

Dinamik Bitki Örtüsü Tahmini Yapay Sinir Ağı Uygulaması: Düzce İli Örneği Üzerinde Çalışma

Sohaib K. M. Abujayyab^{1*}, İsmail Rakıp Karaş² ve Emrullah Demiral³

¹ Karabük Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 78050, Karabük (phone 00905314935668, e-mail s.jayyab@hotmail.com)

² Karabük Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 78050, Karabük (phone 00905325794273, e-mail ismail.karas@karabuk.edu.tr)

³ Karabük Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 78050, Karabük (phone 00905057035053, e-mail emrullahdemiral@karabuk.edu.tr)

Abstract: - Worldwide, vegetation cover functioning as the secure region for wild life, and natural water, air filter from pollution. Forecasting the vegetation dynamics assist the governments and managements to decrease the negative influence of vegetation dynamic fluctuations. In recent years, forecasting of precise vegetation dynamics become and highly important issue, due to rapid vegetation changings and the needs to protect this natural resource. The aim of this article is to forecasting the vegetation dynamics by applying neural networks (NN). Düzce region utilized as case study, which situated in the north west region of Turkey. Normalized difference vegetation index (NDVI) from Moderate Resolution Imaging Spectroradiometer (MODIS) were employed to create vegetation time series. From United States Geological Survey website, 300 NDVI interval data acquired and processed in ArcGIS software. The dataset of vegetation time series built based on required neural networks data structure. Spatiotemporal pixel based sampling strategy performed to forecast the vegetation dynamics. A number of geospatial data handling steps employed using Python and Matlab programing languages. Forecasting data separated to two subdivisions (training set, and testing set). Mean squared error (MSE) utilized as performance accuracy assessment metric. Neural networks effectively implemented using spatiotemporal data and achieve high testing accuracy. Consequences reveals the fitness of neural networks to forecast vegetation dynamics maps.

1. Giriş

Bitki örtüsü toplum ve çevre için sayısız fayda sunmaktadır. Bunların başında, biyolojik çeşitliliğin artması, yağmur sularının tutulması, heyelan ve erozyonun yıkıcı etkilerinin azaltılması, hava sıcaklıklarının dengelenmesi, havanın temizlenmesi, sosyal yaşam kalitesini arttırması, şehrin rahatsız edici gürültüsü ve gri görüntüsü yerine huzur verici ortam ve sesler sunması gelmektedir. Bitki örtüsü iklim şartlarının önemli bir parçasıdır (Sempergreen 2019). Bitki örtüsü miktarındaki değişimler, ekolojik sistem üzerinde önemli ölçüde etkin olan bir faktördür. Bitki örtüsü miktarındaki farklılıklar, iklim şartları, sosyal yaşam kalitesi, gıda oluşumunun sürdürülebilirliği ve tatlı su kaynakları üzerinde uzun vadeli etkilere sebep olabilmektedir. (Stepchenko ve Chizhov 2015). Bitki örtüsü miktarının doğru bir şekilde tahmin edilmesi, insanları, kısıtlı kaynakların etkin kullanımı için teşvik eder (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 (Nay, Burchfield ve Gilligan 2018).

Tüm bunlara ek olarak, bitki örtüsü tahmini sayesinde, bitki örtüsünün geliştirilmesi, çeşitliliğinin arttırılması ve sürekliliği için oluşturulacak hareket planlarının kontrol edilebilme imkânı da elde edilecektir (Hira and Deshpande 2015; Shrestha et al. 2017).

