



TÜR DAĞILIM MODELLEMESİNDE MAKİNE ÖĞRENME YÖNTEMLERİ (MACHINE LEARNING TECHNIQUES IN SPECIES DISTRIBUTION MODELING)

İlksen ÇELİKOĞLU¹

¹Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Peyzaj Mimarlığı Anabilim Dalı, ISPARTA/Türkiye
ilksencelikoglu@gmail.com, ORCID: 0009-0001-3110-7201

Doi: <https://doi.org/10.53463/ecopers.20240253>

Corresponding Author/İletişim yazarı: İlksen ÇELİKOĞLU

E-mail: ilksencelikoglu@gmail.com



ÖZET

Küresel ısınma sebebiyle oluşan iklim değişikliği, uzun süreli sonuçlarıyla insan hayatı için önem teşkil eden evrensel sorunlardanır. İklim değişikliğinin, türlerin dağılımlarında olumsuz etkiye sahip olacağı yapılan çalışmalarla öngörülmektedir. Bu çalışmalarda, türlerin bulunduğu alanları gösteren noktasal veriler ve alanların biyoiklim verileri ele alınarak iklim senaryolarına göre türlerin günümüz- gelecek potansiyel yayılış alanları farklı tür dağılım modelleri ile tespit edilmektedir. Küresel sorunlardan biri olan iklim değişikliğinin türlerin yayılışı üzerindeki etkilerini saptamak ve farklı senaryolarla olası yayılış tahmin etmek için farklı modelleme araçları kullanılmaktadır. Türlerin mevcut ve gelecekteki potansiyel yayılış alanlarının modellemesinde sıkça kullanılan makine öğrenim tekniği yaygınlaşmış, günümüz için önemli çalışma alanlarından biri olmuştur. Makine öğrenme yöntemleri kullanılarak yapılan çalışmalar sonucunda türlerin gelecek kullanımlarının planlanabilmesi, biyolojik çeşitliliğin analiz edilebilmesi ve gerekli koruma tedbirlerinin alınması ön görülmektedir. Bu çalışma ile de tür dağılım modellemesinde sıkça kullanılan makine öğrenme yöntemleri irdelenmiştir.

Anahtar Kelimeler: İklim Değişikliği, Tür Dağılım Modellemesi, Küresel Isınma, Makine Öğrenmesi

ABSTRACT

Climate change caused by global warming is one of the universal problems that is important for human life with its long-term consequences. It is predicted by studies that climate change will have a negative impact on the distribution of species. In these studies, point data showing the areas where the species are found and bioclimatic data of the areas are taken into consideration and the current and future potential distribution areas of the species are determined with different species distribution models according to climate scenarios. Different modeling tools are used to determine the effects of climate change, one of the global problems, on the distribution of species and to predict the possible distribution with different scenarios. The machine learning technique, which is frequently used in modeling the current and potential future distribution areas of species, has become widespread and has become one of the important fields of study today. As a result of studies using machine learning methods, it is envisaged that future uses of species can be planned, biological diversity can be analyzed and necessary conservation measures can be taken. In this study, machine learning methods frequently used in species distribution modeling were examined.

Key words: Climate Change, Species Distribution Modeling, Global Warming, Machine Learning.

1. GİRİŞ

Dünyanın en büyük sorunlarından biri küresel iklim değişikliğidir. İklim değişikliğinden habitat ve insan yaşamı olumsuz olarak etkilenmektedir. Zamanla daha da belirginleşen, etkileri artan küresel iklim değişikliği, gereksinim duyulan doğal su kaynaklarının azalması nedeniyle kuraklık ve çölleşmeye, bunların yanı sıra ekosistem, tür ve genetik çeşitliliklerin zarara uğramasına neden olmaktadır. Ülkemizde küresel iklim değişikliğiyle ilişkili olarak sel, su kaynaklarının azalması, fırtına, kuraklık ve orman yangınları gibi doğal afetler sıkça yaşanmaya başlanmıştır. Su ve kara ekosistemlerinde ortaya çıkan bu değişimler sebebiyle ekosistemler risk altındadır. Bunun yanı sıra sosyoekonomik etkileri de oldukça fazladır. Küresel iklim değişikliğinin sonucunda, buzulların erimekte, sıcaklıklar artmakta, yağışlarda değişiklikler meydana gelmektedir (Öztop, 2023; Tourani vd., 2022). Bitkilerin büyümesi ve gelişmesinde iklimi oluşturan parametreler (sıcaklık, yağış, nem vd.) büyük bir etmendir. Bu sebeple, iklimi oluşturan parametreler, bitki türlerinin coğrafi dağılımını belirleyen değişkenlerdir (Bertrand vd., 2011; Lenoir vd., 2008; Uzun, 2020).

İklim, yerkürenin yaklaşık 4.5 milyar yıllık tarihi boyunca tüm zaman ölçeklerinde doğal olarak bir değişme eğilimi göstermektedir (Türkeş, 2008; Uzun, 2020). Birçok endemik bitki türü, dar coğrafi dağılımları ve sınırlı habitat yayılışları ile küresel iklim değişikliğinin sebep olduğu yok olma tehlikesiyle karşı karşıya olduğu için tehdit altındaki bu türleri ifade eden IUCN kırmızı listesine dâhil edilmiştir (Arslan vd., 2021; Kaky & Gilbert, 2019; Le Breton vd., 2019). Bitki toplumlarının küresel iklim değişikliğine verdiği tepkiler, son zamanlarda oldukça belirgin bir hale gelmiştir (Uzun, 2020; B. Wang vd., 2020).

Küresel iklim değişikliğinin etkileri daha önce görülmemiş fazla oranlarda gerçekleşmekte ve geçtiğimiz yüzyılda ortalama sıcaklık 0,85°C artarak 2100 yılına kadar min. 0,3–1,7°C ila max. 2,6–4,8°C arasında artmaya devam etmesi beklenmektedir (IPCC, 2014). Özellikle habitatları dar olan bitkilerin yaşam alanları küresel iklim değişimi ile risk altında kalmaktadır (Ashraf vd., 2016; Cobben vd., 2014; Fitzpatrick vd., 2008; Lawler vd., 2009; Thuiller vd., 2005; Uzun, 2020). Bu bakımdan yok oluş tehlikesi altında olan türlerin, neslinin tükenmemesi için gereken tedbirler alınmalıdır. Bu bağlamda tür dağılımı tahmini, modelleme ve haritalama tehdit altındaki ve nesli tükenmekte olan bitki türleri için hayati öneme sahiptir (Gaston, 1996; Uzun, 2020).

Küresel iklim değişikliğine bitki türlerinin verdiği tepkiler üç farklı şekilde olabilir (Arslan vd., 2021; Chakraborty vd., 2016; Jagodziński & Dyderski, 2018). İlki; hedefte olan bitki tür, ekolojik nişlerin takibini sürerek başka bir bölgeye göç edebilir (Abdelaal vd., 2019; Arslan vd., 2021;

Keliang vd., 2018). İkincisi; hedefte olan bitki türü, var olan konumda, zamanla değişen farklı iklimsel koşullara uyum sağlayabilir (Arslan vd., 2021; Du vd., 2021; Rana vd., 2021; Yi vd., 2016). Üçüncüsü ise; hedef türün, neslinin tükenmesi, yerel yok oluş gözlemlenebilir (Arslan vd., 2021; Wiens, 2016). Bu türlerin korunması, habitat uygunluklarını göz önünde bulundurarak, günümüz ve gelecekteki koşullar altında tür varlığını ve kalıcılığını sağlayan çevresel faktörlerin belirlenmesi ile mümkündür (Arslan vd., 2021; Mod, 2016; Wilson vd., 2020).

Bitki türlerini korumak için yapılması gereken ilk adım; mevcut coğrafi dağılımı, habitat uygunluğunu ve nesilleri yok olma tehdidiyle karşı karşıya bırakan riskleri belirlemektir (Akyol & Örucü, 2019; Arslan vd., 2021; Wan vd., 2017). Bu bakımdan, nesli tehlikede olan türler yayılış alanlarını değiştirmeden veya nesilleri kalıcı olarak kaybolmadan gerekli tedbirler alınmalıdır (Gaston, 1996; Örucü, 2019; Üyük, 2021). Nesli tükenmekte olan riskli türlerin, karasal ekosistemlere yeniden dahili ve rehabilitesi yapılmalıdır. Bu aşamada ise bitki türlerinin potansiyel dağılımları hakkında detaylı bilgiler verilmeli, analizler yapılmalıdır (Üyük, 2021).

2. TÜR DAĞILIMI MODELLEMESİNİN TEMELLERİ

Tür dağılım modellemesi (SDM), bir türün olası coğrafi yayılışını ve o türün ekolojik ihtiyaçlarını modellemek için kullanılan bir tekniktir. Bu teknik, farklı yerlerdeki potansiyel uygun habitatları tahmin etmek için türün bilinen oluşumunun çevresel koşullarını analiz etmektedir (Çardak & Örucü, 2021; Guisan & Zimmermann, 2000; Li vd., 2019; Peterson vd., 2007; Zhang vd., 2020). Başka bir deyişle türün gereksinimlerinin bir modelini oluşturmak ve haritalamak için verilerin çevresel ve ekolojik değişkenlerle birleştirilmesi oluşumudur (Abrahamyan & Barševskis, 2015; Anderson vd., 2003; Çardak & Örucü, 2021).

Tarihte yüzyıllar boyunca, türlerin yayılış alanları akademik çalışmalarda işlenmiştir. İlk zamanlarda yapılan akademik çalışmalar genellikle nitel özellikler taşımış, günümüzde ise sayısal modeller, haritalar gibi nicel yöntemler, tanım ve tahmin yapmak için kullanılmaktadır. Çeşitli amaçlara hizmet eden, farklı sayısal yöntemler bulunmaktadır (Grinnell, 1904, ss. 364-; Uzun, 2020).

