

Makine Öğrenmesi Yöntemini Kullanarak NDVI Zaman Serisi Verileri ile Bitki Örtüsü Tahmini

Sohaib K. M. Abujayyab^{1*}, İsmail R. Karas² ve Emrullah Demiral³

¹Karabük Üniversitesi, s.jayyab@hotmail.com

²Karabük Üniversitesi, ismail.karas@karabuk.edu.tr

³Karabük Üniversitesi, emrullahdemiral@karabuk.edu.tr

Özet

Doğal bitki örtüsünün korunması ve artırılması, temiz su kaynakları ve doğal yaşamın sürekliliği için küresel öneme sahiptir. Bunun yanında hava kirliliğinin filtrelenmesi, çöp gibi atık maddelerin ayrışması ve temizlenmesini sağlar. Son zamanlarda, bitki örtüsü verilerinin doğru bir şekilde üretimi konusuna ilgi, yüksek zamansal çözünürlüklü ve geniş kapsamlı uzaktan algılanan verilerin erişilebilirliğinin artmasına bağlı olarak eskiye göre daha da artmıştır. Bir bölgeye ait bitki örtüsünün gelecekteki halini gösteren yüksek kalitede tahmin verisi o bölgedeki yöneticiler için geleceğe dair planlama yapmalarında yardımcı olacak ve önlem alınması gereken durumlar için erken uyarı verecektir. Bu çalışmanın amacı, NDVI (Normalized Difference Vegetation Index) zaman serisi verilerini ve makine öğrenmesi yöntemini kullanarak İstanbul'un Asya yakasındaki bitki örtüsünü tahmin etmektir. Tahmin işlemi Orta Çözünürlüklü Görüntüleme Spektrometresi (MODIS-Moderate Resolution Imaging Spectroradiometer) uydu görüntülerine dayalıdır. Analizleri gerçekleştirmek için Yapay Sinir Ağları (NN-Neural Networks) algoritmaları kullanılmıştır. Amerika Birleşik Devletleri Jeolojik Araştırma sunucusundan 300 adet NDVI görüntüsü alınmıştır. Alınan bu görüntüler ArcGIS'de işlenmiştir. Ham verinin tanımlanan noktaları, Python programlama dili kullanılarak birkaç farklı işlemden geçirildikten sonra tahmin veri seti elde edilmiştir. Tahmin veri seti, eğitim seti, doğrulama seti ve test seti olmak üzere üç parçaya ayrılmıştır. Eğitim seti ağı eğitmek için kullanılmıştır. Ağı oluşturmak ve İstanbul'un Asya yakasındaki bitki örtüsünün gelecekteki halini haritalamak için yüzlerce eğitim noktası kullanılmıştır. Çalışma alanı, büyük veri problemini ele almak için birkaç görüntü paneline bölünmüştür. Tahmin işleminin performans doğruluğunu değerlendirmek için ölçüt olarak ortalama kare hatası yöntemi (MSE – Mean Square Error) kullanılmıştır. Kullanılan makine öğrenmesi algoritması ile coğrafi verilere dayalı tahminler başarıyla gerçekleştirilmiş ve yüksek performans doğruluğu elde edilmiştir. Sonuç olarak, makine öğrenmesi yönteminin gelecekteki bitki örtüsü haritasını oluşturmak için kullanılabileceği gösterilmiştir.

Anahtar Sözcükler

Makine Öğrenmesi, NDVI Zaman Serisi, Bitki Örtüsü Tahmini

1. Giriş

Bitki örtüsünün toplum ve çevre açısından sayısız avantajları vardır. Yeryüzünü kaplayan bitki örtüsünün havanın arındırılması, ortam sıcaklığının düşürülmesi, yağmur sularına tampon vazifesi görmesi, biyolojik çeşitliliğin artması, ortam gürültülerinin azaltılması, refah hissini artırması, sosyal etkileşimin artması, erozyonun yıkıcı etkilerini azaltmasının yanında iyileştirici etkisi ile erozyondan korunma sağlaması gibi birçok faydası bulunmaktadır. Bunun yanında bitki örtüsünün iklim şartlarına da olumlu etkileri vardır ve toplum açısından yeşil bir çevre, gri bir çevreye kıyasla daha huzur vericidir (Sempergreen 2019).

Bitki örtüsü yoğunluk dalgalanmaları, doğal sistemin kapasite ve durumu üzerinde çok büyük etkisi olan hayati bir değişkendir. Bitki örtüsündeki yoğunluk dalgalanmalarının sürdürülebilir gıdanın sağlanması, insan refahı, tatlı su, atmosfer ve iklim sistemi üzerinde uzun vadeli etkileri olabilmektedir. (Stepchenko ve Chizhov 2015).

