54%, and both aeration and compaction problems in 5.45%. Optimum conditions, namely the available water content, were found to be equal to SSA in 37.03 % of the soils under forest cover. Among the analyzed algorithms, the most successful prediction was obtained with the random forest (RF) algorithm. The RMSE value was determined as 0.039 cm<sup>3</sup> cm<sup>-3</sup> in estimating the LLWR with the random forest algorithm. Sand and

\* Sorumlu yazar:

Tel. : 0 (246) 214-6313

E-posta : [pelinalaboz@isparta.edu.tr](mailto:pelinalaboz@isparta.edu.tr)

Makale Türü: **ARAŞTIRMA MAKALESİ**

Geliş Tarihi : 28 Nisan 2022

Kabul Tarihi : 1 Haziran 2022

e-ISSN : 2146-8141

DOI : 10.33409/tbbbd.1110496

clay were determined as the best predictors for the estimation of RF and LLWR. In the distribution maps of the observed and predicted values obtained, the lowest RMSE value was determined by the Spherical model of the Simple Kriging method for SSA while the Exponential model of the Simple Kriging method was found the most suitable model for RF. As a result of the study, it has been revealed that LLWR can be obtained with a low error rate and distribution maps can be created with the random forest algorithm. In addition, it has been determined that there are more compaction and aeration problems in soils of hazelnut cultivated areas for agricultural production when compared with pasture and forest soils.

**Keywords:** Soil water dynamics, pedotransfer functions, geostatistics

© 2022 Türkiye Toprak Bilimi Derneği. Her Hakkı Saklıdır

## Giriş

Günümüzde dünya nüfusunun üçte biri yarı kurak ve kurak iklimlerde su stresi yaşamaktadır. Kuraklık stresi çeken nüfusun 2025 yılında 8 milyar, 2050 yılında ise 9.15 milyar kişiye ulaşacağı bildirilmektedir (Kalkınma Bakanlığı, 2018). Toprak su kaynaklarının kullanımı, sürdürülebilir kalkınmanın temelini oluşturmaktadır. Fakat günümüzde hızlı ve bilinçsiz tüketim yenilenebilir su kaynakları üzerindeki dengenin kurulmasında sıkıntılar ortaya çıkmasına yol açmaktadır. Kişi başına düşen su miktarı 2025 yılında yaklaşık 4.800 m<sup>3</sup>'e düşeceği tahmin edilirken, su tüketimi tarımda % 17, sanayide % 20 ve evsel tüketimde % 70 daha artacağı bildirilmiştir (Kalkınma Bakanlığı, 2018). Gıda ve Tarım Örgütü tarafından su kaynaklarının azalması ile kuraklık ve çölleşmeden en fazla etkilenen 7 ülke arasında Türkiye'nin de yer aldığı bildirilmektedir (FAO, 2015; Kalkınma Bakanlığı, 2018). Tarımsal üretimin artırılmasında özellikle toprak ve su gibi doğal kaynakların bilinçli kullanımı önemlidir. Ayrıca, iklim, tarımsal üretimi belirleyen önemli bir parametredir. İklim değişikliği senaryolarına göre fazla kaynak tüketimine karşın, tarımsal üretimde sınırlı teknolojik gelişmelerin kullanımı ile su kıtlığı, arazi bozulumu gibi risklerin artması beklenmektedir (IPCC, 2019). Toprakların önemi ve üretkenliği ise genel olarak sulama olanaklarına bağlıdır. Farklı arazi kullanım türlerinde, toprak yönetimindeki farklılığa göre topraktaki suyun dinamiği ve kullanımı değişmektedir (Özdemir 2019; Öztürkmen ve ark., 2021).

Kısıtlı olan suyun etkin kullanımında toprakların özellikleri ve toprak yönetimi oldukça önemlidir. Çeşitli toprak fiziksel özelliklerinin kombinasyonu olarak sınırlandırılmış su aralığı (SSA) özelliği toprak strüktürel kalite göstergelerinden biri olarak değerlendirilmektedir. İlk olarak Letey (1958) tarafından sınırlayıcı olmayan su aralığı olarak tanımlanan özellikte; bitki tarafından alınabilen su içeriği ile havalanma ve penetrasyon direncinden etkilenen su aralıkları tanımlanmıştır. Da Silva ve ark. (1994), toprakların hacimsel ağırlıklarını da modelde değerlendirerek SSA yaklaşımını geliştirmiştir. Sınırlandırılmış su aralığı; su dinamiği, havalandırma ve kök gelişimini etkileyen penetrasyon direncindeki nem içeriğiyle ilişkili olarak bitki gelişiminde sınırlamaların olduğu minimum toprak nem içeriğidir. SSA'nın kök büyümesi üzerindeki etkisinin üst sınırı; hava dolu gözenek hacmi (%10) veya tarla kapasitesi, alt sınırı ise solma noktası veya kök gelişiminin sınırlandığı 2 MPa toprak penetrasyon direncinin olduğu toprak su içeriği olarak belirlenmiştir (Da Silva ve ark., 1994). Ayrıca farklı arazi türlerine bağlı toprak özellikleri üzerindeki değişkenlikler oldukça fazladır (Eraslan ve ark., 2016; İmamoğlu ve ark., 2018; Gündüz ve Barik, 2019).

SSA belirlemesi zahmetli ve zaman alıcı özelliklerin kombinasyonu olan bir kalite indikatörüdür. SSA özelliğinin pedotransfer fonksiyonlar tarafından tahmin edilebilirliği üzerine çalışmalar ise geçmişten günümüze devam etmektedir (Da Silva ve ark., 1997; Leão ve ark., 2005; Tavanti ve ark., 2019) Alaboz ve ark. (2021), SSA'yı derin öğrenme algoritması ile yapay sinir ağları (YSA)'na göre daha yüksek tahmin doğruluğu ile belirlemiştir. Makine öğrenme algoritmalarından rastgele orman algoritması genellikle diğer yaklaşımlara göre daha yüksek doğruluklar sergilemesi yönünden tercih edilmektedir (Akar ve Güngör, 2013). Watts ve Lawrence (2008) rastgele orman algoritmasının, tarımsal bölgelerin belirlenmesinde düşük hata oranı sağladığını belirtmiştir.

Arazi üzerinde birçok faktöre bağlı olarak değişkenlik gösteren toprak özelliklerinin noktasal örneklemeleri alanı temsili oldukça düşüktür. Ayrıca dinamik özelliklerin ortaya konmasında noktasal değerler yerine mekânsal değerlendirmelerin ortaya konması sürdürülebilir bir yönetim için önemli katkı sunmaktadır (Arslan ve ark., 2018; Saygın ve ark., 2019). Gelişen bilgisayar, algılayıcı sensör teknolojileri ve programlar kolaylıkla hızlı bir şekilde toprak özelliklerinin değişkenliğini haritalar ile ortaya koyabilmektedir. Alaboz ve ark. (2020) toprakların tarla kapasitesi ve solma noktası dağılımlarında en yüksek doğruluk gösteren enterpolasyon yöntemlerini sırasıyla Ordinary Kriging'in Gaussan (RMSE: %4.289) ve Cokkriging (RMSE: %3.187) olarak belirlemişlerdir. SSA ile ilgili çalışmalarda da çoğunlukla noktasal bazlı ya da laboratuvar