Tür dağılım modellemesi (species distribution modeling, SDM) çeşitli adlarla nitelendirilmektedir. Bunlar; iklim örtü modellemesi, habitat modellemesi ve çevresel veya ekolojik niş modellemesidir (Kamal vd., 2018; Kraemer, Sinka, Duda, Mylne, Shearer, Barker, vd., 2015; Kraemer, Sinka, Duda, Mylne, Shearer, Brady, vd., 2015; Türkozan, 2019; Uzun, 2020).

Tür dağılım modellemesinin amacı, türün yayılış gösterdiği alanların toplanması, mekânsal veri tabanlarından belirleyici çevresel değişkenlerin değerlerinin alınması, çevresel değerlerin

modele konularak türün yayılış gösterdiği alanın benzerlerinin veya tür yoğunluğu gibi başka ölçütlerin tahminlerde kullanılmasıdır (Akpan vd., 2018; Kamal vd., 2018; Padilla vd., 2016; Türkozan, 2019; Uzun, 2020). Ek olarak, türe hasar veren organizmaların tehdit potansiyelini değerlendirmek, ender türlerin veya biyoçeşitliliğin yoğun olduğu bölgeleri belirlemek ve koruma tedbirleri için alanları önceliklendirmek gibi farklı amaçlarla kullanılmaktadır (Beaumont vd., 2005; Cassini, 2011; Elith* vd., 2006; Hirzel vd., 2002)

Tür dağılımlarının tahmini için kullanılan regresyon yöntemleri, türlerin gerçekleşmiş nişlerini anlamada ve küresel iklim değişikliği karşısında biyoçeşitliliğin korunmasında önemlidir (Guisan vd., 2002; Leach & Scott, 2002; Öztop, 2023). Tür dağıtım modelleri (SDM), ekoloji hakkında bilgi edinmek veya büyük ölçeklerde habitat uygunluğunun tahminine yardımcı olmak için çevresel değişkenleri türlerin oluşum bilgileriyle bağdaştırmaktadır (Elith & Leathwick, 2009; Öztop, 2023).

Tür dağılım modellerinin temelleri, çevresel değişkenlere verilen tepkiyi ve uyumu kullanarak dağılımları tahmin etmeye dayanır. Dağılım modelleri, farklı istatistiksel ve matematiksel tekniklerle türlerin habitat tercihlerini ve yayılışlarını analiz eder. Bu analizlere, biyotik etkileşimler ve habitat kalitesi de eklenerek kapsamlı bir değerlendirme yapılabilir (Cassini, 2011).

SDM'nin temel adımları şunlardır:

1. Tür dağılımı: Bir türün belirli bir alanda yayılış veya yokluk bilgileri.
2. Çevresel değişkenler: İklim (yağış, nem, vb.), arazi kullanımı, topografya gibi unsurlar, tür dağılımını etkileyen çevresel değişkenlerdir.
3. Modelleme: Çevresel değişkenlerin, tür dağılımı üzerindeki etkilerini analiz ederek, tür dağılımını tahmin etmek için kullanılan matematiksel bir yöntem.
4. Veri toplama: Tür varlığına ait yayılış konumların belirlenmesi ve yokluk konumlarının da toplanması.
5. Model doğrulama: Elde edilen modelin doğruluğunu test etmek için kullanılan analizler.
6. Tahmin: Modelin, tüm zamanlarda (gelecekteki bir iklimde) varlığın olasılığını tahmin etmek için kullanılması (R. Hijmans & Elith, 2013).

2.1. Temel Kavramlar: Tür, Türleşme, Ekolojik Niş, Çevresel ve Biyoklimatik Değişkenler


Heywood (1998)'a göre bugüne kadar bilinen 25 farklı tür tanımı vardır ve 9 tanesi sıkça kullanılmaktadır (Heywood, 1998; Önder & Awad, 2000). Tür, çoğunlukla biyolojik


sınıflandırmanın ve biyolojik çeşitliliğin temeli olarak kabul edilmektedir. Tür, “Yapısal ve özellik bakımından birbirine benzeyen, aynı fiziksel ve kimyasal etkenlere aynı şekilde yanıt veren, aynı kökenden oluşmuş ve birbirleriyle çiftleşerek döl verebilme yeteneğine sahip topluluk” olarak tanımlanmaktadır (Önder & Awad, 2000).

Türleşme, yeni bir türün oluşması, bir türden fazla sayıda türlerin meydana gelmesidir. Yeni türün üreme izolasyonu ve ekolojik uyum sağlaması olarak da açıklanabilir (Önder & Awad, 2000).

Niş; türün, etkileşimde olduğu diğer türler, habitat ve çevre üzerine etkileri ile popülasyonlarını sürdürmesine izin veren ekolojik koşulları ifade eder (Gür, 2018; Peterson vd., 2011; Uzun, 2020).

Hutchinson (1957) de, temel ve gerçekleşen ekolojik niş kavramlarını ortaya atmıştır. “Scenopoetic” (tam karşılığı olmasa da abiyotik, aslında etkileşimsiz, tür tarafından değiştirilemeyen) değişkenler ile tanımlanan temel ekolojik nişin (=bir türün popülasyonlarını sürdürmesine izin veren “Scenopoetic” çevresel koşullar, ki çevresel uzamdan boyutlu bir hiperhacim olarak tanımlanır) “Bionomic” (tam karşılığı olmasa da biyotik, aslında etkileşimli, tür tarafından değiştirilebilir) değişkenler (örneğin, diğer türler ile etkileşimler) ile gerçekleşen ekolojik nişe (=temel ekolojik nişin bir bölümü) indirgendiğini belirtmiştir. Böylece, bir türün coğrafi dağılımı, gerçekleşen ekolojik nişinin coğrafi uzamdaki ifadesidir (Hutchinson, 1957; Uzun, 2020). Son olarak Soberon ve Peterson (2005), niş kavramını biyotik, abiyotik ve hareket faktörlerini (yani, bir türün dağılım alanını şekillendiren üç ana faktörü) bir araya getiren BAH çerçevesini (=BAM framework) kullanarak tanımlamıştır (Soberon & Peterson, 2005; Uzun, 2020). Coğrafyanın, türün coğrafi dağılımını şekillendirmedeki rolü, Grinnell (1914)’ün çalışmasından çok sonra yeniden araştırılmıştır. (Grinnell, 1914; Gür, 2018; Uzun, 2020).





Şekil 1. Ekolojik niş kavramının tarihsel çerçevesi (Gür, 2018)

Tür dağılım modellemesinde, türlerin güncel yayılışını tespit etmek için kullanılan biyoklimatik değişkenler WorldClim’de gözlemlenen verilerden türetilmiş ve bunlar Çizelge 1.’de verilmiştir (Çardak & Örucü, 2021; Fick & Hijmans, 2017; R. J. Hijmans vd., 2005).

Çizelge 1. Çevresel değişkenler (*WorldClim*, 2019)

BIO1	Yıllık ortalama sıcaklık	BIO11	En soğuk çeyreğin ortalama sıcaklığı
BIO2	Günlük ortalama değişim aralığı (ortalama aylık sıcaklık (en yüksek–en düşük))	BIO12	Yıllık yağış miktarı
BIO3	İzotermallik	BIO13	En nemli ayın yağış miktarı
BIO4	Mevsimsel sıcaklık	BIO14	En kurak ayın yağış miktarı
BIO5	En sıcak ayın en yüksek sıcaklığı	BIO15	Mevsimsel yağış miktarı
BIO6	En soğuk ayın en az sıcaklığı	BIO16	En nemli çeyreğin yağış miktarı
BIO7	Yıllık sıcaklık değişim aralığı	BIO17	En kurak çeyreğin yağış miktarı
BIO8	En nemli çeyreğin ortalama sıcaklığı	BIO18	En sıcak çeyreğin yağış miktarı
BIO9	En kurak çeyreğin ortalama sıcaklığı	BIO19	En soğuk çeyreğin yağış miktarı
BIO10	En sıcak çeyreğin ortalama sıcaklığı	ELEV	Sayısal Yükseklik Modeli

Bağıntılı niş modelleri; gözlemlenen bir türün dağılımını coğrafi referanslı iklim değişkenleriyle ilişkilendirerek, çoklu regresyon yöntemleriyle modellenmesidir. Bağıntılı nişler, türlerin çevreleriyle denge içinde olduklarını ve ilgili çevresel değişkenlerin yeterince örneklenmiş olduğunu varsayar. Modeller, sınırlı sayıda tür varlığı arasında interpolasyona izin verir (“Species Distribution Modelling”, 2023).

Bağıntılı niş modellerinin etkili olabilmesi için yalnızca türlerin yayılış alanlarının değil, aynı zamanda türlerin yayılış göstermediği alanların da gözlemlenmesi gereklidir. Tür yokluklarına dair bilgiler, genellikle varlık kayıtları kadar yaygın değildir, bu nedenle çoğunlukla bu modeller oluşturulurken "Rastgele arka plan" veya "Yalancı yokluk" verileri kullanılır. Bağıntılı niş

modelleri, bir türün gözlemlenen dağılımının modelleri olduklarından, gerçekleşmiş nişi (bir türün bulunduğu ortamlar) modelleyen modellerdir. Tür için gerçekleşmiş ve temel niş aynı olabilir, ancak bir tür dağılımı, yayılma sınırlaması veya tür etkileşimleri nedeniyle coğrafi olarak sınırlıysa, gerçekleşmiş niş, temel nişten daha küçük olacaktır (“Species Distribution Modelling”, 2023).

Bağıntılı modeller, mekanik modellerden daha kolay ve hızlı uygulanabilir. Ayrıca, gözlemlenen türlerin dağılım aralığı dengeli değilse, oluşturulan modellerin doğrulukları azalabilir. (“Species Distribution Modelling”, 2023)

2.2. Mekanik Modeller

Mekanik modeller, bağıntılı niş modellerine göre daha yakın zamanda geliştirilmiştir. Bağıntılı modellere karşı olarak, mekanik modeller, bir türün çevresel koşullar içinde varlığını sürdürebileceği aralığı belirlemek için türle ilgili fizyolojik bilgileri (kontrollü saha veya laboratuvar çalışmalarından alınan) kullanır. Bu modeller, temel nişi doğrudan karakterize etmeyi ve projelendirmeyi amaçlar.