Son yıllarda, mekânsal-zamansal uydu görüntülerin erişilebilir olması ile birlikte bitki örtüsü miktarının tahmin edilmesi üzerine yapılan çalışmalarda artmıştır (Hira ve Deshpande 2015; Udelhoven 2012). Uzun aralıklarda uydu görüntülerinin dağıtımını ile ilgili olarak açık erişim politikası uygulamaktadır. Bu sayede bitki örtüsü miktarını tahmin etmek için gerekli olan işlenmemiş veriye kolaylıkla ve yeterli düzeyde erişilebilmektedir. Sık periyodlarla alınan uydu görüntüleri kullanılarak yeryüzünde çok büyük alana yayılmış bölgeler, ihtiyaç duyulandan çok daha ileri ki zaman aralıkları için doğru ve hızlı bir şekilde analiz edilebilmektedir (Verbesselt, Zeileis, and Herold 2012). Bitki örtüsü miktarı izleme programları, mekânsal-zamansal uydu görüntülerinden sinir ağları verisini çıkartmaktadır. Genellikle, elde edilen bu veri, bitki örtüsü miktarındaki mevsimsel büyümenin tarihsel süreçteki değişimi ile ilgili bilgiyi sunmaktadır (Rembold ve ark. 2015). Orta Çözünürlüklü Görüntüleme Spektrometre (MODIS-Moderate Resolution Imaging Spectroradiometer) uydusu ve Terra sensörü tarafından sağlanan uydu görüntüleri bitki örtüsü miktarı ile ilgili araştırmalar için sıra dışı fırsatlar sunmaktadır. Normalleştirilmiş fark bitki örtüsü indeksi (NDVI-Normalized Difference Vegetation Index) (MOD13Q1) bir Coğrafi Bilgi Sistemi (CBS) katmanıdır. Bu katman, 250 m² alana sahip hücre boyutu ve 16 gün aralıkla kaydedilmiş görüntüler içeren MODIS verilerinin kombinasyonlarından oluşturulmaktadır (Colditz, Ressler ve Bonilla-Moheno 2015). NDVI, spektral uydu görüntü indekslerinin en önemlilerinden biridir. NDVI değerleri, her bir pikseldeki yeşil kütlelerin dağılımını sayısal olarak gösterir (Reddy ve Prasad 2018; Wang ve diğerleri 2016). NDVI görüntülerde, en yüksek değerler yeşil malzemedeki yoğunluğu temsil eder. Düşük değerler; bulutlar, kar, çorak topraklar, yapay malzemeler, kentsel alanlar veya su gibi bitki örtüsü olmayan alanları gösterir. NDVI yıllık profilleri bitki örtüsü yoğunluk miktarını açıkça ifade eder. NDVI zaman serileri bitki örtüsü miktarının en yoğun ve en düşük olduğu dönemleri gösterir. 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 sürekliliği hakkında açık ve güçlü deliller 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 kullanılmaktadır (Stepchenko ve Chizhov 2015). Ancak bu yaklaşımlar, doğrusal verilere sahip öngörülen zaman serileri hipotezine dayalı olarak oluşturulmuştur. NDVI zaman serilerinde verilerin doğrusal olmaması nedeniyle seriyi tahmin etmek çok daha güçtür. Literatürde yer alan çalışmalardan birkaçında, doğrusal olmayan makine öğrenmesi yaklaşımlarının, klasik istatistiksel zaman serileri tahmin yöntemlerine kıyasla daha fazla doğruluk elde ettiği ileri sürülmektedir (Li, Wang ve Li 2015; Menezes ve Barreto 2008; Reddy ve Prasad 2018; Udelhoven 2012). Sonuç olarak, NDVI görüntülerine dayanan zaman serisi tahmininde, makine öğrenmesi ve YSA (Yapay Sinir Ağları), klasik istatistiksel tahmin yöntemleri yerine yeni bir alternatif olarak uygulanabilmektedir (Menezes ve Barreto 2008; Stepchenko 2016). Araştırmacılar, NDVI zaman serilerine dayalı mekânsal tahminleri gerçekleştirmek için birçok yöntem önermektedir. Reddy ve Prasad, NDVI verilerini kullanarak bitki örtüsü değişikliklerini tahmin etmek için uzun kısa vadeli hafıza ağları (LSTM- Long Short Term Memory) yönteminden yararlanmışlardır (Reddy ve Prasad 2018). Nay ve arkadaşları, uydu görüntüleri üzerinde çalışarak bitki sağlığı seviyesini tahmin etmek için makine öğrenmesini önermektedir (Nay, Burchfield ve Gilligan 2018). Stepchenko ve arkadaşları, NDVI' yı kısa vadeli tahmin etmeye yönelik

olarak yaptıkları çalışmanın çeşitli adımlarında tekrarlayan sinir ağlarını (RRN-Recurrent Neural Network) uygulamıştır (Stepchenko ve Chizhov 2015).