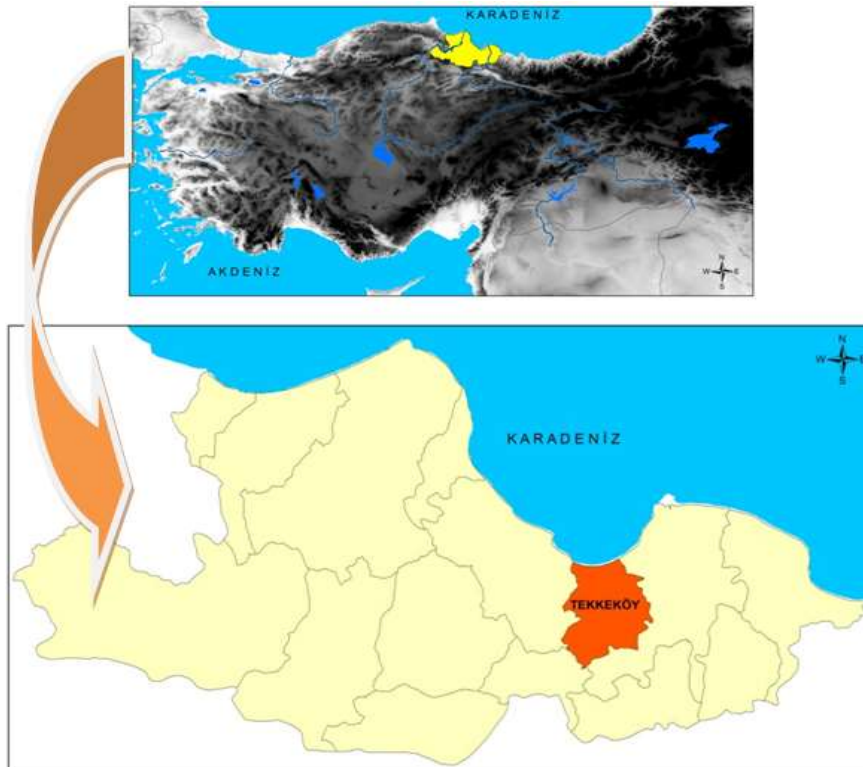
denemeleri şeklinde olup (Cecagno ve ark., 2016; Tavanti ve ark., 2019) en önemli etkinini yaşandığı arazi koşullarında bu özelliğin belirlenmesi tarımsal sürdürülebilirlik açısından oldukça önemlidir.

Bu çalışmada, i) Orta Karadeniz bölgesinde farklı arazi kullanım türleri üzerindeki (tarım, orman, mera) toprakların SSA içeriklerinin belirlenmesi ve alanda sıkışma ve havalanma problemlerinin dağılım haritalarıyla ortaya konması, ii) farklı makine öğrenme algoritmalarıyla (rastgele orman, yapay sinir ağları, destek vektör makinaları) SSA'nın tahminin edilebilirliğinin değerlendirilmesi, iii) elde edilen tahmin değerlerin dağılım haritalarının kullanılabilirliğinin belirlenmesi amaçlanmıştır.

## Materyal ve Yöntem

### Çalışma alanı genel özellikleri


Bu çalışma Samsun Tekkeköy ilçesinde yer alan yaklaşık 13 mikro havzada yürütülmüştür. Samsun ili Tekkeköy ilçesi 41°12'.45.0072" Kuzey, 36°27'.24.9984" doğu koordinatları arasında bulunmaktadır. Samsun - Ordu karayolunun 13 km'sinde güneye doğru 1 km içeride yer almakta olup, İlçe alanı 225.63 km<sup>2</sup> dir (Şekil 1). İlçe topraklarının üçte biri Çarşamba ovasının içerisinde yer alır.



Şekil 1. Çalışma lokasyon haritası

İlçede Orta Karadeniz iklimi hâkimdir. Yazlar sıcak ve nemli, kışları ılık, ilkbahar ve sonbahar yağışlı geçer. En sıcak ay ağustos, ortalama 25°C en soğuk ay ocak, ortalama sıcaklık ise 7°C derecedir (MGM, 2022). Uzun yıllar meteorolojik ölçümler incelendiğinde, yıllık ortalama sıcaklığı 14.6 °C olduğu görülmektedir, toprak sıcaklığı 5 °C'nin altına düşmemektedir. Newhall modeline göre toprak sıcaklık rejimi Mesic, toprak sıcaklık rejimi ise Ustic olarak belirlenmiştir. Uzun yıllar ölçümlerde yıllık toplam yağış 710 mm olup, toplam evapotranspirasyon miktarı ise 774.25 mm ve toprakta yıllık su açığı 64.25 mm olarak belirlenmiştir.

Tekkeköy deniz seviyesinden 0 ile 950 m arasında yer almaktadır. Alanın kuzey doğu yönü düz düze yakın eğimli alanlar yer alırken, güney batı yönünde eğim artarak dik eğimli alanlar bulunmaktadır. Toplam alanın %32.5'i eğimin %12 ve altını oluştururken, %42.7'si çok dik ve sarp eğimli alanlardır. Ayrıca alanın %51.9 ile en fazla yöney kuzey doğrultudaki kuzey, kuzey doğu ve kuzey batı yöneyleri oluşturmaktadır (Şekil 2). Tekkeköy jeolojik materyal yönünden alanın büyük bir kısmı (%65.3) kumtaşı, kumtaşı-çamur taşı- kireç taşı üzerinde yer almaktadır. Alanın etek ve düz ve düze kalın olan kuzey kesimleri ise Alüvyon materyallerle kaplı bulunmaktadır. Ayrıca, alanın güney doğu kesimler de ise (yaklaşık alanın %8.2'si) bazalt, bazalt-andezit-proklatik kayalar yer almaktadır (Şekil 2).




Şekil 2. Çalışma alanı yükseklik, eğim, baki ve jeoloji haritası

## Yöntem

Yapılan büro çalışmaları sonucunda arazi kullanım ve arazi örtüsü, topografik özelliklerdeki değişim gibi unsurlar dikkate alınarak alanı temsil edebilecek 328 adet toprak örnekleme noktası belirlenmiştir (Şekil 3). Toprak örnekleri arazi örtüsü ve arazi kullanım dağılımına göre 165 tanesi tarım (fındık ve işlemeli tarım) alanlarından, 108 tanesi orman alanlarından, 55 tanesi mera arazilerinden alınmıştır.

Araziden alınan bozulmuş ve bozulmamış toprak özelliklerinde temel toprak özellikleri belirlenmiştir. Toprak örnekleme alınan noktalarda nem tayini için toprak alındıktan sonra penetrasyon dirençleri de penetrasyon aleti ile ölçülmüş ve her bir nokta için kaydedilmiştir. Tekstürel fraksiyonlar hidrometre yöntemiyle (Burt, 2014), hacim ağırlığı bozulmamış örnek alma silindirleriyle (Burt, 2014), organik madde Walkley-Black yöntemine göre (Kacar, 2009) doygunluk, tarla kapasitesi ve solma noktası nem sabiteleri seramik basınç tablalarında tayin edilmiştir (Burt, 2014). Hava dolu gözenekliliğinin %10'a eşit olduğu nem içeriği ( $\theta_{HG}$ ) saturasyondaki nem içeriğinden % 10 çıkartılarak hesaplanmıştır (Alaboz ve ark., 2021a).