Bitki örtüsü yoğunluğu hakkında doğru öngörülen bilgilerin sağlanması, kısıtlı kaynakların doğru bir şekilde kullanımı için insanları teşvik eden sistemleri geliştirir (Ziervogel ve ark. 2010). Tam doğru bitki örtüsü bilgileri yaklaşan tehlikeli durumlarla ilgili erken uyarı verecek ve tehlikenin bertaraf edilebilmesi için gerekli önlemlerin alınmasına fırsat sunacaktır (Burchfield and Gilligan 2018). Ek olarak, bitki örtüsünün geliştirilmesi, çeşitliliğinin artırılması ve verimliliği için oluşturulan hareket planlarının kontrol edilebilme imkânı da elde edilecektir (Hira and Deshpande 2015; Shrestha et al. 2017).

Son zamanlarda, zamansal değişimi yüksek kalitede olan uydu görüntülerinin erişilebilirliğinin artması ile bitki örtüsü yoğunluğu tahmininin doğruluğunun artırılması aynı anlama gelmektedir (Hira ve Deshpande 2015; Udelhoven 2012). Uzun organizasyonlarının uydu görüntüsü verilerinin dağıtımında uyguladığı serbest strateji, bitki örtüsünü öngörmek için gerekli uydu verilerinin yeterli kadar mevcut olmasını sağlamıştır. Sık periyodlarla alınan uydu görüntüleri, dünyadaki devasa coğrafi bölgelerin istenilen zaman aralıklarında hassas ve hızlı bir şekilde analiz edilebilirliğini mümkün kılmaktadır (Verbesselt, Zeileis, and Herold 2012). Bitki örtüsünü izleme sistemleri, bitki örtüsünün mevsimsel büyümesi hakkında doğru bilgi sağlamak için uydu görüntülerinden mekansal ve tarihsel veri kümelerini çıkarmaktadır (Rembold ve ark. 2015). Orta Çözünürlüklü Görüntüleme Spektrometresi (MODIS-Moderate Resolution Imaging Spectroradiometer) ve Terra sensöründen elde edilen uydu görüntüleri bitki örtüsü analizi için yüksek imkân sağlamaktadır. Normalleştirilmiş fark bitki örtüsü indeksi (NDVI-Normalized Difference Vegetation Index) MODIS verisinden yararlanılarak hücre boyutu 250 metre ve 16 gün aralıklarla oluşturulmuş bir katmandır (Colditz, Ressler ve

* Sorumlu Yazar: Tel: (0370)4332021-3883 Faks: (0370)4333290

E-posta: s.jayyab@hotmail.com (Abujayyab S.), ismail.karas@karabuk.edu.tr, (Karas İ.) emrullahdemiral@karabuk.edu.tr (Demiral E.)

Bonilla-Moheno 2015). NDVI, spektral uzaktan algılama indeksleri arasında en önemli indekstir. NDVI, aritmetik olarak yeşillik değerlerini gösterir (Reddy ve Prasad 2018; Wang ve diğerleri 2016). NDVI normalleştirilmiş değerleri -1 ile +1 sınırları arasındadır.

NDVI Hesaplama formülü:

$$NDVI = (NIR - R) / (NIR + R)$$

(NIR): Yakın Kızılötesi Spektral yansımaya (near infrared spectral reflectance)

(R) : Kırmızı Spektral Yansımaya (red spectral reflectance)

NDVI görüntülerde, en yüksek değerler yeşil malzemedeki yoğunluğu temsil eder. Olumsuz değerler; bulutlar, kar, çorak topraklar, yapay malzemeler, kentsel alanlar veya su gibi bitki örtüsü olmayan alanları gösterir. NDVI yıllık profilden elde edilen bilgiler şüphesiz çalışma alanına ait bitki örtüsü yoğunluğu durumunu tanımlar. Yıllık profil, örneğin su ve güneş ışığı gibi uygun koşullara bağlı olarak bitki örtüsünün yılın hangi zamanlarında en yüksek seviyeye ulaştığını gösterir. Bunun yanında su kıtlığı, yaprak dökülmesi, hasat, bitki ölümü ve sıcaklık gibi nedenlerden dolayı bitki örtüsünün en düşük seviyeye ulaştığı zaman dilimlerini de göstermektedir. NDVI zaman serileri, bitki örtüsü istikrarlılığı hakkında üstün kanıtlar sunmaktadır (Djeddaoui ve ark. 2017; Udelhoven 2012).