Yine de, doğru NDVI zaman serisi tahmini için çeşitli zorluklarla karşı karşıya kalınmaktadır. Temel sorunlardan bir tanesi, öngörülen bitki örtüsü haritasını üretim sürecinin geniş kapsamlı işlemlerden oluşması ve bazı aşamalarda uzun ve karmaşık coğrafi işlem fonksiyonlarının yerine getirilme zorunluluğunun olmasıdır. Bir başka zorluk ise, analiz yapacak kişinin mekânsal veri ve makine öğrenmesi ile ilgili çeşitli araçları ve yaklaşımları kavramasının gerekliliğidir. Ayrıca, bilgisayar bilimleri alanına uzak kişiler, mekânsal veri kullanılarak YSA uygulamaları geliştirmekte zorlanmaktadırlar. Tüm bunların yanı sıra kullanıcı, güncelliğini yitirmiş uygulamalar, sayısız programlama hatası veya mekânsal verinin birçok ön işlemde geçirilmesi aşamalarında yapılan hatalar gibi durumlar ile karşı karşıya kalabilmektedir. Büyük veri problemi, YSA için eğitim setinin oluşturulması veya mekânsal verilerden modellerin üretilmesi gibi zorluklarda mevcuttur.

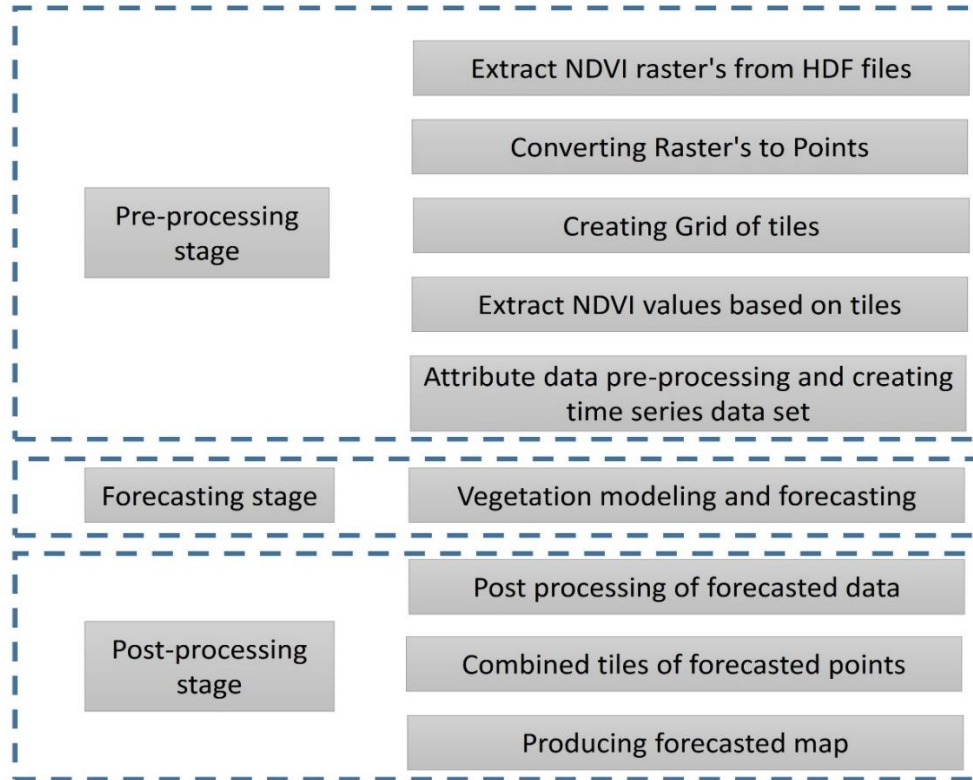
Bu çalışmanın amacı, kullanıcı dostu bir tahmin aracı ile Düzce ili örneği üzerinde bitki örtüsü dinamiklerini tahmin etmektir. ArcGIS ve Matlab ortamında otomatik tahmin araçları geliştirilmiştir. Bu araçlar, NDVI uydu görüntüleri üzerinde çeşitli bazı aşamaların gerçekleştirilmesini sağlamaktadır. Makine öğrenmesi ile bitki örtüsü dinamiklerinin tahminini gerçekleştirilmiştir.