Şekil 3. Çalışma alanı arazi kullanım-arazi örtüsü (AKAÖ) ve toprak örnekleme deseni haritaları

Sınırlandırılmış su aralığı, 4 farklı eşitlikte belirtilen olasılıklara göre belirlenmiştir (Wu ve ark., 2003). Bu eşitlikler 1, 2, 3, 4 'de (Alaboz ve ark., 2021a) ve Şekil 4'de belirtilmiştir.

$$1- (\theta_{HG} \geq \theta_{TK}) \text{ ve } (\theta_{PD} \leq \theta_{SN}) \text{ ise } SSA = \theta_{TK} - \theta_{SN} \quad (1)$$

$$2- (\theta_{HG} \geq \theta_{TK}) \text{ ve } (\theta_{PD} \geq \theta_{SN}) \text{ ise } SSA = \theta_{TK} - \theta_{PD} \quad (2)$$

$$3- (\theta_{HG} \leq \theta_{TK}) \text{ ve } (\theta_{PD} \leq \theta_{SN}) \text{ ise } SSA = \theta_{HG} - \theta_{SN} \quad (3)$$

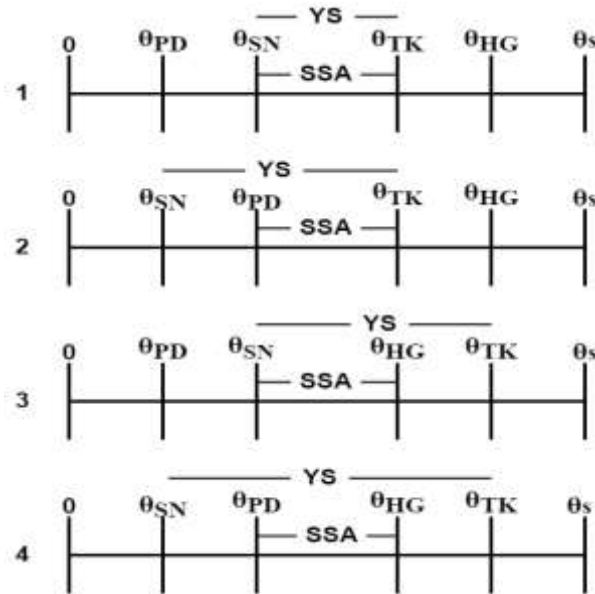
$$4- (\theta_{HG} \leq \theta_{TK}) \text{ ve } (\theta_{PD} \geq \theta_{SN}) \text{ ise } SSA = \theta_{HG} - \theta_{PD} \quad (4)$$

$\theta_{HG}$ : Hava dolu gözenek hacminin %10 olduğu nem içeriği ( $\text{cm}^3 \text{ cm}^{-3}$ ),  $\theta_{TK}$ : Tarla kapasitesi ( $\text{cm}^3 \text{ cm}^{-3}$ ),  $\theta_{SN}$ : Solma noktası ( $\text{cm}^3 \text{ cm}^{-3}$ )  $\theta_{PD}$ : Toprak nem içeriği- 2MPa penetrasyon direncinde ( $\text{cm}^3 \text{ cm}^{-3}$ )

Toprakların  $\theta_{PD}$  içerikleri Eşitlik 5'de belirtilen formülle belirlenmiştir (Busscher, 1990).

$$PD = a\theta^c D_b^d \quad (5)$$

Denklemden, PD: Penetrasyon direnci (MPa),  $\theta$ : penetrasyon direnci ölçüm anındaki nem içeriği,  $D_b$ : Hacim ağırlığı ( $\text{g cm}^{-3}$ ), a, c ve d denklem katsayıları. Arazi kullanımına bağlı olarak belirlenen nem, penetrasyon direnci ve hacim ağırlığı değerlerine göre ayrı ayrı katsayılar excel programının "çözücü" özelliğiyle hesaplanmış ve örnekleme noktaları için 2MPa'daki nem içerikleri hesaplanmıştır.



Şekil 4. Sınırlandırılmış su aralıkları (SSA) ve yarayışlı su içeriği (YS)

### Tahmin modelleri

Toprakların kum, silt, kil, organik madde ve hacim ağırlığı özellikleriyle SSA'nın tahminleri yapay sinir ağları, rastgele orman ve destek vektör makinaları ile "R Core ve Matlab" programları aracılığıyla gerçekleştirilmiştir.

## Destek vektör makinaları algoritması

Destek vektör makineleri (SVM), hem sınıflandırma, hem de regresyon analizinde kullanılan denetimli makine öğrenme algoritmasıdır. Algoritmanın çalışması esnasında verilerin türüne bağlı olarak Kernel fonksiyonları kullanılmakta bu sayede hem doğrusal, hem de doğrusal olmayan sınıflandırma işlemleri tahmin edilmektedir. SVM modellemenin amacı; değişkenleri düzlemin bir tarafında ve kategorik durumları düzlemin diğer tarafında olacak şekilde, vektör kümelerini ayırmak ve maksimum marjini veren hiper düzlemi bulmaktır (Cortes ve Vapnik, 1995). SVM, N boyutlu bir veri setinde en iyi şekilde sınıflara ayıran hyperplane bulan bir makine algoritmasıdır. Referans alınan noktalara göre hyperplane çizilir ve referans alınan noktalar support vektörlerdir. SVM’de her zaman doğrusal bir düzlem olmaz doğrusal düzlemlerde hyperplane bulmak çok daha kolaydır ve bu hatta göre sınıflamalar yapılabilmektedir (Smola ve Schölkopf, 2004). Doğrusal olmadığına veriler bir boyut atlattırılarak sınıfları ayıracak hyperplane belirlenir. Doğrusal olmayan bir problem kernel fonksiyonu ile doğrusal bir probleme dönüştürebilmektedir. SVM vektörünün temeli Eşitlik (6)’de belirtilmiştir.

$$f(x) = \omega \cdot \varphi(x) + b \quad (6)$$

Burada  $\varphi(x)$  doğrusal olmayan dönüştürülmüş eğitim verileridir,  $\omega$ : ağırlık vektörleri,  $b$ : bias (eğilim değeri) hiper düzlemin orjinalden olan uzaklığını temsil eder.  $\omega$  ve  $b$  katsayıları, düzenli risk fonksiyonunun minimize edilmesiyle tahmin edilir: Bu çalışmada Support vektör regresyon, kernel fonksiyonu olarak radyal tabanlı fonksiyon kullanılmıştır (Ballabio, 2009). Radyal tabanlı sınıflandırma işlemi doğrusal olmadığından, örneği daha yüksek boyutlu bir uzaya taşıyarak gerçekleştirir. Veri seti %70 training, %30 testing şeklinde değerlendirilmiştir. Tahminde R programında “e1071” ve “Caret” paketleri kullanılmıştır.

## Yapay sinir ağları

Bu çalışmada çok katmanlı ileri beslemeli geri yayımlı ağlar ile çalışılmıştır. Yapay sinir ağlarında (YSA) çok katmanlı algılayıcılar bir giriş bir veya daha fazla ara, bir de çıkış katmanlarından oluşur (Çakır, 2019). İlk katman model giriş katmanı, ikinci katman ara gizli katmanlar üçüncü katman ise model çıkış katmanıdır. Yapay sinir ağları ile oluşturulacak tahminde, ileri beslemeli geri yayılım tekniği kullanılarak farklı öğrenme algoritmalarından Levenberg-Marquardt algoritması (LM) 5:10:1 mimarisi kullanılarak değerlendirilmiştir. YSA tahminlerinin elde edilmesi için MATLAB programında “nntool” paketi kullanılmıştır. Yapay sinir ağlarında veri setinin %70’i model oluşturma, %15’i validasyon %15’i ise test aşamasında kullanılmıştır.