NDVI zaman serisi analizi, çok sayıda istatistiksel yaklaşım kullanılarak gerçekleştirilmiştir. Bütünleşik otoregresif hareketli ortalama (ARIMA- Autoregressive Integrated Moving Average) tekniği, tek değişkenli NDVI zaman serisi tahmini için sıklıkla kullanılır (Stepchenko ve Chizhov 2015). Öte yandan, bu yaklaşımlar, tahmin edilen zaman serileri doğrusal verilere sahiptir, hipotezine dayanarak oluşturulmuş yaklaşımlardır. NDVI zaman serisi tahmininde, verilerin doğrusal olmaması nedeniyle zorluk artar. Daha önce yapılan birkaç araştırma, doğrusal olmayan makine öğrenmesi yaklaşımlarının klasik zaman serileri tekniklerine kıyasla daha fazla doğruluk elde ettiğini önermektedir (Li, Wang ve Li 2015; Menezes ve Barreto 2008; Reddy ve Prasad 2018; Udelhoven 2012). Sonuç olarak, sinir ağları tekniği, klasik istatistiksel tahmin yöntemleri yerine NDVI görüntülerine dayanan zaman serisi tahmininde yeni bir alternatif olarak uygulanmıştır (Menezes ve Barreto 2008; Stepchenko 2016).

NDVI zaman serilerine dayalı mekânsal tahminleri gerçekleştirmek amacıyla bilim adamları bir dizi yöntem önermektedir. Nay, uzaktan algılanan verilere dayalı bitki örtüsü sağlığı yaklaşımı için makine öğrenmesini önermiştir (Nay, Burchfield ve Gilligan 2018). Reddy, NDVI verilerini kullanarak bitki örtüsü değişikliklerini tahmin etmek için uzun kısa vadeli hafıza ağları (LSTM- Long Short Term Memory) yönteminden yararlanmıştır (Reddy ve Prasad 2018). Stepchenko ve arkadaşları, NDVI' yı kısa vadeli tahmin etmeye yönelik olarak yaptıkları çalışmanın çeşitli adımlarında tekrarlayan sinir ağlarını (RRN-Recurent Neural Network) uygulamıştır (Stepchenko ve Chizhov 2015).

Yine de, doğru NDVI zaman serisi tahmini için çeşitli zorluklarla karşı karşıya kalınmaktadır. Temel sorunlardan bir tanesi, bitki örtüsü haritası üretim sürecinin geniş kapsamlı işlemlerden oluşması ve bazı aşamalarda sorunlu coğrafi işlem fonksiyonlarının kullanılıyor olmasıdır. Bir başka zorlukta, analiz yapacak kişinin mekânsal veri ve makine öğrenmesi ile ilgili çeşitli araçları ve yaklaşımları kavramasının gerekliliğidir. Ayrıca, bilgisayar uzmanları dışındakiler sinir ağlarını coğrafi mekânsal alana uygulamakta zorlanmaktadır. Tüm bunların yanı sıra kullanıcı, güncelliğini yitirmiş uygulamalar, sayısız programlama hatası veya coğrafi verinin ön işlemleri aşamasında yapılan hatalar gibi durumlar ile karşı karşıya kalabilir. Büyük veri problemi, Yapay sinir ağı için eğitim setinin oluşturulması, mekânsal verilerden modellerin üretilmesi gibi zorluklarda mevcuttur.

Bu çalışmada, ArcGIS ve Matlab ortamında otomatik tahmin araçları geliştirilmektedir. Bu araçlar, NDVI uydu görüntüleri üzerinde çeşitli aşamaları tamamlayarak ve yapay sinir ağlarını kullanarak bitki örtüsü tahminini gerçekleştirmektedir. Bu çalışmanın amacı, kullanıcı dostu bir tahmin aracı ile İstanbul'un Asya yakasındaki bitki örtüsünü öngörmektir.