2. Yöntem

Bu bölümde, çalışmada kullanılan yöntemler ve ara işlemler açıklanmaktadır. Geliştirilen tahmin fonksiyonları, gelecekteki bitki örtüsü dinamiklerini haritalamak için bir platform sağlamaktadır. Tahmin fonksiyonları, NDVI zaman serilerinden bilgi çıkarımı için “önce zaman-sonra konum” yaklaşımı ve piksel tabanlı yöntemler içermektedir. Geliştirilen fonksiyonlar bitki örtüsü yoğunluğunu 250 m² hücre boyutlarında ve 16 günlük periyodlarla tahmin etmektedir. Fonksiyonlar Matlab ve ArcGIS-Python ortamlarında son kullanıcıların kolaylıkla kullanabileceği şekilde tasarlanmıştır. USGS (United States Geological Survey - <https://search.earthdata.nasa.gov/data>) sunucusundan indirilen MODIS/Terra bitki örtüsü uydu görüntüleri kullanılmıştır. Dünyanın herhangi bir yerine ait MODIS görüntüsüne ulaşmak mümkündür. MODIS görüntüleri tüm dünyayı kapsamaktadır. Kronolojik olarak, kayıt tarihine göre sıralı MODIS görüntülerinden elde edilen zaman serileri, YSA için eğitim ve test veri seti olarak kullanılmıştır. Şekil 1’de iş akış şeması verilmiştir. İş akış şeması dokuz alt araç içermektedir. İş akış şemasında yer alan fonksiyonların çoğu ardışık olarak uygulanmaktadır. Her bir aşamanın çıktısı olarak elde edilen veri bir sonraki aşamanın girdi olarak kullanılmaktadır. Geriye kalan diğer işlemleri aynı anda gerçekleştirmek mümkündür.

A aşamasında HDF’den NDVI elde edilir. Bu aşamada genellikle yüzlerce görüntü üzerinde çalışılmaktadır ve kullanılan fonksiyon piksel tabanlı olarak işlem yapmaktadır. USGS web sitesinden indirilen MODIS-HDF dosyaları işlenerek NDVI görüntüler elde edilmektedir. Çok sayıda HDF dosyasının işlenmesi gerekmektedir. HDF görüntü dosyaları bellekte yüksek yer kaplamaktadır. Bu sebepten ötürü tek seferde tüm dosyaların işlenmesi zorlaşmaktadır. Sonuç olarak, yorucu ve zaman alıcı bir süreç ortaya çıkmaktadır. HDF dosyaları “Input” klasörü içerisine kaydedilmektedir. Bu aşamada geliştirilen araç ile yüksek bellek tüketimini azaltmak için Input klasörü içerisinde bulunan HDF dosyaları tek tek Import edilerek işlenmektedir. Çalışma alanı, 250 m² alana sahip birçok hücre içermektedir. Her bir hücreye ait 16 gün aralıklarla kaydedilmiş birçok HDF görüntüleri mevcuttur. Bu tarih aralıklarının her biri için ayrı ayrı NDVI görüntüleri oluşturulur. Çalışma alanı birçok hücre içerdiğinden dolayı öncelikle her bir hücre için elde edilen

NDVI görüntüleri geçici olarak “in_memory” klasöründe saklanır. Çalışma alanı içerisinde yer alan tüm hücreler için NDVI görüntüler çıkartıldıktan sonra birleştirilerek ilgili tarih için tek bir NDVI görüntü elde edilir ve bu görüntü “target” klasörüne kaydedilir. Bu işlem tüm tarih aralıkları için tekrarlanır. Bu işlemler sonucunda, her bir tarih aralığı için 250 m2 hücre boyutuna sahip birçok HDF görüntüsünden oluşan çalışma alanına ait maskelenmiş NDVI görüntüler elde edilmiş olur. Sonuç olarak, herhangi bir tarih için çalışma alanı birçok hücreden meydana gelmektedir. Bu aşama sonucunda hücreler birleştirilerek, her bir tarih için ayrı ayrı maskelenmiş NDVI görüntüler elde edilmektedir.



Şekil 1: İş Akış Şeması

B aşamasında raster veri, vektör veriye dönüştürülür. Bir görüntüdeki her bir piksel için bir değer üretilir ve tablo olarak kaydedilir. Tablonun boyutları ile görüntünün piksel çözünürlüğü aynıdır. Her bir piksele karşılık bir nokta karşılık gelmektedir. Noktalar tablosu, ilerleyen aşamalarda NDVI zaman serilerinin çıkarımı, YSA eğitim ve test veri setlerinin oluşturulması aşamasında kullanılacaktır. Bu araç ile çalışma alanı içerisindeki herhangi bir raster katmanı, nokta katmanına dönüştürür. Araç, pikselleri somutlaştırarak noktalar tablosuna dönüştürür.