Basit bir model bir türün hayatta kalamayacağı eşik değerleri belirleyebilir. Karmaşık bir model ise çeşitli alt modeller içerebilir; örneğin, makro-iklim koşulları verilerek mikro-iklim koşulları, vücut sıcaklığı verilerek diğer biyolojik oranlar (hayatta kalma, üreme), kaynak veya enerji gereksinimleri ve popülasyon dinamikleri. Çevresel veriler, model girdileri olarak kullanılır. Çünkü tür dağılım tahminleri, türün bilinen aralığından bağımsızdır. Bu modeller, aralığı aktif olarak değişen ve dengeye ulaşmamış türler için kullanışlı olmasından dolayı tercih sebebidir (istilacı türler vb.) (“Species Distribution Modelling”, 2023).

Mekanik modeller, sebep-sonuç ilişkisine dayanır ve dengesiz durumlar için daha çok kullanılır. Bağıntılı modellere kıyasla oluşturulmaları daha fazla zaman ve emek gerektirir. Genellikle hızlı bir şekilde elde edilemeyen birçok fizyolojik verinin toplanması ve doğrulanması gerekir. Bu modeller birçok parametreyi çalışabilir, tahmin edebilir ve çok karmaşık hale gelebilirler (“Species Distribution Modelling”, 2023). Mekanik ve bağıntılı modeller, ek bilgiler elde etmek amacıyla bir arada kullanılabilir. Örneğin, mekanik bir model, türün temel nişinin açıkça dışında olan bölgeleri belirlemek için kullanılabilir ve bu bölgeler, yokluklar olarak işaretlenebilir veya analizden dışlanabilir. Böylece yapılan modellemelerin doğruluğu artar (“Species Distribution Modelling”, 2023).

3. MAKİNE ÖĞRENİMİNİN TEMELLERİ

Makine öğrenmesinin tarihi 1950'lere kadar uzanmaktadır (Eker vd., 2023; Nandi & Pal, 2021). Makine öğrenmesinin zaman içerisindeki gelişim ve değişimi Şekil 2.'de gösterilmiştir.

Nandi ve Pal (2022) tarafından ortaya konulan makine öğrenmesinin tarihsel gelişimi şu şekilde özetlenmektedir: "...Alan Turing tarafından 1950 yılında bilgisayarın bir insanla aynı zekâyı sergileyip sergilemediğini belirlemek için yaptığı Turing Testi makine öğrenmesinin ilk örneği olarak bilinmektedir. 1956 yılında John McCarthy tarafından yapay zekâ terimi bir konferansta ilk defa kullanılmıştır. Daha sonra ise Allen Newell, John Clifford Shaw ve Herbert Alexander Simon tarafından çalışan ilk yapay zekâ yazılım programı olan Logic Theorist geliştirilmiştir. 1967 yılında Frank Rosenbalt deneme yanılma yoluyla "Öğrenen" ilk bilgisayar tabanlı sinir ağını kurmuştur. Sinir ağından birkaç yıl sonra "Perceptrons" isimli (Marvin & Seymour, 1969) sinir ağları konusunda dönüm noktası olan hem de gelecek projeler için altlık oluşturacak kitap yayınlanmıştır. Kendini eğitmede geri-yayılım (back-propagation) algoritmaları kullanan yapay zekâ uygulamaları ise 1980'lerde benimsenmiş ve kullanılıyordu. IBM tarafından 1997 yılında geliştirilen Deep Blue bir satranç maçında Dünya satranç şampiyonu Garry Kasparov'u yenmiştir. Jeopardy şampiyonları Ken Jennings ve Brad Rutter, 2011 yılında IBM Watson'a yenildiler. Baidu tarafından geliştirilen süper bilgisayar Minwa 2015 yılında sinir ağı (Convolutional Neural Networks, CNN) kullanarak görüntüleri bir insandan daha yüksek bir doğruluk oranıyla tanıma ve kategorize etme amaçlı kullanılmıştır. Aynı dönem ImageNet yarışmasının sonuçlarını iyileştirmeye dönük ihtiyaçlar AlexNet'i ortaya çıkarmıştır. Derin bir sinir ağı ile desteklenen DeepMind AlphaGo 2016 yılında beş oyunluk bir maçta Go oyunu dünya şampiyonlarını yenmiştir...".



Şekil 2. Makine öğrenmesinin zaman içerisindeki gelişim ve değişimi (Eker vd., 2023; Nandi & Pal, 2021)

En temeliyle makine öğrenimi dört disipline dayanır; veri madenciliği, veri tabanı yönetimi, yapay zekâ ve derin öğrenme. Veri madenciliği, sonuçları tahmin etmek için büyük veri kümeleri içindeki normal olmayanları ve korelasyonları bulma sürecidir. Veri tabanı yönetimi, bilgisayar ortamında tutulan birbiriyle ilişkili verileri yönetme sürecidir. Yapay zekâ (AI), makinelerin deneyimlerden öğrenmesini, yeni girdilere uyum sağlamasını ve insan benzeri görevleri gerçekleştirmesini mümkün kılar. Yapay zekâ örneklerinin çoğu (satranç oynayan bilgisayarlardan kendi kendini süren arabalara), genellikle derin öğrenmeye dayanır. Bu teknolojiler sayesinde bilgisayarlar, çok miktarda ve büyük hacimli veriyi işleyerek, verilerdeki kalıpları tanıyarak belirli görevleri yapmak için eğitilebilir. Derin öğrenme ise insan beyninin veri işleme ve karar vermede davranışlarını kalıplar oluşturarak taklit eden bir yapay zekâ işlevidir. (Petekçi, 2021)

Makine öğrenmesi “Açık bir şekilde programlama yapılmadan, girdi verilerinden bilgisayarlara öğrenme yeteneği kazandırmaya yönelik bir çalışma alanı” olarak tanımlanmaktadır. Makine öğrenme süreci, hem analiz edilen hem de yeni girdi verisinden aşamalı olarak gerçekleştirilir (Eker vd., 2023; Nassif vd., 2019). Bunların yanı sıra makine öğrenmesini, “İstatistiğin ve bilgisayar biliminin kesiştiği bir alan” veya “Bilgisayara belirlenmiş görevleri yerine getirmesi için programlama yapmadan bazı örüntüleri tanımlama ve yeni tahminler ortaya çıkarma yoludur” olarak da açıklanabilmektedir (Alpaydın, 2020; Altınışık, 2022). Başarılı bir makine öğrenmesi sürecindeki işlem adımları aşağıdaki gibi özetlenebilir (Eker vd., 2023; Murty & Avinash, 2023).



Şekil 3. Makine öğrenmesi sürecindeki işlem adımları (Eker vd., 2023; Murty & Avinash, 2023).

1. Veri toplama (Data collection/acquisition); bilgisayarların öğrenebileceği şekilde önceki deneyimi temsil eden verilerin toplanma sürecidir. Sistemin sonunda koşullandırılacağı aynı koşullar dikkate alınarak benzer veriler toplanmalıdır. Böyle toplanan veriler çoğunlukla “Alan içi (in domain)” veriler olarak geçmektedir (Eker vd., 2023; Murty & Avinash, 2023). Bir makine öğrenmesi sisteminin performansı, büyük ölçüde mevcut alan içi eğitim verilerinin miktarı tarafından belirlenmektedir. Çoğunlukla, daha fazla alan içi doğru veriye ulaşmak, performansı artırmanın en etkili yolu olmaktadır (Eker vd., 2023; Jiang, 2021).

2. Özellik oluşturma (Feature generation) veya Özellik mühendisliği (Feature engineering); ham verilerden belli özellikleri çıkarmak için genellikle alana özgü bazı prosedürlerin uygulanması gerekmektedir. Başarılı bir makine öğrenmesinde, özellikler kompakt olmalı, ancak aynı zamanda ham verilerdeki en önemli bilgileri de korumalıdır (Eker vd., 2023; Jiang, 2021). Veri toplamada sıkça karşılaşılan üç farklı sorun vardır(Eker vd., 2023; Murty & Avinash, 2023). Bunlar;

- i) Eksik veri,
- ii) Farklı etki alanlarından veriler ve
- iii) Aykırı değerlerin varlığı.

3. Model Seçimi (Model selection); elde edilen verilerin türlerine ve ilgili alan bilgisine dayalı uygun model seçimi yapılır. Bazı veri türleri için makine öğrenmesi modellerinin yalnızca bir alt kümesi kullanılabilmektedir (Eker vd., 2023; Murty & Avinash, 2023). Örneğin, bazı özellikler sayısal ve diğerleri kategorik ise, algılayıcılara ve destek vektör makinelerine (SVM) dayalı sınıflandırıcılar uygun değildir. Bu gibi durumlarda Bayes sınıflandırıcısı ve karar ağacı tabanlı sınıflandırıcılar tercih edilmelidir.

4. Model tahmini/eğitimi (Model estimation/training); çıkarılan özellik temsillerinden bazı matematiksel modeller oluşturmak için bir öğrenme algoritması seçimi yapılmaktadır (Eker vd., 2023; Jiang, 2021). Bu seçim genel olarak, eğitim verilerinin boyutuna ve türüne bağlıdır. Genellikle uygulamada, etiketlenmiş verilerin bir alt kümesi eğitim verileri olarak kullanılırken,


başka bir alt küme ise modelleri doğrulamak için tercih edilmektedir (Eker vd., 2023; Murty & Avinash, 2023). Son zamanlarda makine öğrenmesindeki gelişmeler, öğrenme algoritmalarının tercihi ve model oluşturma konusunda kullanıcıya birçok çeşit sunmaktadır.