## Rastgele orman algoritması

Rastgele orman algoritması, ağaç tipi öğrenme algoritmalarından biridir (Breiman, 2001). RO sınıflandırıcısı ile bir ağaç üretmek için en iyi bölünmeyi belirlemek için her bir düğümde kullanılan değişkenlerin sayısı (mtry) ve ağaçların sayısı (ntree)’dir (Pal, 2005). Tuning işlemi gerçekleştirilerek en uygun mtry belirlenir. RO, budama olmadan en büyük boyutta ağaç geliştirmek için CART algoritmasını kullanmaktadır (Breiman, 2001). CART algoritmasında, bir düğümde belirli bir ölçüt uygulanarak bölünme işlemi gerçekleştirilir. Bölünme işlemlerinde homojen sınıf dağılımına sahip düğümler tercih edilir. RO yöntemi, Gini indeksini kullanmaktadır. Gini indeksinin sıfır olmasıyla ağaç dallanma işlemi sona erdirilir (Watts ve ark., 2011). İstenilen ağaç kadar her düğümde en iyi dallar belirlenerek ağaçlar üretilir (Liaw ve Wiener, 2002). En iyi performansı gösteren ağaç bir sınıfa aktarılır (Liaw ve Wiener, 2002). Rastgele orman algoritması R paket programında çalıştırılmıştır. R Core programında “randomforest”, “caret” ve “mice” paketleri kullanılmıştır. Tuning işlemi yapılmış ve mtry: 2, ntree=60 olarak elde edilmiştir. Veri setinin %70’i training, %30’u test seti olarak değerlendirilmiştir. Modellerde en başarılı tahmin seçilerek belirlenen ve tahmin edilen değerlerin konumsal dağılım haritaları üretilmiştir. Konumsal dağılım haritalarının üretilmesi, CBS yazılımı olan ArcGIS programı içerisinde yer alan farklı enterpolasyon modelleri yardımıyla gerçekleştirilmiştir. Haritalama öncesi verilerin normal dağılım göstermeyenleri özelliklere uygun dönüşümler yapılmıştır. Haritalama kısmında Ters Mesafe Ağırlıklandırma (IDW), Radyal Tabanlı Fonksiyon (RBF), Kriging yöntemleri (Basit Kriging, Ordinary Kriging ve Universal Kriging) kullanılmıştır. Genel olarak, modellerin değerlendirilmesinde hata kareler ortalaması karakökü (RMSE), ortalama mutlak hata (MAE) ve ortalama mutlak hata yüzdesi (MAPE) parametreleri en uygun enterpolasyon yöntemi ve tahmin

modelinin değerlendirilmesinde kullanılmıştır. Bu çalışmada en uygun dağılım modelin belirlenmesinde RMSE kullanılmıştır (Eşitlik 7).

$$RMSE = \sqrt{\frac{\sum(Z_i - Z)^2}{n}} \quad (7)$$

Burada,  $Z_i$ : tahmin değeri,  $Z$ : gerçek değer,  $n$ : gözlem sayısı

## Bulgular ve Tartışma

### Toprak özellikleri ve SSA içerikleri

Farklı arazi kullanımlarına bağlı olarak elde edilen toprak özelliklerinin bazı tanımlayıcı istatistikleri Çizelge 1' de belirtilmiştir.

Çizelge 1. Toprak özelliklerinin tanımlayıcı istatistikleri

	Ortalama	Standart Sapma	Varyasyon Katsayısı	Minimum	Maksimum	Çarpıklık	Basıklık
<b>TARIM</b>							
Kum %	31.80	16.06	50.49	3.18	89.32	0.57	0.03
Silt %	26.570	5.36	20.17	1.00	41.191	-0.82	3.50
Kil %	41.63	15.14	36.36	9.74	72.67	0.03	-0.83
OM %	2.72	1.15	42.39	0.60	6.38	0.92	1.13
HA gr cm <sup>-3</sup>	1.38	0.10	7.41	1.18	1.750	-0.25	-0.47
$\theta_{HG}$ cm <sup>3</sup> cm <sup>-3</sup>	0.38	0.038	10.25	0.28	0.45	0.11	-0.60
$\theta_{TK}$ cm <sup>3</sup> cm <sup>-3</sup>	0.36	0.073	20.17	0.12	0.43	-0.78	-0.23
$\theta_{SN}$ cm <sup>3</sup> cm <sup>-3</sup>	0.25	0.073	29.83	0.07	0.25	-0.32	-1.02
$\theta_{PD}$ cm <sup>3</sup> cm <sup>-3</sup>	0.25	0.23	92.79	0.07	0.35	2.59	7.15
SSA cm <sup>3</sup> cm <sup>-3</sup>	0.098	0.027	27.61	0.03	0.21	-0.19	0.89
<b>MERA</b>							
Kum %	39.88	15.96	40.01	4.95	67.82	-0.13	-1.01
Silt %	27.25	5.361	19.67	15.85	40.33	0.53	0.08
Kil %	32.86	13.90	42.29	13.68	59.52	0.34	-1.16
OM %	3.18	1.27	40.06	0.68	6.00	0.23	-0.25
HA gr cm <sup>-3</sup>	1.44	0.06	4.65	1.27	1.75	-0.61	-0.21
$\theta_{HG}$ cm <sup>3</sup> cm <sup>-3</sup>	0.356	0.026	7.26	0.32	0.42	0.59	-0.36
$\theta_{TK}$ cm <sup>3</sup> cm <sup>-3</sup>	0.325	0.07	22.28	0.19	0.44	-0.05	-1.31
$\theta_{SN}$ cm <sup>3</sup> cm <sup>-3</sup>	0.205	0.07	34.20	0.10	0.34	0.33	-1.09
$\theta_{PD}$ cm <sup>3</sup> cm <sup>-3</sup>	0.035	0.04	116.79	0.01	0.22	2.95	10.12
SSA cm <sup>3</sup> cm <sup>-3</sup>	0.11	0.02	19.61	0.05	0.16	-0.91	0.99
<b>ORMAN</b>							
Kum %	38.08	13.78	36.19	10.16	72.04	0.15	-0.57
Silt %	29.02	5.719	19.71	15.41	42.28	0.09	-0.21
Kil %	32.90	12.30	37.39	8.58	65.32	0.45	-0.27
OM %	4.16	1.48	35.54	1.32	6.57	-0.14	-1.20
HA gr cm <sup>-3</sup>	1.442	0.06	3.89	1.29	1.73	-0.99	0.23
$\theta_{HG}$ cm <sup>3</sup> cm <sup>-3</sup>	0.356	0.02	5.99	0.32	0.41	1.01	0.25
$\theta_{TK}$ cm <sup>3</sup> cm <sup>-3</sup>	0.33	0.06	19.38	0.17	0.44	-0.28	-0.51
$\theta_{SN}$ cm <sup>3</sup> cm <sup>-3</sup>	0.203	0.06	30.24	0.07	0.34	0.27	-0.69
$\theta_{PD}$ cm <sup>3</sup> cm <sup>-3</sup>	0.103	0.06	58.62	0.04	0.35	2.02	3.96
SSA cm <sup>3</sup> cm <sup>-3</sup>	0.11	0.02	19.63	0.04	0.17	-0.76	0.57