C aşamasında özdeş kare alanlara bölme işlemi gerçekleştirilir. Görüntü bu aşamada özdeş kare parçalara ayrılır. Her bir kare alan döşeme olarak isimlendirilmiştir. Aracın hedefi bilgisayarın CPU iş yükünü bölmek ve bütünün eş parçalarının çoklu işleme veya paralel programlamaya elverişli hale getirilmesini sağlamaktır. Bu sayede verilerin işlenmesi süreci kısılacaktır. Bunun yanında verileri döşeme kümelerine ayırarak, düşük yeterlilikteki cihazlarda bellek tüketimi sorunundan kurtarmaktadır.

D aşamasında döşemelere ait noktalar için NDVI değerleri hesaplanır. Bu işlev, işlem belleğini yönetmek için B ve C aşamalarını kullanır. Bu aşamada öncelikle, B aşamasında elde edilen noktalar tablosu parçalara bölünmektedir. Her bir parça aynı boyutta ve kare

alana karşılık gelmektedir. Bu işlem için Arcpy kütüphanesindeki SearchCursor işlevi kullanılmıştır. C aşamasında oluşturulan her bir döşeme ile ilişkili noktalar tabloları elde edilmektedir. Daha sonra bir döşemeye ait noktalar tablosunda yer alan her bir değere karşılık NDVI nitelik bilgisi çıkartılır ve yeni bir tablo şeklinde saklanır. Bu işlem bir NDVI görüntüye ait tüm döşemeler için yinelenir ve NDVI nitelik tablosu oluşturulur. Bu aşamanın çıktısı olarak A aşamasında üretilen NDVI görüntü sayısı ile aynı sayıda NDVI nitelik tablosu elde edilmektedir. Çıktı verileri ESRI-Shapefile dosya formatındadır. Matlab fonksiyonlarını kullanabilmek için çıktının bu formatta olması gerekmektedir.

E Aşamasında veriler ön işlemden geçirilir. Öncelikle bu araç veri setlerinden aykırı veya eksik bilgi içeren noktaları temizler. Giriş verileri, D aşamasında üretilen NDVI nitelik bilgisini içeren tablo verisidir. Bu araç, SQL sözdizimini oluşturmak için giriş verilerine ait tablo alanları üzerinde yinelenir. Ardından, aykırı veya eksik satırlar bulunur ve temizlenir. Arcpy kütüphanesinde (DeleteFeatures_management) işlevi, istenmeyen kayıtları giriş noktalarından kaldırmak için kullanılır. Bu araç, çalışma alanını belirlemesi ve işlenecek alanları seçmesi için kullanıcıya izin verir. Kullanıcının, orijinal zorunlu alanlar dışında kalan diğer ilişkisiz alanları seçmekten kaçınması gerekmektedir. Seçilen her bir dosyadaki NDVI sayısal değerleri 0 ile + 1 arasında normalleşir. Normalleştirme işlemi için Denklem 1'de verilen formül kullanılır. Mekânsal verileri ArcGIS'ten Matlab ortamına aktarmak için çıktının ESRI-Shapefile formatında saklanması gerekmektedir. Bu aşama sonucunda A aşamasında üretilen her bir NDVI görüntüye karşılık gelecek şekilde aynı sayıda Shapefile formatında dosyalar oluşturulmaktadır.

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

(1)


Denklem 1'de verilen NIR, Near Infrared Spectral Reflectance (Yakın Kızılötesi Spektral Yansıma) değerini, R ise, Red Spectral Reflectance (Kırmızı Spektral Yansıma) değerini ifade etmektedir.

F Aşaması Matlab yardımıyla bitki örtüsü tahmini. Bu aşama tüm iş akışının kalbini temsil eder. Bu aşamada 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, E aşamasında üretilen Shapefile dosyalarının Import edilmesi ile başlar. Kod, programın grafik arayüzü ile giriş için gerekli Shapefile dosyalarının seçimini kullanıcıya bırakır.