5. Model değerlendirme/doğrulama (Model evaluation/validation); bu adımda doğrulama verileri (validation data) olarak bilinen özel olarak bu amaca hizmet eden veriler kullanılmaktadır. Ancak, model bazı durumlarda doğrulama verilerinde iyi çalışmayabilir. Bu da modelin verilerle aşırı uyumlu (overfitting) olduğuna işaret etmektedir (Eker vd., 2023; Murty & Avinash, 2023).

6. Model açıklaması (Model explanation); bu adım alandaki uzman kişinin dikkatini çekmek ve geri bildirim almak için önemlidir (Eker vd., 2023; Murty & Avinash, 2023).

3.1. Makine Öğrenme Türleri

Makine öğrenmesini anlamlandırmak için öncelikle öğrenme kavramı tanımlanmalıdır. Öğrenme kavramı, farklı şekillerde ifade edilmektedir. Simon öğrenmeyi, "Zaman içinde yeni bilgilerin keşfedilmesi yoluyla davranışların iyileştirilmesi süreci" olarak açıklamaktadır. Makine öğrenmesi ise bu öğrenme işinin bilgisayarlar tarafından gerçekleştirilmesidir. Makine öğrenmesi, bilgisayarın geçmişteki deneyimlerinden elde edilen bilgi ve tecrübeleri kullanarak bir model oluşturur, bu model sayesinde gelecekte oluşacak olan benzer olaylar hakkında karar verebilmesini ve problemlere çözüm bulabilmesine imkân tanıyan bir yapay zekâ alanıdır. Başka bir deyişle makine öğrenmesi "Bilgisayarın bir olay ile ilgili bilgileri ve tecrübeleri öğrenerek gelecekte oluşacak benzeri olaylar hakkında kararlar verebilmesi ve problemlere çözümler üretebilmesidir" denilebilir (Pulat & Kocakoç, 2021).



Şekil 4. Makine öğrenmesi türleri

Farklı amaçlara hizmet eden 4 makine öğrenmesi yaklaşımı mevcuttur (Ceyhan & Kasapbaşı, 2022; Masani vd., 2019). Bunlar;

- Denetimli (Supervised) Öğrenme
- Denetimsiz (Unsupervised) Öğrenme
- Yarı-Denetimli (Semi-Supervised) Öğrenme
- Pekiştirmeli (Reinforcement) Öğrenme

Denetimli Öğrenme; etiketli veriler kullanılarak gerçekleştirilir. Denetimli makine öğreniminde bağımsız verilerle birlikte bağımlı değişken de kullanılır. Oluşturulan model daha sonra verilen bağımsız değişkenleri kullanarak, hedef değişkeni tahmin eder. Sınıflandırma ve regresyon amaçlı kullanılır. Doğrusal regresyon (lineer regresyon), lojistik regresyon (logistic regression), naïve bayes, destek vektör makineleri (support vector machines), karar ağaçları (decision tree) gibi denetimli makine öğrenmesi algoritmaları mevcuttur. (Ceyhan & Kasapbaşı, 2022)

Denetimsiz Öğrenme; etiketlenmemiş, belirsiz veriler üzerinde çalışır. Veriler etiketsiz olduğundan kümeleyerek anlam çıkarır. K-ortalamlar (k-means), k-en yakın komşu (k-nearest neighbour), apriori algoritması, temel bileşenler analizi (principal component analysis) denetimsiz makine öğrenme algoritmalarıdır. (Ceyhan & Kasapbaşı, 2022)

Yarı-Denetimli Öğrenme; denetimli ve denetimsiz öğrenme tekniklerini içerisinde barındırır. Etiketsiz çok miktarda veri ile etiketli az miktarda veriyi birlikte kullanabilen bir öğrenmedir (Ceyhan & Kasapbaşı, 2022).

Pekiştirmeli Öğrenme; deneme-yanılma yolunu benimsemiştir. Ödül-ceza sistemini baz alan bir yaklaşımdır. Bu yolla başarıyı hedefler. Pekiştirmeli öğrenmede ajan çevresini ölçebilir ve buna göre bir aksiyon alabilir. Alınan bu aksiyona karşı bir tepki bekler ve bu tepkiler ödül sistemi içerisinde değerlendirilir. Kazanılan ödüller ile ajan eğitilmiş olur (Ceyhan & Kasapbaşı, 2022).

3.2. Tür Dağılım Modellemesinde Kullanılan Algoritmalar

Türlere ait mevcut ve farklı iklim senaryolarına göre güncel ve gelecek yıllardaki potansiyel yayılış alanları, türün yaşam gösterdiği alanlardaki noktasal veri kayıtları ile bu alanlara ait sayısal biyoiklim verileri kullanılarak makine öğrenme teknikleri ile ortaya konulabilmektedir (Arslan, 2019; Çardak & Örüçü, 2021; S. Phillips & Dudík, 2008; Sarıkaya vd., 2018; Sérgio vd., 2007; Tittensor vd., 2009; Y. Wang vd., 2007; Ward, 2007; Williams vd., 2009; Wollan vd., 2008; Yuan vd., 2015).

Tür dağılımlarının tahmin, son yıllarda koruma planlamasının önemli bir bileşeni haline gelmiştir. Az rastlanan veya soyu tükenmekte olan türlerin araştırılması, insani faaliyetlerin sonucunun biyolojik çeşitlilik üzerindeki etkisinin değerlendirilmesi, güncel koruma alanlarının planlanması, küresel iklim değişikliğinin türlerin yayılışı üzerindeki etkilerinin tahmin edilmesi, istilacı türlerin yayılmasının önlenmesi amacıyla geliştirilen modelleme yöntemleri vardır (Abrahamyan & Barševskis, 2015; Çardak & Örüçü, 2021; Guisan & Thuiller, 2005; Peterson, 2006).

3.2.1 MaxEnt (Maximum Entropy)

MaxEnt yazılımı S.J. Philips ve arkadaşları tarafından 2004 de “Türlerin dağılım modellerine maksimum entropi yaklaşımı” başlıklı çalışma ile duyurulmuştur. Yazılım maksimum entropi prensibine dayanmaktadır. Temel çalışma prensibi maksimum entropi dağılımının olasılığını bularak seçilen türün dağılımını hesaplamaktır. MaxEnt’in olasılık dağılımını oluşturan etmenler, çalışma alanına ait çevresel parametrelerin değeridir. Bu değerler her biri farklı katmanlarda olacak şekilde örnekleme noktalarında türlere ait noktasal veriler, , iklimsel değişkenler, vejetasyon ,yükseklik, toprak yapısı gibi farklı parametreleri içerisinde barındırır (Çardak & Örüçü, 2021; Karacaoğlu, 2013; S. J. Phillips vd., 2006). Türlerin bir bölgede var olma durumunu göz önünde bulundurarak istatistiksel analizler yapar, türün bulunduğu konumları maksimum entropi modeline göre analiz eder ve hangi iklim koşullarında daha iyi bir yayılış göstereceğini, seçili tür için yaşamını devam ettirecek alanları tahmin etmektedir (Çardak & Örüçü, 2021; Yılmaz, 2015).

MaxEnt bilgisayar programının diğer programlara göre bazı avantajları bulunmaktadır (Çardak & Örü, 2021; S. J. Phillips vd., 2006; Yılmaz, 2015). Ücretsizdir, programın çalışması için türün sadece varlık konum verileri ve çalışma alanının çevresel ve iklimsel verilerini gerekmektedir. Örneklerin konum veri sayısı yeterli miktarda olmasa bile iyi bir performansla program çalışabilir (Costa vd., 2009; Çardak & Örü, 2021; Hernandez vd., 2006; Pearson, 2010; S. Phillips & Dudík, 2008; Yılmaz, 2015). Ara yüzü kolay bir programdır ve farklı programlarla kolayca birlikte çalıştırılabilir. Maksimum entropi modelleme, bilgisayar tabanlı algoritma da ve istatistik yöntemlerini içeren araştırmalarında aktif bir şekilde kullanılmaktadır (Çardak & Örü, 2021).

3.2.2 GARP

Türlerin yayılış alanlarını tahmin etmek için kullanılan makine öğrenme yöntemlerinden biridir. İlk uygulaması Boston ve Stockwell tarafından 1994 yılında " Environmental Resources Information Network" adlı bilimsel bir toplantıda gerçekleştirilmiştir (Beaumont vd., 2005; Çardak & Örü, 2021; Karacaoğlu, 2013). Bu model türlerin dağılımlarını tahmin etmek için genetik algoritmalar kullanmaktadır ve kullanılan bu algoritmalar Holland tarafından geliştirilmiştir (Çardak & Örü, 2021; Holland, 1992; Karacaoğlu, 2013). GARP, türlerin konumlarına ait nokta verileri ve türün hayatta kalma yeteneğini sınırlayabilecek çevresel parametreleri içeren coğrafi katmanları kullanmaktadır (Çardak & Örü, 2021; *DataOne*, 2020). GARP'ın bağıntılı modelleri, türlerin oluşum kayıtlarını veya gerçek dağılımını ve türün fizyolojisini çevresel değişken kümeleri ile ilişkilendirerek tür için uygun olan çevresel koşulları tahmin etmeyi hedeflemektedir (Abrahamyan & Barševskis, 2015; Çardak & Örü, 2021).

GARP modellerinin altlığı regresyon modellerine bağlanmaktadır. Modelin çalıştırılması için gerekli verilerin doğru bir şekilde elde edilmesi, türler için tahmini yayılış haritalarının oluşturulması, ele alınan veri yükü açısından zorlu bir süreç gibi olsa da coğrafi bilgi sistemleri ile ilişkili olarak çalışan bir sistem olduğundan çevresel parametrelere ait verilerin oluşturulup işlenmesi ve kullanılmasında önemli bir avantaj sağlamaktadır (Çardak & Örü, 2021; Karacaoğlu, 2013).