OM: Organik madde,  $\theta_{HG}$ : Hava dolu gözenek hacminin %10 olduğu durumdaki nem içeriği  $\theta_{TK}$ : Tarla kapasitesinde ki nem içeriği  $\theta_{SN}$ : Solma noktasındaki nem içeriği,  $\theta_{PD}$ : 2MPa penetrasyon direncindeki nem içeriği, SSA: Sınırlandırılmış su aralığı

Tarım topraklarının kum, silt ve kil içerikleri sırasıyla %3.18-89.32, %1.00-41.91, %9.74-72.67 arasında değişkenlik gösterirken bu özellikler mera ve orman için %4.95-67.82, %15.85-40.33, %13.68-59.52, %10.16-72.04, %15.41-42.28 ve %8.58-65.32 aralıklarında tespit edilmiştir. Toprakların tekstürleri genellikle "orta ve ağır" bünye grubunda belirlenmiş ve kum, silt ve kil içerikleri yönünden her üç arazi grubunda da veri setleri normale yakın bir dağılım sergilemiştir. Tarım topraklarının organik madde içerikleri ortalama %2.72 iken mera ve orman örtüsü altında bu değer %3.18 ve %4.16 olarak belirlenmiştir.

Tarım yapılan topraklarda kültürel işlemler, toprak işleme, anız yakma gibi faaliyetler topraklardaki organik madde seviyesini düşürmektedir (Erol, 2011).

Orman örtüsü altında devamlı birikimlerin olması toprakların organik madde içeriğinin yüksek olmasına neden olmuştur. Ayrıca orman örtüsü altında elde edilen organik madde içeriklerinin veri setleri incelendiğinde diğer arazi kullanımlarından farklı olarak negatif çarpıklık katsayısı dikkat çekmektedir. Negatif çarpıklık katsayısı veri setinin ortalamadan daha yüksek değerlerinin varlığı sonucu oluşmaktadır. Tekstürel fraksiyonların varyasyon katsayıları incelendiğinde benzerlikler tespit edilmiştir. Varyasyon katsayısı dağılımdaki değerlerin ortalamaya göre % kaçlık bir değişim gösterdiğinin belirlendiği bir katsayıdır. Wilding (1985)'e göre düşük (<%15), orta (<%35) ve yüksek (>%35) olarak sınıflandırılmış olup tekstürel fraksiyonlardaki veri setleri ortalamaya göre "orta ve yüksek" organik madde ise "yüksek" seviyede varyasyon göstermiştir. Gülser ve ark. (2021) aynı topografyada yer alan orman ve meraya dönüştürülen arazilerin özelliklerini karşılaştırdıkları çalışmada, orman topraklarına ait özelliklerin daha yüksek varyasyon katsayısına sahip olduğunu bildirmişlerdir. Toprakların hacim ağırlığı özellikleri tekstürel fraksiyonlara ve toprak sıkışmasına bağlı olarak değişkenlik gösteren bir parametre olup veri setlerinde normale yakın bir dağılım sergilemiş olsa da, ortalamadan yüksek değerlerin olması negatif çarpıklık katsayısı sonucunu ortaya çıkarmıştır. Tarım topraklarının hava dolu gözenek hacminin %10 olduğu andaki nem içeriği değerleri ( $\theta_{HG}$ ) 0.28-0.45  $cm^3 cm^{-3}$  olarak belirlenirken, tarla kapasitesi ( $\theta_{TK}$ ) nem içerikleri 0.12-0.43  $cm^3 cm^{-3}$  olarak belirlenmiştir. Varyasyonları ise ortalamaya göre %10.25 ve 20.17 seviyelerinde tespit edilmiştir. Toprakların solma noktası ( $\theta_{SN}$ ) ve 2 MPa penetrasyon direncinde belirlenen nem içerikleri ( $\theta_{PD}$ ) ise sırasıyla 0.07-0.25  $cm^3 cm^{-3}$ , 0.07-0.35  $cm^3 cm^{-3}$  olarak elde edilmiştir.  $\theta_{PD}$  ile elde edilen veri seti normalden uzak bir dağılım sergilemiştir. Arazide ölçülen penetrasyon dirençlerindeki değişkenlik söz konusu bu veri setinde elde edilen nem içeriklerinin de varyasyonunun yüksek olmasına yol açmıştır. Toprakların SSA içerikleri ise 0.03-0.19  $cm^3 cm^{-3}$  olarak tespit edilmiştir. Tarım arazileri üzerindeki toprakların %14.55'inde SSA yarayışlı su içeriğine karşılık gelirken, %28.48'inde havalanma problemi, %27.27'sinde hem havalanma hem sıkışma, %29.70'inde ise sıkışma problemi tespit edilmiştir. Kay ve Anger (2002)' e göre SSA içerikleri <0.1  $cm^3 cm^{-3}$  ise "çok az", 0.1-0.15  $cm^3 cm^{-3}$  ise "az", 0.15-0.2  $cm^3 cm^{-3}$  "ise iyi", >0.2  $cm^3 cm^{-3}$  olduğu durumlarda ise "çok iyi" olarak sınıflandırılmıştır. Topraklar bu sınıflamaya göre "çok az, iyi" olarak sınıflandırılmıştır.

Mera arazi kullanımı altındaki toprakların  $\theta_{HG}$ ,  $\theta_{TK}$ ,  $\theta_{SN}$ ,  $\theta_{PD}$  içerikleri sırasıyla 0.32-0.42  $cm^3 cm^{-3}$ , 0.19-0.44  $cm^3 cm^{-3}$ , 0.10-0.34  $cm^3 cm^{-3}$ , 0.01-0.22  $cm^3 cm^{-3}$  aralıklarında belirlenmiştir. Toprakların SSA seviyeleri 0.05-0.16  $cm^3 cm^{-3}$  olarak tespit edilmiştir. Mera topraklarının % 43.63'ünde yarayışlı su SSA aralığına denk gelirken yani optimum koşullar ortaya çıkarken % 36'sinde havalanma, % 14.54'ünde sıkışma, % 5.45'inde hem havalanma hem sıkışma problemleri tespit edilmiştir.  $\theta_{PD}$ ' dışındaki diğer nem sabitelerinde varyasyon katsayısı düşük ve normale yakın bir dağılım gösteren veri setleri mevcuttur. Kay ve Anger (2002)' e göre SSA aralıkları "çok az ve iyi" sınıflarında belirlenmiştir. Orman örtüsü üzerinde toprakların  $\theta_{HG}$ ,  $\theta_{TK}$ ,  $\theta_{SN}$ ,  $\theta_{PD}$  içerikleri sırasıyla 0.32-0.41  $cm^3 cm^{-3}$ , 0.17-0.44  $cm^3 cm^{-3}$ , 0.07-0.34  $cm^3 cm^{-3}$ , 0.04-0.35  $cm^3 cm^{-3}$  olarak tespit edilmiştir. Kay ve Anger (2002)' e göre toprakların SSA içerikleri "çok az, iyi" sınıflarında elde edilmiştir. Toprakların SSA içerikleri belirlenirken yaklaşık % 37.04'sinde optimum koşullar yani yarayışlı su içeriği SSA ya eşit olarak tespit edilmiştir. Toprakların % 4.62'sinde havalanma ve sıkışma problemi, % 3.7'sinde sıkışma ve % 54. 62'sinde ise havalanma problemleri ortaya çıkmıştır.