Bu aşama boyunca, Shapefile dosyaları tek tek işlenir. İlk olarak, Shapefile dosyalarındaki her bir nokta için zaman serisi veri kümeleri çıkartılır. Bu işlem tüm noktalar için tekrarlanır. Burada, her bir noktanın bir piksele karşılık geldiğini hatırlayalım. Bu işlem sonucunda elde edilen zaman serileri yapay sinir ağı modelini geliştirmek ve test etmek için kullanılır. Her bir nokta için zaman serileri, eğitim veri seti ve test veri seti şeklinde iki bölüme ayrılmıştır. Oluşturulan yapay sinir ağı modeli gelecekteki bitki örtüsünü tahmin eder. Sinir ağının Matlab arayüzünde bulunan açılır pencereleri işlem sürelerini kısaltmak için devre dışı bırakılmıştır (net.trainParam.showWindow = 0). Nöron sayısı, eğitim algoritması ve ilerideki çoklu tahmin adımlarının sayısı kullanıcı tarafından tanımlanabilir. Her bir nokta için öngörülen yeni bitki örtüsü değerleri kopyalanır ve yeni bir matriste saklanır. Daha sonra elde edilen matristeki tahmin değerlerinin her birine ait x, y koordinatları eklenerek yeni bir matris oluşturulur. Ek olarak, tahmin çıktı matrisindeki her bir zaman serisi için ortalama karesel hata (MSE-Mean Square Error) kaydedilmektedir. Son olarak, oluşturulan tahmin matrislerinin her biri ayrı ayrı Excel dosya formatında kaydedilmektedir.

G aşaması, veri sonrası işlemler. Bu aşamada Matlab'da depolanan bitki örtüsü tahminlerine ait matrisler Excel dosyası şeklinde Import edilebilir. Araç Excel dosyaları üzerinde döngü oluşturur. Daha sonra onları noktalar katmanları olarak yerleştirir ve ayrı birer Shapefile dosyaları olarak kaydeder. Kullanıcı burada dosya isimlendirme için (% satır içi değişken değiştirme%- %inline variable substitution%) kullanılmalıdır. Buradaki çıktı tahmin edilen bitki örtüsü verilerini içeren matrisler 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 matris içerisindeki noktaları bir özellik sınıfında olacak şekilde birleştirir. İlk aşamadan bu yana bir piksel için oluşturulan tahmin değerleri, bu aşamada birleştirilerek, bir piksel için üretilen tahmin sayısı kadar yeni dosya oluşturulmaktadır.

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.