3.2.3 Random Forest

Random Forest algoritması, topluluk öğrenme yöntemidir. Sınıflandırma işlemi sırasında birden fazla karar ağacı üretir ve bu şekilde sınıflandırma değerini yükseltmeyi hedefler. Bireysel olarak oluşturulan karar ağaçları, bir araya gelerek karar ormanını oluşturur. Karar ormanı içerisinde

bulunan karar ağaçları, ilişkili olduğu veri setinden rastgele seçilmiş birer alt kümedir. (Fidancı, 2017)

Random Forests 2001 yılında Leo Breiman tarafından geliştirilmiştir. RF algoritması Brieman'ın 1996 yılında geliştirdiği Random Subspace yöntemlerinin birleşmesidir (Fidancı, 2017). RF tekniği, bilinen diğer makine öğrenme teknikleri içerisinde tahmin geçerliliği ve model yorumlanabilirlik doğruluğu en yüksek olan tekniklerdendir. Rastgele örneklemeyi ve topluluk yöntemlerindeki tekniklerin iyileştirilmiş özelliklerini içerir. Bu sebeple RF, daha iyi genellemeler yapar ve doğruluğu yüksek geçerli tahminlerde bulunur. RF'nin tahminlerinin kesin olmasının nedenleri, sapması düşük sonuçlar vermesi ve ağaçlar arasındaki düşük korelasyondur. Düşük sapma miktarı ise oldukça büyük ağaçların oluşturulması ile mümkündür. Farklı ağaçlar oluşturularak da düşük korelasyonlu topluluk elde edilebilir. Birbirinden farklı olarak kurulan sınıflama ve regresyon karar ağaçları bizi sonuca götürür. Karar ormanı oluşturur. Ormanın oluşumu esnasında çıkarılan sonuçlar toplanılarak en son tahmin yapılır (Fidancı, 2017).

RF;

- Çoğu veri setiyle çalışırken, Adaboost ve Destek Vektör Makinelerine göre daha net ve kısa sürede sonuçlanır.
- Çokça değişken ve fazla sayıda sınıf etiketine sahip değişkenleri içerisinde barındıran veri setlerini kullanır.
- Ormana ağaçlar eklendikçe, test setine ait hata tahmini azalır, sonuçların kesinliği artar (Fidancı, 2017).

3.2.4 GAM ve GLM

Doğrusal regresyon modellerinde, istatistiksel analiz yöntemleri bağımlı değişkenin normal dağıldığı varsayımına dayanır. Bağımlı değişkenin sürekli olmadığı durumları analiz etmek için de genelleştirilmiş modeller kullanılmaktadır. Bu durumlarda bağımlı değişken sürekli değildir. Bunun yanı sıra, değişkenleri sürekli olup, normal dağılım göstermeyen verilerde olabilir. Bu tür verilerin analizine imkân verecek geliştirilmiş modeller Genelleştirilmiş Doğrusal Modellerdir (GLM) (Ceng vd., 2009). GLM, ilk kez Nelder ve Wedderburn (1972) tarafından ortaya konmuştur. Çok çeşitli alanlarda kullanılmıştır. Bu alanlardaki ilk detaylı kitaplar McCullagh ve Nelder (1989), Aitkin ve Ark (1989) ve Dobson (1990) tarafından yazılmıştır. Regresyon modelleri, farklı değişkenlerin etkileşimli davranışını anlamak için tahmin, sınıflandırma ve veri analitik araçlarını sağlayarak pek çok uygulama alanında kullanılmasında önemli bir etkidir.

Basit olmasına rağmen doğrusal modeller, sık sık gerçek yaşam etkilerinde genellikle doğrusal olmadığı için başarısızlığa neden olurlar. Daha esnek istatistiksel modeller, doğrusal olmayan regresyon etkilerini tanımlamak için kullanılabilmektedirler. Bu modeller de; Genelleştirilmiş Toplamsal Modeller (GAM) olarak adlandırılırlar (Aitkin vd., 1989; Ceng vd., 2009; Cengiz & Percy, 2001; Dobson & Barnett, 1990; McCullagh & Nelder, 1989; Nelder & Wedderburn, 1972).

Toplamsal Modellerin her türlü bağımlı değişken için genelleştirilmiş hali Hastie & Tibrishani (1990) ve Hastie (1991) tarafından ortaya çıkmıştır. Bu durum da Genelleştirilmiş Toplamsal Modeller (GAM) olarak isimlendirilir. Bu modeller, bilinen GLM'nin modifiye edilmiş halidir. Bağımlı değişkenin ortalamasının bir toplamsal tahmin ediciye bağlı olduğu bu modellerde doğrusal olmayan bir fonksiyonu kullanılır. GLM'de olduğu gibi GAM, bağımlı değişkenin dağılımının üstel dağılımlar ailesinden olmasını ister. GAM'la GLM arasındaki tek fark GAM'ın doğrusal tahmin edici olarak bilinmeyen düzleştirici fonksiyonları kullanmasıdır (Ceng vd., 2009; T. J. Hastie, 1991; T. Hastie & Tibshirani, 1990)

Çoklu regresyon analizin temel varsayımlarından biri olan bağımlı değişken ile açıklayıcı değişkenler arasındaki varsayımın doğrusal gibi bilinen bir matematiksel forma sahip olması varsayımı genelde incelenmez. Bu da bazı açıklayıcı değişkenlerin istatistiksel olarak anlamsızlığına neden olabilir. Doğru bir regresyon modeliyle istatistiksel olarak anlamsız olan açıklayıcı değişkenler anlamlı hale gelebilir (Ceng vd., 2009).

Klasik doğrusal modeller ve toplamsal modeller pek çok istatistiksel veri analizinde kullanılabılırken, bu modellerin uygun olmadığı durumlarda söz konusudur. Örneğin, normal dağılım bağımlı değişkenlerin kategorik olduğu durumlarda uygun değildir veya bağımlı değişken ile açıklayıcı değişken arasındaki ilişki bilinen parametrik bir formda olmayabilir (Ceng vd., 2009).

Genelleştirilmiş Toplamsal Modeller bu tür zorlukların aşılmasını sağlayabilir. Hem bağımlı değişkenin normal dağılım göstermediği hem de bağımlı değişkenle açıklayıcı değişken arasındaki ilişkinin parametrik (doğrusal yada kübik olmadığı durumlar) olmadığı durumlarda, GAM modellemeye esneklik getirir. Genelleştirilmiş Doğrusal modellere benzer şekilde GAM'da bir tesadüfi bileşen, bir toplamsal bileşen ve bir de bu iki bileşeni birleştiren fonksiyonu içerir (Ceng vd., 2009).

3.3. Makine Öğreniminin Avantajları

Makine öğrenmesi, farklı birçok alanda karşımıza çıkmaktadır. Makine öğrenmesi, günümüzde verilerin giderek artmasıyla daha önemli hale gelmiştir. Bu öğrenme, verileri birlikte

işleyebilmeyi ve bu bütünden yeni çıkarımların elde edilmesini sağlar. Büyük verilerle, gelecekte tahmin edilebilecek sonuçların elde edilmesine altlık oluşturur. Günümüzde verilerin büyük boyutlu ve karışık olması sebebiyle, insanlar bu verileri kısa zamanda yorumlayamaz. Bu sebeple, makine öğrenmesi devreye girer. Karışık ve büyük hacimli verilerden, geleceğe dönük analizlerin elde edilmesine olanak tanır (Gökalp, 2022; Türkmenoğlu & Tantuğ, 2014).

- Makine öğrenmesi birçok sektörde verimliliği arttırmak için kullanılmaktadır. Araç-gereçlerin bakım, onarım ve oluşabilecek sorunların tahmininde kullanılmakta, bu sayede sorunların azaltılması hedeflenmektedir.
- İlk icat edilen sohbet robotları, kodlanan anahtar kelimelere göre eylemleri gerçekleştiriyordu. Makine öğrenimi ile sohbet robotlarının cevapları çeşitlendi, daha hızlı ve net anlamaya başladı.
- Sağlık sektöründe tanı ve tedavide kullanılmaktadır. Hasta bakım ve hasta sonuçlarında verimliliği arttırmaktadır.
- Çiftçilerin ürün seçiminde karar verme aşamasında; iklim, enerji, su ve diğer etmenlere ait verilerinin karşılaştırılmasını sağlamaktadır.
- Yöneticilerin; sorunları belirlemesinde, çözüm aramada ve karar aşamasında hızlı olmasına yardımcı olmaktadır.
- Amazon – Trendyol gibi e-ticaret şirketlerinin ve Netflix - YouTube gibi büyük platformlar, müşteri memnuniyetini arttırmak ve süreci hızlandırmak için makine öğrenmesi kullanmaktadır.
- Makine öğrenmesi; hava, saat ve mevsim gibi değişkenlerin hizmet talebi üzerindeki etkilerini hesaplamakta; elde edilen bilgileri geçmiş verilerle kıyaslayarak, günümüz-gelecek öngörüsünü çıkartmaktadır.
- Makine öğrenmesi birçok çok sektör tarafından, pazar araştırması ve müşteri segmentasyonu için tercih edilmektedir.
- Görüntü tanıma ve sınıflandırmada kullanılmaktadır. Şüpheli davranışları algılama ve yüz tanımda sistemlerinin gelişmesinde katkı payı vardır (Turhost, 2020) .

4. TARTIŞMA VE SONUÇ

Türkiye'nin, evrensel bir sorun olan iklim değişikliğinden Akdeniz Havzası'ndaki diğer ülkeler gibi büyük ölçüde etkilenmesi öngörülmektedir. Ülkemiz, birçok endemik türü ve nesli

tükenmekte olan bitkileri barındırmaktadır. Biyolojik çeşitlilik açısından zengin olan Türkiye, iklim değişikliğine duyarlıdır.