2. Tahmin Araçlarının Geliştirilmesi

Geliştirilen tahmin araçları gelecekteki bitki örtüsünün haritalandırılması için olanak sağlar. Tahmin araçları, NDVI zaman serisinden bilgiyi çıkartmak için önce zaman-sonra konum yaklaşımı ve piksel tabanlı yöntem kullanmaktadır. Geliştirilen araçlar, bitki örtüsünü 16 günlük aralıklarla ve 250 metrelik hücre boyutunda tahmin etmektedir. Bu araçlar, ArcGIS, Python ve Matlab yazılımlarını temel düzeyde kullanabilenlere yönelik olarak tasarlanmıştır. Araçlar ve komut dosyaları Github web sunucusu üzerinden (<https://github.com/SohaibAbujayyab>) yayınlanmıştır. Araçlar, USGS'nin (United States Geological Survey) sunucusundan indirilen MODIS/Terra bitki örtüsü uydu görüntülerini kullanmaktadır (<https://search.earthdata.nasa.gov/data>). MODIS görüntüleri tüm dünyayı kapsamaktadır. Tarihsel sıralı MODIS görüntülerinden elde edilen zaman serilerini eğitmek ve test etmek için sinir ağları kullanılmıştır. Şekil 1'de araçların coğrafi işlemler iş akışı şeması gösterilmiştir. İş akışı şeması A'dan I'ya 9 aşamadan oluşmaktadır ve her bir aşama için bir araç geliştirilmiştir. İş akışındaki bazı araçlar ardışık olarak uygulanır. Her aşamanın çıktısı, bir sonraki aşamaya ait girdiyi temsil eder. Geriye kalan işlemler aynı anda yapılabilir. Geriye kalan işlemler aynı anda yapılabilir.

A aşamasında HDF'den NDVI elde edilir. Bu aşamadaki çalışma genellikle yüzlerce görüntüden oluşur ve araç piksel tabanlıdır. Sonuç olarak, coğrafi işlemlerin gerçekleştirilmesi yorucu ve zaman alıcı olacaktır. Bu aşamanın hedefi, USGS web sitesinden indirilebilen MODIS-HDF dosya kombinasyonundan NDVI görüntülerini çıkarmayı sistematik hale getirmektir. Çok sayıda HDF dosyasından dolayı yükselen bellek tüketimini azaltmak için "Input" klasörü içerisindeki

x_{norm} =normalleştirilmiş değerler, x_{min} = x_i nin minimum değeri, x_{max} = x_i nin maksimum değeri

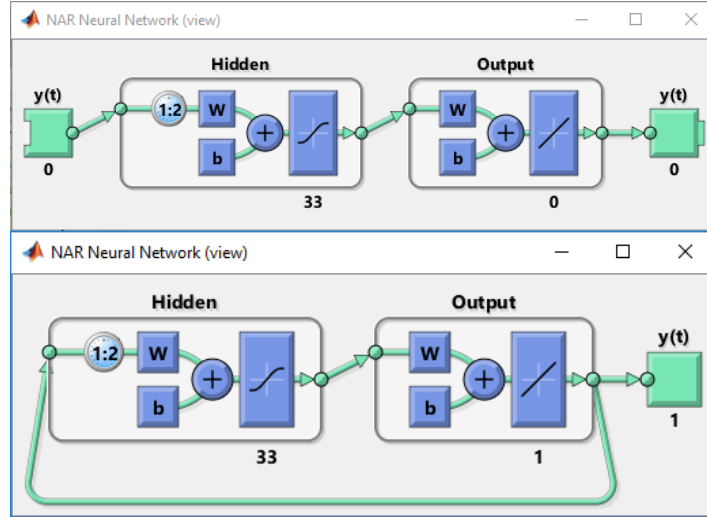
```
1 Begin
2
3 Make list of input tiles of Shapefiles(SHP) files
4 Find the size of list of SHP files
5
6 for each file out of points tiles SHP files
7   Read SHP of poits tiles
8   for each pixel point (Time-Series)
9     constructing target data
10  end
11
12 for each Time-Series
13   Defining training function = 'trainlm'
14   Create a Nonlinear Autoregressive Network
15   Prepare the Data for Training and Simulation
16   Setup Division of Data for Training, Validation, Testing
17   Train the Network
18   Test the Network
19   creating Closed Loop Network to do multi-step prediction.
20   Multi-step Prediction
21   store performance values
22 end
23
24 Generating new matrix to store predicted NDVI values
25
26 for each record of points in predicted matrix
27   Copy predicted NDVI values to the new matrix
28 end
29
30 for each record of points in predicted matrix
31   Add X and Y coordinates of point to new NDVI matrix from original SHP
32 end
33 Store predicted NDVI matrix to xls file
34 end
```

Şekil 2: Tahmin aşamasının sözde kodu

F Aşaması Matlab bitki örtüsü tahmini. Bu aşama tüm iş akışının kalbini temsil eder. Bu araçta yapay sinir ağı, NDVI zaman serisini eğitmek, tahmin ağı inşa etmek ve bu ağı kullanarak gelecekteki bitki örtüsünü tahmin etmek için uygulanmıştır. Matlab programı sadece bu aşamada kullanılmaktadır. Matlab'daki sağlam fonksiyonlar araştırmacıyı yapay sinir ağını uygulamaya teşvik etmektedir. Matlab kodu, Şekil 2'de sözde kod üzerinden kısaca açıklanmıştır. Matlab kodu, Shapefiles-Döşemeler verilerin (E aşamasında elde edilen veriler) import edilmesi ile başlar. Kod, programın grafik arayüzü ile giriş Shapefile-Döşemeler dosyasının seçimini kullanıcıya bırakır.