Tarım topraklarının SSA içerikleri mera ve orman arazi kullanımlarına göre daha yüksek seviyelerde belirlense de ideal koşul olan SSA'nın yarayışlı su içeriğine eşit olduğu koşullar daha düşük oranlardadır. Bu durum özellikle fındık arazilerinde alınan toprak örneklerinde daha yaygın olduğu belirlenmiştir. Tarım arazilerinde diğer arazi gruplarına göre havalanma ve sıkışma problemleri daha yüksek seviyelerde tespit edilmiştir. Bunun sebebi işlemeli tarım arazilerinde, bilinçsiz toprak işleme toprakların tavında işlenmemesi gereğinden fazla tarla trafiği ve organik madde ilavesinin az olması sonucu ortaya çıkabileceği düşünülmektedir. Ayrıca tarım arazilerinin büyük bir kısmını ise fındık alanları oluşturmaktadır ki, bu alanlarda toprak işleme hemen hemen hiç yapılmaması nedeniyle alan içerisinde gübreleme, budama, ilaçlama hasat gibi kültürel işlemler için makinalı uygulamalarda zaman içerisinde sıkışma çok daha fazla meydana gelebilmektedir. Nem sabiteleri tekstür, organik madde ve strüktüre bağlı olarak değişim göstermektedir. Ayrıca tarla kapasitesindeki nem içeriği sıkışmaya bağlı gözenek hacmindeki değişimden kaynaklı önemli seviyede etkilenmektedir (Karahana ve ark., 2014). Sıkışmayla birlikte doğal olarak artan penetrasyon direnci ve hacim ağırlığıyla birlikte SSA azalmaktadır (Haghighi Fashi ve ark. 2017). SSA'nın geniş değişim aralığı bitkilerin sudan daha etkili yararlanabildiğini ve ürün verimi üzerinde olumlu etkisi



olduğu bildirilmiştir (Chan ve ark., 2006). Negiş ve ark (2020), organik materyal uygulamasıyla toprak sıkışmasının azaldığı SSA'nın arttığını belirtmiştir. Alaboz ve ark (2021) SSA'nın kil, organik madde ve  $\text{CaCO}_3$  ile pozitif, hacim ağırlığı ile negatif yönlü korelasyon sergilediğini değerlendirmiştir.

### Tahmin modellerinin değerlendirilmesi

Toprakların kum, silt, kil, organik madde ve hacim ağırlığı içerikleri kullanarak SSA'nın tahmininde 3 farklı algoritmanın değerlendirilmesi sonucu elde edilen hata değerleri Çizelge 2'de belirtilmiştir. 3 algoritma incelendiğinde SSA'nın tahmininde en düşük hata oranları RO en yüksek hata ise YSA algoritmaları ile elde edilmiştir. Lewis (1982), MAPE değerine göre modelleri çok iyi (<%10), iyi (%10-20), kabul edilebilir (%20-50), yanlış ve hatalı (>%50) olarak sınıflandırmıştır.

Çizelge 2. Farklı algoritmalar ile SSA tahmini


Algoritma		RMSE, $\text{cm}^3 \text{cm}^{-3}$	MAE, $\text{cm}^3 \text{cm}^{-3}$	MAPE, %
RO	Eğitim	0.023	0.018	17.92
	Test	0.039	0.023	18.35
DVM	Eğitim	0.044	0.047	22.35
	Test	0.049	0.043	23.44
YSA	Eğitim	0.045	0.041	25.35
	Test	0.058	0.050	25.25

RO: rastgele orman algoritması, DVM: Destek vektör algoritması, YSA: yapay sinir ağırları

Rastgele orman algoritmasında elde edilen RMSE değerleri eğitim ve test verisinde sırasıyla  $0.023 \text{ cm}^3 \text{ cm}^{-3}$  ve  $0.039 \text{ cm}^3 \text{ cm}^{-3}$  iken MAE değerleri  $0.018 \text{ cm}^3 \text{ cm}^{-3}$ ,  $0.023 \text{ cm}^3 \text{ cm}^{-3}$  olarak tespit edilmiştir. MAPE değeri ise %17.92 ve %18.35 olarak bulunmuş MAPE değerine göre model gücü "iyi" olarak sınıflandırılmaktadır (Lewis 1982). Rastgele orman algoritmasına göre tahminde kullanılan özelliklerin önemi Şekil 3'de belirtilmiştir. Rastgele orman algoritmasıyla tahminde kullanılan değişkenlerin önemi ve modelden çıkarıldığında oluşabilecek hatayı ortaya koymaktadır (Prasad ve ark., 2006).

Destek vektör algoritması ile tahminde RMSE değerleri  $0.039 \text{ cm}^3 \text{ cm}^{-3}$  ve  $0.044 \text{ cm}^3 \text{ cm}^{-3}$ , MAE değerleri  $0.023 \text{ cm}^3 \text{ cm}^{-3}$ ,  $0.047 \text{ cm}^3 \text{ cm}^{-3}$  MAPE ise % 22.35 ve 23.44 olarak belirlenmiş ve modelin tahmin gücü Lewis (1982)' e göre "kabul edilebilir" olarak sınıflandırılmıştır. Yapay sinir ağlarında ise elde edilen RMSE, MAE ve MAPE değerleri eğitim ve test setlerinde sırasıyla 0.045-0.058  $\text{cm}^3 \text{ cm}^{-3}$ , 0.041-0.05  $\text{cm}^3 \text{ cm}^{-3}$ , % 25.35-25.25 olarak tespit edilmiştir. Yapay sinir ağları ile tahminlerde genellikle doğrusal olmayan ilişkiler için uygun olduğu Marashi ve ark. (2017), tarafından bildirirken Alaboz ve ark (2021) yapay sinir ağlarına göre derin öğrenme algoritmasının SSA'nın tahmininde daha başarılı olduğunu belirtmiş. Yine Yamaç ve ark. (2020) tarla kapasitesi tahmininde nisbi RMSE değerini %9.39 ile en düşük hata oranı ile derin öğrenme algoritması ile tahmin etmiştir. Destek vektör makineleri algoritmaları ile de toprak özelliklerinde başarılı tahminler elde edildiği yapılan çalışmalar ile ortaya konmuştur (Silva ve ark., 2020; Dong ve ark., 2021)

Rastgele orman algoritması, orijinal ölçülerin tahmin doğruluğunu tanımlayan iki nitel ölçü Increased Mean Square Error (IncMSE) ve Increased Impurity Index (IncNodePurity) ile özelliklerin önemini ortaya koymaktadır (Şekil 5).



Şekil 5. Rastgele orman algoritmasında özelliklerin önemi


IncMSE, belirli bir orijinal değişkenin değerine rastgele izin verildiğinde tahmin doğruluğu üzerindeki etkiyi ölçer (Breiman, 2001). o değişkenin dışarıda bırakılması ise model doğruluğunun ne kadar azaldığını gösterir. IncNode-Purity her bir bölünmede kullanılan özelliğin kullanılmasıyla homojenliği, purity'i ortaya koyan özelliktir. Daha yüksek bir IncNodePurity değeri, daha yüksek bir değişken önemini temsil eder, yani düğümler çok daha 'saf'tır. IncMSE değerlerine göre RO ile SSA'nın tahmininde OM'nin modelden uzaklaştırılması etki göstermemekte olup kil özelliğinin modelden uzaklaştırılması ile yaklaşık % 15 MSE'nin artacağı belirlenmiştir. Hem IncMSE, hemde IncNodePurity değerlerine göre modelden uzaklaştırılınca hata oranını artacağı ve model için en önemli özellik toprakların kil ve kum içeriği olduğu belirlenmiştir.