Türler, biyolojik ve ekolojik gereksinimleriyle birbirlerinden farklılaşırlar ve her tür iklim değişikliğinden farklı seviyelerde etkilenir. Son zamanlarda yapılan çalışmalarla da türlerin iklim değişimine gösterdiği reaksiyonların incelenmesi ve izlenmesi önemli hale gelmiştir. İklim değişikliğinin olası olumlu ve olumsuz sonuçları dikkate alınmalı ve uygun koruma stratejileri belirlenmelidir. Biyolojik çeşitliliğin korunması ve sürdürülebilmesi, ekolojik ve ekonomik yönden önemlidir.

İklim değişikliğinin olumsuz etkilerini azaltmak için türlerin gelecek yayılışlarının doğru modellenmesi önemli bir çalışma konusudur. Tehlikeli altında olan türlerin yayılış alanları olan habitatların geri kazanımında, çevre faktörünün ve iklim değişimlerinin ekosistem ve tür kapsamındaki olası etkilerinin tahmin edilmesinde farklı Tür Dağılım Modelleri (SDM) tercih edilmektedir.

Bu çalışma da tür dağılım modellerinin temelleri ve makine öğrenmesinden bahsedilmiş, kullanılan Maximum Entropy, GARP, Random Forest, GAM ve GLM algoritmalarına değinilmiş, kullanım alanları, amaçları, avantaj ve dezavantajları irdelenmiştir.

Bu çalışma ile irdelenen algoritmalar sonucunda;

Maximum Entropy (MaxEnt) algoritmasının, ücretsiz ve ara yüzünün kolay olması, sadece varlık verileri ile çalışma alanına ait verilerle bile iyi bir performansla çalışması algoritmanın tercih sebeplerindendir. GARP algoritmasının, CBS sistemleri ile ilişkili olarak çalışması, verilerin işlenmesi ve kullanılmasında avantaj sağlamaktadır. RF, sapması düşük sonuçlar verdiği için diğer yöntemler arasında tahmin geçerliliği ve yorumlanabilirlik doğruluğu en yüksek algoritmadır. GAM ve GLM ise bağımlı değişkenin sürekli olmadığı durumları analiz etmek için kullanıldığı sonucuna varılmıştır.

KAYNAKÇA

- Abdelaal, M., Fois, M., Giuseppe, F., & Bacchetta, G. (2019). Using MaxEnt modeling to predict the potential distribution of the endemic plant *Rosa arabica* Crép. In Egypt. *Ecological Informatics*, 50. <https://doi.org/10.1016/j.ecoinf.2019.01.003>
- Abrahamyan, A., & Barševskis, A. (2015). Environmental Niche Modelling with Desktop GARP for Wild *Origanum vulgare* L. (Lamiaceae) in Armenia. *Environment. Technology. Resources. Proceedings of the International Scientific and Practical Conference*, 3, 7. <https://doi.org/10.17770/etr2013vol3.869>
- Aitkin, M., Anderson, D., & Hinde, J. (1989). Statistical Modelling of Data on Teaching Styles. *Journal of the Royal Statistical Society. Series A (General)*, 144(4), 419. <https://doi.org/10.2307/2981826>

- Akpan, G., Adepoju, K., Oladosu, Olakunle, & Adelabu, S. (2018). Dominant malaria vector species in Nigeria: Modelling potential distribution of *Anopheles gambiae* sensu lato and its siblings with MaxEnt. *PLoS ONE*, 13, e0204233. <https://doi.org/10.1371/journal.pone.0204233>
- Akyol, A., & Örüçü, Ö. K. (2019). İklim Değişimi Senaryoları ve Tür Dağılım Modeline Göre Kızılçık Türünün (*Cornus mas* L.) Odun Dışı Orman Ürünleri Kapsamında Değerlendirilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 17, Article 17. <https://doi.org/10.31590/ejosat.615019>
- Alpaydın, E. (2020). *Yapay Öğrenme: Yeni Yapay Zeka*. NadirKitap. <https://www.nadirkita.com/yapay-ogrenme-yeni-yapay-zeka-ethem-alpaydin-kitap27997917.html>
- Altınışık, B. (2022). *Makine Öğrenmesi Algoritmaları İle Dinamik Portföy Modellemesi*.
- Anderson, R., Lew, D., & Peterson, A. (2003). Evaluating predictive models of species' distributions: Criteria for selecting optimal models. *Ecological Modelling*, 211-232. [https://doi.org/10.1016/S0304-3800\(02\)00349-6](https://doi.org/10.1016/S0304-3800(02)00349-6)
- Arslan, E. S. (2019). İklim değişimi senaryoları ve tür dağılım modeline göre kentsel yol ağaçlarının ekosistem hizmetleri bağlamında değerlendirilmesi: *Robinia pseudoacacia* L. örneği. *Turkish Journal of Forestry*, 20(2), 142-148.
- Arslan, E. S., Gülçin, D., Sarıkaya, A. G., Ölmez, Z., Gülcü, S., Şen, İ., & Örüçü, Ö. K. (2021). Kokulu Ardiç'in (*Juniperus foetidissima* Willd.) Günümüz ve Gelecekteki Potansiyel Yayılışının Makine Öğrenmesi ile Modellenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 22, Article 22. <https://doi.org/10.31590/ejosat.848961>
- Ashraf, U., Ali, H., Chaudry, M., Ashraf, I., Adel, B., & Saqib, Z. (2016). Predicting the Potential Distribution of *Olea ferruginea* in Pakistan incorporating Climate Change by Using Maxent Model: *Sustainability*, 8, 722. <https://doi.org/10.3390/su8080722>
- Beaumont, L., Hughes, L., & Poulsen, M. (2005). Predicting species distributions: Use of climatic parameters in BIOCLIM and its impact on predictions of species' current and future distributions. *Ecological Modelling*, 186, 251-270. <https://doi.org/10.1016/j.ecolmodel.2005.01.030>
- Bertrand, R., Lenoir, J., Piedallu, C., Riofrío-Dillon, G., De Ruffray, P., Vidal, C., Pierrat, J.-C., & Gégout, J.-C. (2011). Changes in plant community composition lag behind climate warming in lowland forests. *Nature*, 479(7374), 517-520.
- Cassini, M. H. (2011). Ecological principles of species distribution models: The habitat matching rule. *Journal of Biogeography*, 38(11), 2057-2065. <https://doi.org/10.1111/j.1365-2699.2011.02552.x>
- Ceng, M. A., Sava, N., & Terz, Y. (2009). *Çoklu Doğrusal Regresyonda Model Seçiminde Genelleştirilmiş Toplamsal Modellerin Kullanımı*.
- Cengiz, M. A., & Percy, D. F. (2001). Mixed multivariate generalized linear models for assessing lower-limb arterial stenoses. *Statistics in Medicine*, 20(11), 1663-1679. <https://doi.org/10.1002/sim.924>
- Ceyhan, H., & Kasapbaşı, M. C. (2022). Üretim Sistemlerinde Makine Öğrenmesi ile Kestirimci Bakım Uygulaması ve Modellemesi. *European Journal of Science and Technology*. <https://doi.org/10.31590/ejosat.1019210>
- Chakraborty, A., Joshi, P., & Kamna, S. (2016). Predicting distribution of major forest tree species to potential impacts of climate change in the central Himalayan region. *Ecological Engineering*, 97, 593-609. <https://doi.org/10.1016/j.ecoleng.2016.10.006>
- Cobben, M., Treuren, R., Castaneda Alvarez, N., Khoury, C. K., Kik, C., & Hintum, T. (2014). Robustness and accuracy of Maxent niche modelling for *Lactuca* species distributions in light of collecting expeditions. *Plant Genetic Resources*, 13, 1-9. <https://doi.org/10.1017/S1479262114000847>

- Costa, G., Nogueira, C., Machado, R., & Colli, G. (2009). Sampling bias and the use of ecological niche modeling in conservation planning: A field evaluation in a biodiversity hotspot. *Biodiversity and Conservation*, 19, 883-899. <https://doi.org/10.1007/s10531-009-9746-8>
- Çardak, Ç., & Örucü, Ö. (2021). *Juniperus excelsa Bieb. (Boylu Ardıç) Türünün Coğrafi Dağılımının Modellenmesinde GARP ve Maxent Programlarının Karşılaştırılması*. *DataOne*. (2020). DesktopGarp. <https://old.dataone.org/software-tools/desktopgarp>
- Dobson, A. J., & Barnett, A. G. (1990). *An Introduction to Generalized Linear Models, Third Edition* (3rd edition). Chapman and Hall/CRC.
- Du, Z., He, Y., Wang, H., Wang, C., & Duan, Y. (2021). Potential geographical distribution and habitat shift of the genus *Ammopiptanthus* in China under current and future climate change based on the MaxEnt model. *Journal of Arid Environments*, 184, 104328. <https://doi.org/10.1016/j.jaridenv.2020.104328>
- Eker, R., Alkış, K., Ucar, Z., & Aydın, A. (2023). Ormancılıkta makine öğrenmesi kullanımı. *Turkish Journal of Forestry / Türkiye Ormancılık Dergisi*, 24, 150-177. <https://doi.org/10.18182/tjf.1282768>
- Elith, J., H. Graham, C., P. Anderson, R., Dudík, M., Ferrier, S., Guisan, A., J. Hijmans, R., Huettmann, F., R. Leathwick, J., Lehmann, A., Li, J., G. Lohmann, L., A. Loiselle, B., Manion, G., Moritz, C., Nakamura, M., Nakazawa, Y., McC. M. Overton, J., Townsend Peterson, A., ... E. Zimmermann, N. (2006). Novel methods improve prediction of species' distributions from occurrence data. *Ecography*, 29(2), 129-151. <https://doi.org/10.1111/j.2006.0906-7590.04596.x>
- Elith, J., & Leathwick, J. R. (2009). Species Distribution Models: Ecological Explanation and Prediction Across Space and Time. *Annual Review of Ecology, Evolution, and Systematics*, 40(1), 677-697. <https://doi.org/10.1146/annurev.ecolsys.110308.120159>
- Fick, S., & Hijmans, R. (2017). WorldClim 2: New 1-km spatial resolution climate surfaces for global land areas. *International Journal of Climatology*, 37. <https://doi.org/10.1002/joc.5086>
- Fidancı, A. S. (2017, Ekim 23). *Random Forest Algoritması*. <https://www.slideshare.net/SezerFidanci/random-forest-algoritmasi>
- Fitzpatrick, M., Gove, A., Sanders, N., & Dunn, R. (2008). Climate change, plant migration, and range collapse in a global biodiversity hotspot: The *Banksia* (Proteaceae) of Western Australia. *Global Change Biology*, 14, 1337-1352. <https://doi.org/10.1111/j.1365-2486.2008.01559.x>
- Gaston, K. J. (1996). *Species richness: Measure and measurement*. *Biodiversity: A Biology of Numbers and Difference*. <https://journals.sagepub.com/doi/10.1177/030913339602000108>
- Gökalp, Ö. (2022). *Makine Öğrenmesi—Machine Learning* (s. 14).
- Grinnell, J. (1904). *The Origin and Distribution of the Chest-Nut-Backed Chickadee* on JSTOR. <https://www.jstor.org/stable/4070199>
- Grinnell, J. (1914). *Barriers To Distribution as Regards Birds and Mammals*.
- Guisan, A., Edwards, T. C., & Hastie, T. (2002). Generalized linear and generalized additive models in studies of species distributions: Setting the scene. *Ecological Modelling*, 157(2), 89-100. [https://doi.org/10.1016/S0304-3800\(02\)00204-1](https://doi.org/10.1016/S0304-3800(02)00204-1)
- Guisan, A., & Thuiller, W. (2005). Predicting species distribution: Offering more than simple habitat models. *Ecology letters*, 8(9), 993-1009.
- Guisan, A., & Zimmermann, N. (2000). Guisan A, Zimmermann NE. Predictive habitat distribution models in ecology. *Ecological Modeling*, 135, 147-186. [https://doi.org/10.1016/S0304-3800\(00\)00354-9](https://doi.org/10.1016/S0304-3800(00)00354-9)