Bu aşama boyunca, Shapefiles-Döşemeler üzerinde yinelemeler çalışmaktadır. İlk döngü, Shapefiles-Döşemelerden zaman serisi veri kümesi oluşturmaya yöneliktir. Zaman serisindeki ikinci döngü, yapay sinir ağı modelini geliştirmek ve test etmek içindir. Ardından bitki örtüsünü tahmin eder. Her bir nokta için zaman serileri, eğitim seti, doğrulama seti ve test seti şeklinde üç bölüme ayrılmıştır. Yapay sinir ağının yapısı Şekil 3'te gösterilmiştir. Sinir ağının açılır pencereleri işlem sürelerini kısaltmak için devre dışı bırakılmıştır (net.trainParam.showWindow = 0). Nöron sayısı, eğitim algoritması ve ilerideki çoklu tahmin adımlarının sayısı tanımlanabilir. Üçüncü döngü, öngörülen bitki örtüsü değerlerini kopyalar ve yeni matrisinde saklar. Son döngü ise, her bir döşeme dosyası için koordinatların eşini import eder ve bunu yeni tahmin matrisinde saklar. Ek olarak, bu döngü, tahmin çıktı matrisindeki her bir zaman serisi için ortalama karesel hatayı (MSE) kaydeder. Son olarak, kod, her bir döşeme için bir tahmin matrisi oluşturur ve Excel dosyası şeklinde kaydeder.

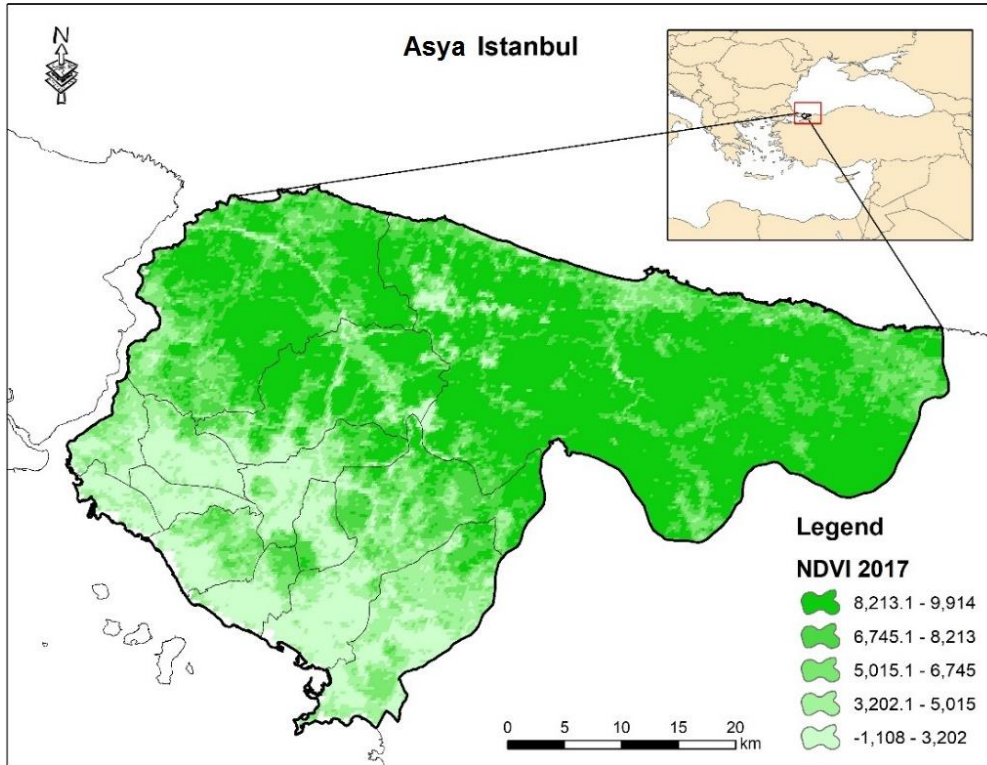
G aşaması, veri sonrası işlemler. Bu aşamada Matlab'da depolanan bitki örtüsü tahminlerine ait döşemeler Excel dosyası şeklinde import edilebilir. Araç Excel dosyaları üzerinde döngü oluşturur. Daha sonra onları noktalar katmanları olarak yerleştirir ve ayrı Shapefiles-döşemeleri olarak saklar. Kullanıcı burada dosya isimlendirme için (% satır içi değişken değiştirme%- %inline variable substitution%) kullanılmalıdır. Buradaki çıktı tahmin edilen bitki örtüsü verilerini içeren döşemeler için noktalar katmanlarıdır. H aşaması öngörülen noktaların birleştirilmiş döşemeleri. Bu aracın amacı, önceki aşamada elde edilen noktalar katmanlarını birleştirerek tek bir noktalar katmanı elde etmektir. Araç, öngörülen bitki örtüsü verilerini içeren tüm döşemeleri bir özellik sınıfında olacak şekilde birleştirir. I aşaması vektör veriyi raster veriye dönüştürür. Bu aşamada, noktalar tablosundan interpolasyon ile raster tablosu oluşturulur. İnterpolasyon yöntemi TopoToRaster'dır (PointElevation alt metodu). Kullanıcının bir veya birkaç interpolasyonu gerçekleştirmesini ve bunları raster tablosu olarak otomatikman kaydetmesini sağlamak için esnek bir araçtır. Çıktı olarak elde edilen raster veri çalışma alanında öngörülen bitki örtüsü yoğunluğunu temsil etmektedir.