Veri setlerinin eğitim ve test aşamasında elde edilen hata oranları bir birine yakın olarak bulunmuştur. Veri setinde eğitim ve test aşamasında yakın tahmin gücünün elde edilmesi modeli oluşturan veri setinin algoritmalar tarafından başarılı bir şekilde eğitildiğini göstermektedir. SSA ve RO için dağılım haritalarının oluşturulması amacıyla uygulanan enterpolasyon modellerine ait RMSE değerleri Çizelge 3' de verilmiştir. Çizelge 3' e göre SSA için en uygun model Simple Kriginge ait Spherical model en uygun olarak belirlenirken, RO için ise Simple Kriginge ait Exponential model ise en uygun dağılımı veren model olarak belirlenmiştir. SSA ve RO değerlerine ait dağılım haritaları Şekil 6 da verilmiştir. Şekil 6 da görüleceği üzere SSA ve RO değerleri çalışma alanının kuzey batıdan güney batıya doğru bir artış eğiliminde olduğu göstermektedir.

Çizelge 3. Enterpolasyon modeller and of SSA ve tamin değerlere ait RMSE

Enterpolasyon	Modeller	SSA	RO
IDW	IDW-1	0.0256	0.0194
	IDW-2	0.0273	0.0209
	IDW-3	0.0290	0.0224
RBF	TPS	0.0351	0.0261
	CRS	0.0264	0.0197
	SWT	0.0262	0.0196
Kriging	Ordinary	Gaussian	0.0254
		Exponential	0.0255
		Spherical	0.0255
	Simple	Gaussian	0.0253
		Exponential	0.0253
		Spherical	<b>0.0252</b>
	Universal	Gaussian	0.0254
		Exponential	0.0255
		Spherical	0.0255
		0.0198	0.0189
		0.0197	0.0197
		0.0197	0.0197
		0.0189	<b>0.0188</b>
		0.0189	0.0189
		0.0197	0.0197
		0.0198	0.0198
		0.0198	0.0198

TPS:Thin Plate Spline, CRS:Completely Regularized Spline, SWT:Spline with Tension, SSA:Sınırlandırılmış su aralığı, RO:Rastgele orman modeli



Şekil 6. SSA ve RO değerlerine ait konumsal dağılım haritaları

## Sonuç

Bu çalışmada; Orta Karadeniz bölgesinde farklı arazi kullanım türleri altında toprakların sınırlayıcı su aralığı içeriklerinin değerlendirilmesi, havalanma ve sıkışma problemlerinin ortaya konmasının yanında, farklı makine öğrenme algoritmaları ile SSA'nın tahmin edilebilirliği incelenmiştir.

Tarım arazileri üzerindeki toprakların % 14.55'inde SSA optimum koşullarda iken, % 28.48'inde havalanma problemi, % 27.27'sinde hem havalanma hem sıkışma, % 29.70'inde ise sıkışma problemi tespit edilmiştir. Havalanma ve sıkışma problemlerinin Mera topraklarının % 43.63'ünde optimum koşullar ortaya çıkarken % 36'sinde havalanma, %14.54'ünde sıkışma, % 5.45'inde hem havalanma hem sıkışma problemleri tespit edilmiştir. Orman örtüsü altındaki topraklarda ise % 37.037'sinde optimum koşullar % 4.62'sinde havalanma ve sıkışma, % 3.7'sinde sıkışma ve % 54.62'sinde ise havalanma problemleri tespit edilmiştir. Çalışma sonucunda tarım yapılan topraklarda (özellikle fındık alanlarında) ideal koşulların oransal olarak daha az olduğu, havalanma ve sıkışma problemlerinin mera ve orman arazi kullanım türlerine kıyasla daha fazla olduğu sonucuna varılmıştır. SSA'nın tahmininde kullanılan farklı algoritmalar içerisinde en düşük hata oranı ve başarılı tahmin rastgele orman algoritması ile elde edilmiştir. Bu algoritmada çok sayıda ağaç kullanılması tahmin gücünü arttırmaktadır.

Bu çalışma ile farklı arazi kullanımlarına bağlı olarak toprakların özellikleri ve suyun dinamiğinde farklılıkların olduğu ortaya konmuştur. Arazilerin durumlarının değerlendirilmesi ve problemlerin önceden tespiti için tahmin modelleri ile jeostatistiksel yaklaşımların kullanılması gelecekte oluşabilecek tehlikelerin önceden değerlendirmesine olanak kılacaktır. Ayrıca sıkışma ve havalanma problemlerini minimum seviyeye indirmek için organik madde ilavesi, korumalı toprak işleme ve tarla trafiğinin azaltılması gibi önlemlerin alınması önerilmektedir.

## Kaynaklar

- Akar Ö, Güngör Ö. 2013. Classification of multispectral images using random forest algorithm. *Journal of Geodesy and Geoinformation* 1(2):139-146.
- Alaboz P, Demir S, Dengiz O. 2020. Determination of spatial distribution of soil moisture constant using different interpolation model case study, Isparta Atabey plain. *Journal of Tekirdag Agricultural Faculty* 17(3): 432-444.
- Alaboz P, Başkan O, Dengiz O. 2021. Computational intelligence applied to the least limiting water range to estimate soil water content using GIS and geostatistical approaches in alluvial lands. *Irrigation and Drainage* 70(5): 1129-1144.
- Alaboz P, Demir S, Işıldar A A, Başayığıt L. 2021a. Elma tarım alanlarında yüzey toprakların sınırlandırılmış su aralığının belirlenmesi. *Toprak Su Dergisi* 10(1): 13-22.
- Arslan E, Çaycı G, Dengiz O, Yüksel M, Atikman Çiçek N. 2018. Toprakların bazı makro besin elementi içeriklerinin farklı tarımsal arazi kullanımları altında konumsal dağılımlarının belirlenmesi. *Toprak Su Dergisi*, 7(2): 28-37.
- Ballabio C. 2009. Spatial prediction of soil properties in temperate mountain regions using support vector regression. *Geoderma* 151: 338-350. <https://doi.org/10.1016/j.geoderma.2009.04.022>.
- Breiman L. 2001. *Random Forests*, Machine learning, Kluwer Academic Publishers 45(1): 5-32.
- Burt R. 2014. *Soil survey field and laboratory methods manual*. United States Department of Agriculture. Natural Resources Conservation Service. National Soil Survey Center. Natural Resources Conservation Service. Kellog Soil Survey Laboratory.
- Busscher WJ. 1990. Adjustment of flat-tipped penetrometer resistance data to a common water content. <http://naldc.nal.usda.gov/download/18014/PDF>.
- Cecagno D, de Andrade S E V G, Anghinoni I, Kunrath T R, Martins A P, Reichert J M, de Faccio Carvalho PC. 2016. Least limiting water range and soybean yield in a long-term, no-till, integrated crop-livestock system under different grazing intensities. *Soil and Tillage Research*, 156: 54-62.
- Chan K, Oates A, Swan A, Hayes R, Dear B, Peoples M. 2006. Agronomic consequences of tractor wheel compaction on a clay soil. *Soil and Tillage Research* 89 (1): 13-21
- Cortes C, Vapnik V. 1995. Support-vector networks. *Mach. Learn.* 20, 273-297.
- Çakır F S, 2019. *Yapay sinir ağları*. Nobel yayınları, 2. Baskı, Ankara.
- Da Silva A, Kay B, Perfect E. 1994. Characterization of the least limiting water range of soils. *Soil Science Society of America Journal* 58 (6): 1775-1781.