- Gür, H. (2018). *Hastalık biyocoğrafyası: Kırım-Kongo kanamalı ateşi hastalık bulaşma döngüsü ile örnek bir çalışma / Disease biogeography: A case study with Crimean-Congo hemorrhagic fever transmission cycle*. 46, 335-350.
- Hastie, T. J. (1991). *Generalized Additive Models | 7 | Statistical Models in S | Trevor J.* <https://www.taylorfrancis.com/chapters/edit/10.1201/9780203738535-7/generalized-additive-models-trevor-hastie>
- Hastie, T., & Tibshirani, R. (1990). *Generalized Additive Models*.
- Hernandez, P., Graham, C., Master, L., & Albert, D. (2006). The effect of sample size and species characteristics on performance of different species distribution modeling methods. *Ecography*, 29, 773-785. <https://doi.org/10.1111/j.0906-7590.2006.04700.x>
- Heywood. (1998). *The Species Concept As A Socio-Cultural Phenomenon A source Of The Scientific Dilemma*.
- Hijmans, R., & Elith, J. (2013). Species Distribution Modeling with R. *Encyclopedia of Biodiversity*, 6. <https://doi.org/10.1016/B978-0-12-384719-5.00318-X>
- Hijmans, R. J., Cameron, S. E., Parra, J. L., Jones, P. G., & Jarvis, A. (2005). Very high resolution interpolated climate surfaces for global land areas. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 25(15), 1965-1978.
- Hirzel, A. H., Hausser, J., Chessel, D., & Perrin, N. (2002). Ecological-Niche Factor Analysis: How to Compute Habitat-Suitability Maps Without Absence Data? *Ecology*, 83(7), 2027-2036. [https://doi.org/10.1890/0012-9658\(2002\)083\[2027:ENFAHT\]2.0.CO;2](https://doi.org/10.1890/0012-9658(2002)083[2027:ENFAHT]2.0.CO;2)
- Holland, J. H. (1992). *Adaptation in Natural and Artificial Systems*. MIT Press. <https://mitpress.mit.edu/9780262581110/adaptation-in-natural-and-artificial-systems/>
- Hutchinson. (1957). *Concluding Remarks Cold Spring Harbor Symposia on Quantitative Biology*.
- IPCC. (2014). *IPCC. AR5 Synthesis Report: Climate Change 2014* —. <https://www.ipcc.ch/report/ar5/syr/>
- Jagodziński, & Dyderski. (2018). *How much does climate change threaten European forest tree species distributions?*
- Jiang, H. (2021). *Machine Learning Fundamentals | Pattern recognition and machine learning*. Cambridge University Press.
- Kaky, E. D. A. K., & Gilbert, F. (2019). *Assessment of the extinction risks of medicinal plants in Egypt under climate change by integrating species distribution models and IUCN Red List criteria*.
- Kamal, M., Kenawy, M., H. Rady, M., Khaled, A., & Samy, A. (2018). Mapping the global potential distributions of two arboviral vectors *Aedes aegypti* and *Ae. Albopictus* under changing climate. *PLoS ONE*, 13, e0210122. <https://doi.org/10.1371/journal.pone.0210122>
- Karacaoğlu, Ç. (2013). *Isophya Rizeensis (Orthoptera: Tettigonidae) Türünün Ekolojik Niş Modellemesi*.
- Keliang, Z., Yao, L., Meng, J., & Tao, J. (2018). Maxent modeling for predicting the potential geographical distribution of two peony species under climate change. *Science of the Total Environment*, 634, 1326-1334. <https://doi.org/10.1016/j.scitotenv.2018.04.112>
- Kraemer, M. U. G., Sinka, M. E., Duda, K. A., Mylne, A. Q. N., Shearer, F. M., Barker, C. M., Moore, C. G., Carvalho, R. G., Coelho, G. E., Van Bortel, W., Hendrickx, G., Schaffner, F., Elyazar, I. R. F., Teng, H.-J., Brady, O. J., Messina, J. P., Pigott, D. M., Scott, T. W., Smith, D. L., ... Hay, S. I. (2015). The global distribution of the arbovirus vectors *Aedes aegypti* and *Ae. Albopictus*. *eLife*, 4, e08347. <https://doi.org/10.7554/eLife.08347>
- Kraemer, M. U. G., Sinka, M. E., Duda, K. A., Mylne, A., Shearer, F. M., Brady, O. J., Messina, J. P., Barker, C. M., Moore, C. G., Carvalho, R. G., Coelho, G. E., Van Bortel, W., Hendrickx, G., Schaffner, F., Wint, G. R. W., Elyazar, I. R. F., Teng, H.-J., & Hay, S. I. (2015). The global compendium of *Aedes aegypti* and *Ae. Albopictus* occurrence. *Scientific Data*, 2, 150035. <https://doi.org/10.1038/sdata.2015.35>

- Lawler, J. J., Shafer, S. L., White, D., Kareiva, P., Maurer, E. P., Blaustein, A. R., & Bartlein, P. J. (2009). Projected climate-induced faunal change in the Western Hemisphere. *Ecology*, 90(3), 588-597. <https://doi.org/10.1890/08-0823.1>
- Le Breton, T., Zimmer, H., Gallagher, R., Cox, M., Allen, S., & Auld, T. (2019). Using IUCN criteria to perform rapid assessments of at-risk taxa. *Faculty of Science, Medicine and Health - Papers: Part B*, 1-21. <https://doi.org/10.1007/s10531-019-01697-9>
- Leach, J., & Scott, P. (2002). Designing and Evaluating Science Teaching Sequences: An Approach Drawing upon the Concept of Learning Demand and a Social Constructivist Perspective on Learning. *Studies in Science Education*, 38, 115-142. <https://doi.org/10.1080/03057260208560189>
- Lenoir, J., Gégout, J.-C., Marquet, P. A., de Ruffray, P., & Brisse, H. (2008). A significant upward shift in plant species optimum elevation during the 20th century. *science*, 320(5884), 1768-1771.
- Li, Y., Tang, Z., Yujing, Y., Wang, K., Cai, L., He, J., Gu, S., & Yao, Y. (2019). *Incorporating species distribution model into the red list assessment and conservation of macrofungi: A case study with Ophiocordyceps sinensis*.
- Marvin, & Seymour. (1969). *Perceptrons*. MA: MIT Press. <https://mitpress.mit.edu/9780262630221/perceptrons/>
- Masani, K., Oza, P., & Agrawal, S. (2019). Predictive Maintenance and Monitoring of Industrial Machine using Machine Learning. *Scalable Computing: Practice and Experience*, 20, 663-668. <https://doi.org/10.12694/scpe.v20i4.1585>
- McCullagh, P., & Nelder, J. A. (1989). *Generalized Linear Models* / P. McCullagh / Taylor & Francis eBooks, Re.
- Mod, H. (2016). What we use is not what we know: Environmental predictors in plant distribution models. *Journal of Vegetation Science*, 27. <https://doi.org/10.1111/jvs.12444>
- Murty, M. N., & Avinash, M. (2023). *Representation in Machine Learning*. Springer Nature. <https://doi.org/10.1007/978-981-19-7908-8>
- Nandi, A., & Pal. (2021). *Interpreting Machine Learning Models: Learn Model Interpretability and Explainability Methods*.
- Nassif, A., Shahin, I., Attili, I., Azzeh, M., & Shaalan, K. (2019). Speech Recognition Using Deep Neural Networks: A Systematic Review. *IEEE Access*, PP, 1-1. <https://doi.org/10.1109/ACCESS.2019.2896880>
- Nelder, J. A., & Wedderburn, R. W. M. (1972). Generalized Linear Models. *Journal of the Royal Statistical Society. Series A (General)*, 135(3), 370-384. <https://doi.org/10.2307/2344614>
- Önder, F., & Awad, T. I. (2000). *Türlerin Oluşumu Üzerine Bir İnceleme*.
- Örücü, Ö. K. (2019). Phoenix theophrasti Gr.'nin iklim değişimine bağlı günümüz ve gelecekteki yayılış alanlarının MaxEnt Modeli ile tahmini ve bitkisel tasarımda kullanımı. *Turkish Journal of Forestry*, 20(3), Article 3. <https://doi.org/10.18182/tjf.613205>
- Öztop, Z. (2023). *XANTHIUM SPINOSUM L.'UN İKLİM DEĞİŞİKLİĞİNE BAĞLI OLARAK GLOBAL DÜZEYDE POTANSİYEL DAĞILIM ALANLARININ BELİRLENMESİ* [Thesis]. <http://acikerisim.harran.edu.tr:8080/xmlui/handle/11513/3150>
- Padilla, O., Rosas, P., Moreno, W., & Toulkeridis, T. (2016). Modeling of the ecological niches of the Anopheles spp in Ecuador by the use of geo-informatic tools. *Spatial and Spatio-temporal Epidemiology*, 21. <https://doi.org/10.1016/j.sste.2016.12.001>
- Pearson, R. (2010). Species' Distribution Modeling for Conservation Educators and Practitioners. *Lessons in Conservation*, 3.
- Petekci, A. R. (2021). *Teorik Olarak Makine Öğrenimi*.
- Peterson, A. (2006). Uses and Requirements of Ecological Niche Models and Related Distributional Models. *Biodiversity Informatics*, 3. <https://doi.org/10.17161/bi.v3i0.29>