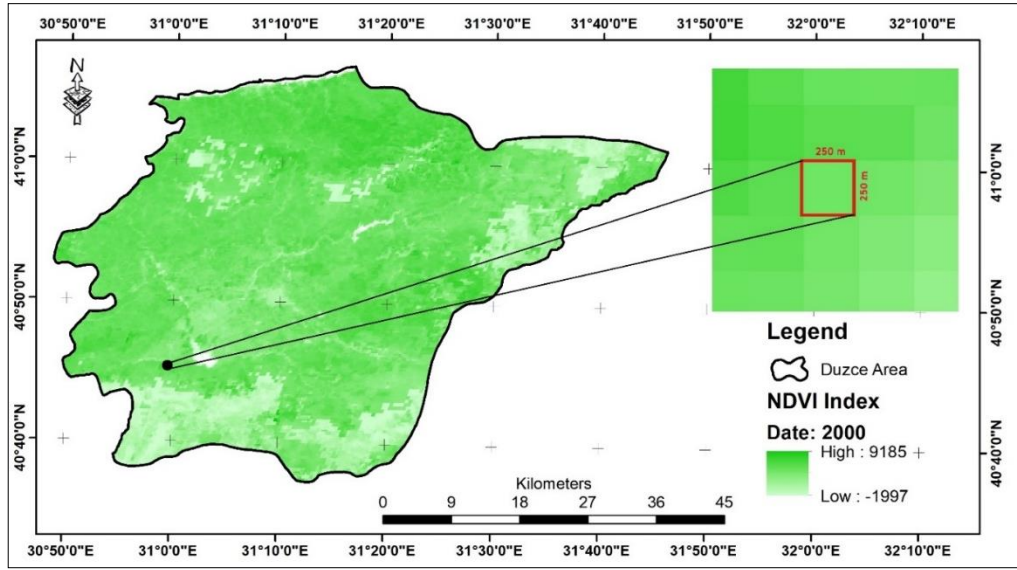


Şekil 2: Çalışma Alanı

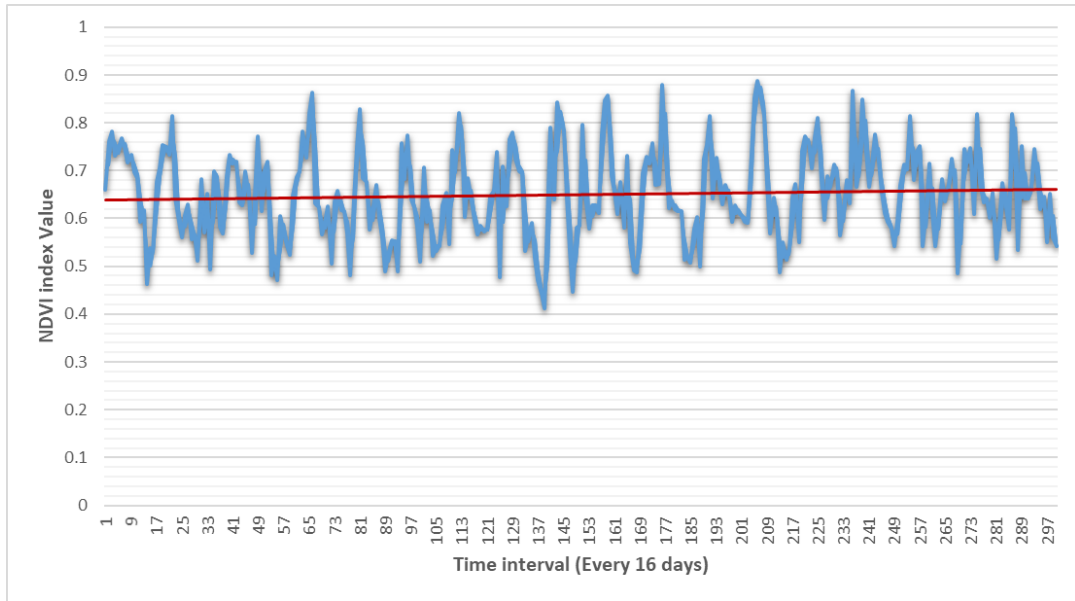
3. Çalışma Alanı Üzerinde Uygulama

Bu bölümde, geliştirilen araçlar çalışma alanında analiz yapmak için çalıştırılmış ve uygulanmıştır. Çalışma alanı olarak belirlenen bölge, coğrafi olarak ülkemizin Batı Karadeniz bölgesinde yer alan Düzce ilimizdir. Şekil 2' gösterilen bu alanın neredeyse %60'ından fazlası, analizi yapmak ve öngörülen haritaları oluşturmak için uygun olan yoğun bitki örtüsüne sahiptir. Ayrıca, 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. İlgi alanında 40.241 nokta oluşturulmuştur. NDVI zaman serilerinden bilgi çıkarımı için “önce zaman-sonra konum” yaklaşımı uygulanmıştır.



Şekil 3: NDVI zaman serisi için örnek bir test pikseli konumu



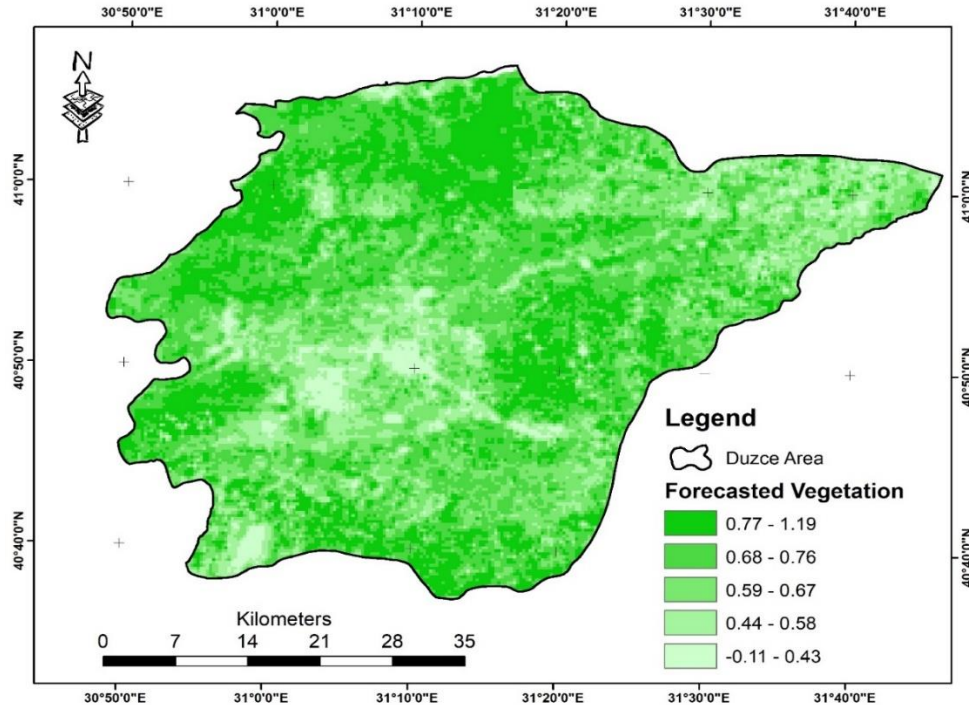
Şekil 4: 2000-2018 yıl aralığı için NDVI zaman serisi