- Da Silva AP, Kay B. 1997. Estimating the least limiting water range of soils from properties and management. *Soil Science Society of America Journal* 61 (3): 877-883.
- Dong Z, Wang N, Liu J, Xie J, Han J. 2021. Combination of machine learning and VIRS for predicting soil organic matter. *Journal of Soils and Sediments*, 21(7): 2578-2588.
- Eraslan S, İmamoğlu A, Coşkun A, Saygın F, Dengiz O. 2016. İnebolu Havzası topraklarının erozyon duyarlılıklarını belirlenmesinde agregat ve strüktür stabilite durumları, Arazi örtüsü ile olan ilişkileri. *Uluslararası Coğrafya Sempozyumu*, 13-14.
- Erol H. 2011. Farklı dozlarda humik+fulvik asit uygulamasının farklı bölge topraklarında mısır vejetasyonu altında toprağın biyolojik aktivitesine etkisi. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Toprak Bilimi ve Bitki Besleme Anabilim Dalı, 58s.
- FAO-Toprak Gübre ve Su Kaynakları MAE. 2015. Türkiye topraklarının organik karbon bilgi yönetim sistemi, Ankara.
- Gülser C, Ekberli İ, Gülser F. 2021. Effects of deforestation on soil properties and organic carbon stock of a hillslope position land in Black Sea Region of Turkey. *Eurasian Journal of Soil Science*. 10(4):278-284.
- Gündüz Z, Barik K. 2019. Farklı Toprak Yönetiminin Toprağın Bazı Fiziksel Özelliklerine Etkisi. *Journal of the Institute of Science and Technology* 9(3): 1797-1807.
- Haghighi Fashi F, Gorji M, Sharifi F. 2017. Least limiting water range for different soil management practices in dryland farming in Iran. *Archives of Agronomy and Soil Science* 63(13): 1814-1822.
- IPCC - Intergovernmental Panel on Climate Change, 2019. Fifth assessment report (AR5). <https://www.ipcc.ch/report/ar5/syr/>.
- İmamoğlu A, Eraslan S, Coşkun A, Saygın F, Dengiz O. 2018. Farklı toprak özelliklerine bağlı toprak kabuk oluşumu. *Türk Coğrafya Dergisi* (71): 47-52.
- Kacar B. 2009. Toprak analizleri. Nobel yayın dağıtım, Ankara, p.467.
- Kalkınma Bakanlığı, 2018. On Birinci Kalkınma Planı (2019-2023), Tarımda toprak ve suyun sürdürülebilir kullanımı. Özel İhtisas Komisyon Raporu.
- Karahan G, Erşahin S, Öztürk HS. 2014. Field capacity dynamics affected by soil properties. *Journal of Agricultural Faculty of Gaziosmanpaşa University* 30(1): 1-9.
- Kay BD, Anger DA. 2002. Soil structure in soil physics companion (AWarrick, Ed) 249-296.
- Leão TP, Da Silva AP, Perfect E, Tormena CA. 2005. An algorithm for calculating the least limiting water range of soils. *Agronomy Journal* 97(4): 1210-1215.
- Letey J. 1958. Relationship between soil physical properties and crop production. In *Advances in soil science* (pp. 277-294). Springer, New York, NY.
- Lewis CD. 1982. *Industrial and business forecasting methods*. Londra: Butterworths publishing, 40 p
- Liaw A, Wiener M. 2002. Classification and regression by random forest. *R News*, Vol.2/3, December.
- Marashi M, Torkashvand A M, Ahmadi A, Esfandyari M, 2017. Estimation of soil aggregate stability indices using artificial neural network and multiple linear regression models. *Spanish Journal of Soil Science: SJSS* 7(2):122-132.
- MGM - Meteoroloji Genel Müdürlüğü, 20220. <http://www.mgm.gov.tr/veridegerlendirme/yillik-toplam-yagis-verileri.aspx#sfU>.
- Negiş H, Şeker C, Çetin A. 2020. Toprak sıkışması ve sınırlayıcı su aralığı üzerine farklı organik materyallerin etkileri. *Toprak Bilimi ve Bitki Besleme Dergisi* 8(2): 118-127.
- Özdemir N. 2019. Farklı topoğrafik yapı ve arazi kullanım koşullarında hacim ağırlığı ile bazı fiziksel ve kimyasal toprak özellikleri arasındaki ilişkiler. *Toprak Bilimi ve Bitki Besleme Dergisi* 7(2): 86-91.
- Öztürkmén AR, Ramazanoğlu E, Çelik A, Arslan M. 2021. Effects of different land use on some soil properties in Adıyaman province. *Avrupa Bilim ve Teknoloji Dergisi* (25): 594-600.
- Pal M. 2005. Random forest classifier for remote sensing classification. *International Journal of Remote Sensing* 26(1): 217-222.
- Prasad AM, Iverson LR, Liaw A. 2006. Newer classification and regression tree techniques: Bagging and random forests for ecological prediction. *Ecosystems* 9:181-199
- Saygın F, Dengiz O, İç S, İmamoğlu A. 2019. Bazı fiziko-kimyasal toprak özellikleri ile bazı erodibilite parametreleri arasındaki ilişkilerin mikro havza ölçeğinde değerlendirilmesi. *Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi* 20 (1): 82-91.
- Silva SHG, Weindorf DC, Pinto LC, Faria WM, Junior FWA, Gomide LR, Curi N. 2020. Soil texture prediction in tropical soils: A portable X-ray fluorescence spectrometry approach. *Geoderma* 362: 114136.

- Smola AJ, Schölkopf B. 2004. A tutorial on support vector regression. *Statistics and Computing* 14(3):199-222.
- Takçı H. 2008. *Data Mining Lecture Notes*, Gebze Institute of Technology.
- Tavanti RF, Freddi ODS, Tavanti TR, Rigotti A, Magalhães WDA. 2019. Pedofunctions applied to the least limiting water range to estimate soil water content at specific potentials. *Engenharia Agrícola* 39(4): 444-456.
- Watts JD, Lawrence RL. 2008. Merging random forest classification with an object-oriented approach for analysis of agricultural lands, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXVII(B7).
- Watts JD, Powell SL, Lawrence RL, Hilker T. 2011. Improved classification of conservation tillage adoption using high temporal and synthetic satellite imagery. *Remote Sensing of Environment*, 115(1): 66-75.
- Wilding LP. 1985. Spatial variability: Its documentation, accommodation and implication to soil surveys. 166-194p. In D.R. Nielsen and J. Bouma (eds.). *Soil Spatial Variability*: Pudoc. Wageningen Netherlands.
- Wu L, Feng G, Letey J, Ferguson L, Mitchell J, Mc Cullough-Sanden B, Markegard G. 2003. Soil management effects on the nonlimiting water range. *Geoderma* 114(3-4): 401-414.
- Yamaç SS, Şeker C, Negiş H. 2020. Evaluation of machine learning methods to predict soil moisture constants with different combinations of soil input data for calcareous soils in a semiarid area. *Agricultural Water Management* 234:106121.