Şekil 3: Yapay sinir ağı yapısı

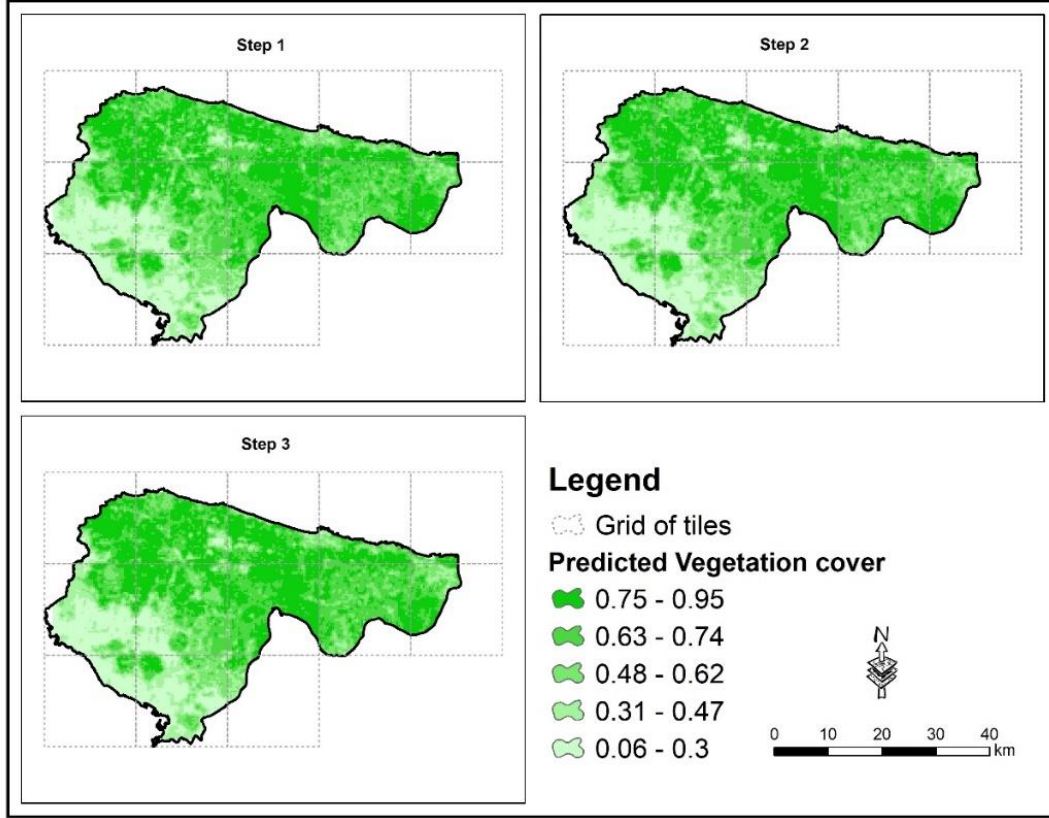
3. Tahmin Araçlarının Uygulaması

Bu bölümde, geliştirilen araçlar çalışma alanında analiz yapmak için çalıştırılmış ve uygulanmıştır. Coğrafi olarak, bu bölge, Türkiye'nin kuzeyindeki İstanbul ilinin Asya tarafında yer almaktadır. Çalışma alanı İstanbul Boğazı'nın doğusu ve Karadeniz'in güneyindedir. İstanbul'un Asya yakasının yeşil alanı Şekil 4'te gösterilmiştir. Bu alanın neredeyse %70'inden fazlası, analizi yapmak ve öngörülen haritaları oluşturmak için uygun olan yoğun bitki örtüsüne sahiptir. Ek olarak, öngörülen sonuçlar bu alandaki karar vericiler için çok değerli olacaktır. MODIS HDF dosyaları, %10'dan fazla bulut içeren görüntüler filtrelendikten sonra USGS sunucusundan alınmıştır. HDF dosyalarından 300 NDVI görüntüsü çıkarıldı. Araçlar, alan için noktalar tablosu oluşturmaktadır. Her nokta bir bitki örtüsü zaman serisini temsil etmektedir. İlgili alanda 35.029 nokta oluşturulmuştur. Araçlar hesaplama sürecini yönetmek için döşemeler sistemini uygulamıştır. Döşeme boyutu 17 km*17 km dir. Bu döşeme boyutuna göre çalışma alanı 13 veri bölümüne ayrılmıştır. Her bölüm ayrı ayrı temizlenmiş ve değerler normalleştirilmiş, sonra Matlab'a taşınmış ve yapay sinir ağı beslenmiştir. Döşeme sisteminin kullanılması, bu büyük miktardaki veriyi verimli bir şekilde işlemeye izin vermektedir.



Şekil 4: İlgili Alanının konumu

Ayrıca çalışma alanı kapsamındaki 35.029 zaman serisine dayanarak 35.029 ağ geliştirilmiştir. Geliştirilen ağlar eğitilmiş ve test edilmiştir. Ortalama performans hatası, ortalama kare hata ölçümüne göre %81 dir. Daha sonra, her bir zaman serisine ait gelecekteki bitki örtüsünü tahmin etmek için ağlar kullanılmaktadır. Öngörülen değerler tekrar ArcGIS'e taşınır ve gelecekteki bitki örtüsü haritaları üretilinceye kadar işlenir. Bu çalışmada, önce zaman-sonra konum yaklaşımı uygulanmıştır. Her bir pikselin geçmiş verilerine dayanarak, geliştirilen ağ karmaşık bilgiyi öğrenmeyi başardıktan sonra gelecekteki bitki örtüsünün yoğunluğunu tahmin etmektedir. Öngörülen veri döşemelerinin üç zaman aşamalı bitki örtüsü dağılımını Şekil 5'te gösterilmiştir.