- Peterson, A., Papes, M., & Eaton, M. (2007). Transferability and model evaluation in ecological niche modeling: A comparison of GARP and Maxent. *Ecography*, 30, 550-560. <https://doi.org/10.1111/j.0906-7590.2007.05102.x>
- Peterson, A., Soberón, J., Pearson, R., Anderson, R., Martínez-Meyer, E., Nakamura, M., & Araújo, M. (2011). Ecological Niches and Geographic Distributions. İçinde *Monographs in Population Biology* (C. 49). <https://doi.org/10.1515/9781400840670>
- Phillips, S., & Dudík, M. (2008). Modeling of species distributions with MAXENT: New extensions and a comprehensive evaluation. *Ecography*, 31, 161-175. <https://doi.org/10.1111/j.0906-7590.2008.5203.x>
- Phillips, S. J., Anderson, R. P., & Schapire, R. E. (2006). Maximum entropy modeling of species geographic distributions. *Ecological modelling*, 190(3-4), 231-259.
- Pulat, M., & Kocakoç, İ. D. (2021). Türkiye’de Makine Öğrenmesi ve Karar Ağaçları Alanında Yayımlanmış Tezlerin Bibliyometrik Analizi. *Yönetim ve Ekonomi Dergisi*, 28(2), Article 2. <https://doi.org/10.18657/yonveek.870190>
- Rana, S. K., Rana, H. K., Luo, D., & Sun, H. (2021). Estimating climate-induced ‘Nowhere to go’ range shifts of the Himalayan *Incarvillea* Juss. Using multi-model median ensemble species distribution models. *Ecological Indicators*, 121, 107127. <https://doi.org/10.1016/j.ecolind.2020.107127>
- Sarikaya, O., Karaceylan, I., & Sen, I. (2018). *Maximum entropy modeling (maxent) of current and future distributions of Ips mannsfeldi (Wachtl, 1879)(Curculionidae: Scolytinae) in Turkey.*
- Sérgio, C., Figueira, R., Draper, D., Menezes, R., & Sousa, A. J. (2007). Modelling bryophyte distribution based on ecological information for extent of occurrence assessment. *Biological Conservation*, 135(3), 341-351. <https://doi.org/10.1016/j.biocon.2006.10.018>
- Soberon, J., & Peterson, A. T. (2005). *Interpretation of Models of Fundamental Ecological Niches and Species Distributional Areas.*
- Species distribution modelling. (2023). İçinde *Wikipedia*. https://en.wikipedia.org/w/index.php?title=Species_distribution_modelling&oldid=1181885841
- Thuiller, W., Lavorel, S., Araújo, M., Sykes, M., & Prentice, I. (2005). Climate change threats to plant diversity in Europe. *Proceedings of the National Academy of Sciences of the United States of America*, 102, 8245-8250. <https://doi.org/10.1073/pnas.0409902102>
- Tittensor, D. P., Baco, A. R., Brewin, P. E., Clark, M. R., Consalvey, M., Hall-Spencer, J., Rowden, A. A., Schlacher, T., Stocks, K. I., & Rogers, A. D. (2009). Predicting global habitat suitability for stony corals on seamounts. *Journal of Biogeography*, 36(6), 1111-1128. <https://doi.org/10.1111/j.1365-2699.2008.02062.x>
- Tourani, M., Çağlayan, A., Işık, V., & Saber, R. (2022). İran’da iklim değişikliğinin, klimatolojik, meteorolojik ve hidrolojik afetlere etkisi. *Türk Coğrafya Dergisi*, 80, Article 80. <https://doi.org/10.17211/tcd.1085714>
- Turhost. (2020, Aralık 18). Makine Öğrenmesi (Machine Learning) Nedir? • Turhost Blog. *Turhost Blog*.
- Türkeş, M. (2008). Küresel iklim değişikliği nedir? Temel kavramlar, nedenleri, gözlenen ve öngörülen değişiklikler. *İklim Değişikliği ve Çevre*, 1(1), 26-37.
- Türkmenoğlu, C., & Tantuğ, A. (2014). *Sentiment Analysis in Turkish Media*. <https://doi.org/10.13140/2.1.1502.1125>
- Türkozan, S. T. (2019). *TÜRKİYE’DE AEDES (STEGOMYIA) ALBOPICTUS (SCUSE, 1894)’UN POPULASYON GENETİĞİ VE EKOLOJİK NİŞ MODELLEMESİ.*
- Uzun, A. (2020). *İKLİM DEĞİŞİMİ SENARYOLARINA GÖRE PEYZAJ TASARIMINDA KULLANILAN FABACEAE FAMILİYASINA AİT BAZI ODUNSU TÜRLERİN GÜNÜMÜZ VE GELECEKTEKİ YAYILIŞ ALANLARININ TAHMİNİ.* <https://doi.org/10.13140/RG.2.2.35773.59368>

- Üyük, A. (2021). *Platanus orientalis* L.(Doğu Çınarı) 'in CMIP6 İklim Modelleri İle Yayılış Alanlarının Karşılaştırmalı Tahmini.
- Wan, J.-Z., Wang, C.-J., & Yu, F.-H. (2017). Spatial conservation prioritization for dominant tree species of Chinese forest communities under climate change. *Climatic Change*, 144, 1-14. <https://doi.org/10.1007/s10584-017-2044-7>
- Wang, B., Xu, G., Li, P., Li, Z., Zhang, Y., Cheng, Y., Jia, L., & Zhang, J. (2020). Vegetation dynamics and their relationships with climatic factors in the Qinling Mountains of China. *Ecological Indicators*, 108, 105719. <https://doi.org/10.1016/j.ecolind.2019.105719>
- Wang, Y., Xie, B., Wan, F., Xiao, Q., & Dai, L. (2007). The Potential Geographic Distribution of *Radopholus similis* in China. *Agricultural Sciences in China*, 6(12), 1444-1449. [https://doi.org/10.1016/S1671-2927\(08\)60006-1](https://doi.org/10.1016/S1671-2927(08)60006-1)
- Ward, D. F. (2007). Modelling the potential geographic distribution of invasive ant species in New Zealand. *Biological Invasions*, 9(6), 723-735. <https://doi.org/10.1007/s10530-006-9072-y>
- Wiens, J. (2016). Climate-Related Local Extinctions Are Already Widespread among Plant and Animal Species. *PLOS Biology*, 14, e2001104. <https://doi.org/10.1371/journal.pbio.2001104>
- Williams, J. N., Seo, C., Thorne, J., Nelson, J. K., Erwin, S., O'Brien, J. M., & Schwartz, M. W. (2009). Using species distribution models to predict new occurrences for rare plants. *Diversity and Distributions*, 15(4), 565-576. <https://doi.org/10.1111/j.1472-4642.2009.00567.x>
- Wilson, J., Foxcroft, L., Geerts, S., Hoffman, M. T., MacFadyen, S., Measey, J., Mills, A., Richardson, D., Robertson, M., & van Wilgen, B. (2020). *The Role of Environmental Factors in Promoting and Limiting Biological Invasions in South Africa* (ss. 355-385). https://doi.org/10.1007/978-3-030-32394-3_13
- Wollan, A. K., Bakkestuen, V., Kauserud, H., Gulden, G., Halvorsen, R., & Svenning, J.-C. (2008). Modelling and Predicting Fungal Distribution Patterns Using Herbarium Data. *Journal of Biogeography*, 35(12), 2298-2310.
- WorldClim. (2019). <https://www.worldclim.org/>
- Yılmaz, G. (2015). *Isophya major*, *I. nervosa* ve *I. rectipennis* (Orthoptera: Tettigonidae: Phaneropterinae) türlerinin ekolojik Niş modeli.
- Yi, Y.-J., Cheng, X., Yang, Z.-F., & Zhang, S. (2016). Maxent Modeling for Predicting the Potential Distribution of Endangered Medicinal Plant (*H. Riparia* Lour) in Yunnan, China. *Ecological Engineering*, 92, 260-269. <https://doi.org/10.1016/j.ecoleng.2016.04.010>
- Yuan, H.-S., Wei, Y.-L., & Wang, X.-G. (2015). Maxent modeling for predicting the potential distribution of Sanghuang, an important group of medicinal fungi in China. *Fungal Ecology*, 17, 140-145. <https://doi.org/10.1016/j.funeco.2015.06.001>
- Zhang, K., Sun, L., & Tao, J. (2020). Impact of Climate Change on the Distribution of *Euscaphis japonica* (Staphyleaceae) Trees. *Forests*, 11(5), Article 5. <https://doi.org/10.3390/f11050525>