Şekil 5: Öngörülen bitki örtüsü

3. Sonuç

Bitki örtüsü tahmini, son yıllarda önemli bir analiz alanı olarak karşımıza çıkmaktadır. Bitki örtüsü, gıda sistemlerinin dengelenmesini ve gıda güvenliğini önemli ölçüde etkiler. Doğru bitki örtüsü bilgileri, özellikle politika belirleyicileri için gelecekte anormal durumlara karşı erken uyarı vererek hazırlıklı olmalarına yardımcı olur. Öngörülen bitki örtüsü verileri hızla farkındalığı arttırmakta, insanlar ve doğal kaynaklar üzerindeki zararlı etkileri azaltmaktadır. Bu çalışmada, Türkiye'nin kuzey batısındaki İstanbul ilinin Asya yakasındaki bitki örtüsünü öngörmek amacıyla geliştirilen dokuz aracın iş akışı sunulmuştur. 300 Normalleştirilmiş Fark Vejetasyon İndeksi (NDVI) zaman serisi verisi, makine öğrenme tekniğine dayalı olarak analiz edilmiştir. NDVI verileri, Orta Çözünürlüklü Görüntüleme Spektrometre (MODIS) uydü görüntülerinden elde edilmiştir.

Araçlar, python programlama dilini kullanarak yapay sinir ağı veri setlerini oluşturmak için bitki örtüsü bilgilerinin tarihsel gözlemlerini toplar ve işler. Yapay sinir ağı modelleri oluşturmak için binlerce eğitim kaydı kullanılmıştır. Veri seti %70 eğitim seti, %15 doğrulama seti ve %15 test seti şeklinde ayrılmıştır. İlgili alanı, belleği yönetmek için bölümlere ayrılmıştır. Regresyon değerlendirme ölçütü olarak ortalama kare hatası (MSE) yaklaşımı kullanılmıştır. Ortalama kare hatası yaklaşımına dayalı ortalama performans başarıları %81 dir. Yapay sinir ağı prosedürü etkin bir şekilde bitki örtüsü tahminini gerçekleştirmiştir ve yüksek performans doğruluğu elde etmiştir. Özetlemek gerekirse, sonuçlar, makine öğrenmesinde yapay sinir ağı'nın potansiyel bitki örtüsü yoğunluğunu tahmin etme yeteneğini göstermektedir.

Teşekkür

Bu çalışma, 2221 - TÜBİTAK (Türkiye Bilimsel ve Teknolojik Araştırma Kurumu) Konuk veya Akademik İzinli (Sabbatical) Bilim İnsanı Destekleme Programı tarafından desteklenmiştir. Destekleri için borçluyuz.

Kaynaklar

- Colditz, Rene R., Rainer A. Ressler, and Martha Bonilla-Moheno. 2015. "Trends in 15-year modis ndvi time series for mexico." Pp. 1–4 in 2015 8th International Workshop on the Analysis of Multitemporal Remote Sensing Images (Multi-Temp). IEEE.
- Djeddaoui, Farid, Mohammed Chadli, Richard Gloaguen, Farid Djeddaoui, Mohammed Chadli, and Richard Gloaguen. 2017. "Desertification susceptibility mapping using logistic regression analysis in the djelfa area, algeria." *Remote Sensing* 9(10):1031.
- Hira, Swati and P. S. Deshpande. 2015. "Data analysis using multidimensional modeling, statistical analysis and data mining on agriculture parameters." *Procedia Computer Science* 54:431–39.
- Li, Deren, Shuliang Wang, and Deyi Li. 2015. "Spatial data mining."
- Menezes, José Maria P. and Guilherme A. Barreto. 2008. "Long-term time series prediction with the narx network: an empirical evaluation." *Neurocomputing* 71(16–18):3335–43.
- Nay John, Burchfield Emily and Jonathan Gilligan. 2018. "A machine-learning approach to forecasting remotely sensed vegetation health" *International Journal of Remote Sensing* 39(6):1800–1816.
- Reddy, D. Sushma and P. Rama Chandra Prasad. 2018. "Prediction of Vegetation Dynamics Using NDVI Time Series Data and LSTM." *Modeling Earth Systems and Environment* 4(1):409–19.
- Rembold, Felix, Michele Meroni, Ferdinando Urbano, Antoine Royer, Clement Atzberger, Guido Lemoine, Herman Eerens, and Dominique Haesen. 2015. "Remote Sensing Time Series Analysis for Crop Monitoring with the SPIRITS Software: New Functionalities and Use Examples." *Frontiers in Environmental Science* 3:46.
- Sempergreen. 2019. "Benefits of Green Ground Cover." Retrieved February 24, 2019 (<https://www.sempergreen.com/us/solutions/green-ground-covering/benefits-green-ground-cover>).
- Shrestha, Ranjay, Liping Di, Eugene G. Yu, Lingjun Kang, Yuan-zheng SHAO, and Yu-qi BAI. 2017. "Regression Model to Estimate Flood Impact on Corn Yield Using MODIS NDVI and USDA Cropland Data Layer." *Journal of Integrative Agriculture* 16(2):398–407.
- Stepchenko, Arthur. 2016. "NDVI Index Forecasting Using a Layer Recurrent Neural Network Coupled with Stepwise Regression and the PCA." Pp. 130–35 in.
- Stepchenko, Arthur and Jurij Chizhov. 2015. "NDVI Short-Term Forecasting Using Recurrent Neural Networks." *Environment. Technology. Resources. Proceedings of the International Scientific and Practical Conference* 3:180.
- Udelhoven, Thomas. 2012. "Long Term Data Fusion for a Dense Time Series Analysis with MODIS and Landsat Imagery in an Australian Savanna." *Journal of Applied Remote Sensing* 6(1):063512.
- Wang, Siyuan, Bojuan Yang, Qichun Yang, Linlin Lu, Xiaoyue Wang, and Yaoyao Peng. 2016. "Temporal Trends and Spatial Variability of Vegetation Phenology over the Northern Hemisphere during 1982-2012" edited by S. Joseph. *PLOS ONE* 11(6):e0157134.
- Verbesselt, Jan, Achim Zeileis, and Martin Herold. 2012. "Near Real-Time Disturbance Detection Using Satellite Image Time Series." *Remote Sensing of Environment* 123:98–108.
- Ziervogel, Gina, Peter Johnston, Margaret Matthew, and Pierre Mukheibir. 2010. "Using Climate Information for Supporting Climate Change Adaptation in Water Resource Management in South Africa." *Climatic Change* 103(3–4):537–54.