Şekil 3'te çalışma alanı içerisinde test amaçlı rastgele seçilen bir piksel (250m * 250m) gösterilmiştir. NDVI veri seti, 16 gün aralıklarla kaydedilmiş yaklaşık son 19 yıla ait görüntülerden %10'dan daha fazla bulut içeren görüntüler çıkarıldıktan sonra geriye kalan 300 adet NDVI görüntüyü içermektedir. Bu görüntülerdeki her bir piksel için uydudan alındığı tarihe göre NDVI değerleri çıkarılmış ve bu değerler NDVI zaman serilerini oluşturmak için kullanılmıştır. NDVI zaman serileri şekil 4'te de görüleceği üzere mevsimlere bağlı olarak dalgalanmaktadır. Kış aylarında kar yağması ile birlikte görüntüde bulunan yeşil pikseller yerini beyaza bırakacağı için o piksele ait NDVI değeri küçülmektedir. Baharın gelmesi ile birlikte bitki örtüsünün gerçek yoğunluğu ortaya

çıkılmaktadır. Maksimum NDVI değerleri Mayıs ve Ağustos ayları arasında gözlemlenmektedir. Çalışma alanı için NDVI değerlerindeki değişikliklerin 0,41 ila 0,89 birim aralığında değişiklik gösterdiği görülmektedir. NDVI eğilimleri her zaman monoton değildir, değişebilir. Örneğin, olumlu bir eğilim tam tersine, olumsuz bir eğilime dönüşebilir. Ancak genel olarak, eğilimin hafif yükselme yönlü olduğu kabul edilebilir.

Hesaplama sürecini yönetmek için çalışma alanı özdeş kare alanlara (20.000m * 20.000m) bölünmüştür. Bu bölümlenme ile şekil 5' gösterildiği gibi çalışma alanı 12 eşit parçaya ayrılmıştır. Her bölüm için çalışma alanı dışında kalan aykırı değerler filtrelenmiş ve geriye kalan çalışma alanına ait değerler normleştirilmiştir. Daha sonra Matlab yardımıyla YSA modeli oluşturulmuştur. Çalışma alanının bu şekilde bölmelere ayrılması, büyük miktarda olan verinin verimli bir şekilde işlenmesi ve sınırlı makine belleği durumunda daha hızlı ve ucuz veri yönetimi imkânı sunmaktadır.

Ayrıca çalışma alanını kapsayacak şekilde 35.029 adet zaman serisine dayanarak 35.029 ağ ağ geliştirilmiştir. Geliştirilen ağlar eğitilmiş ve test edilmiştir. Ortalama kare hatası (MSE) yöntemine göre genel tahmin doğruluğu 0.741 olarak ölçülmüştür. Daha sonra, her bir zaman serisine ait gelecekteki bitki örtüsünü tahmin etmek için ağlar kullanılmaktadır. Tahmini değerler yine ArcGIS'e taşınır ve gelecekteki bitki örtüsü dinamik haritaları üretilinceye kadar işlenir. Öngörülen bitki örtüsü dağılımı Şekil 5'da gösterilmiştir. Bu deney NDVI zaman serisinin mevcut durumuna göre, geleceğe yönelik bitki örtüsü tahminini göstermektedir. NDVI değerleri 10 gruba ($G = \{1,2,3,4,5,6,7,8,9,10\}$) ayrılabilir. Her bir pikselin geçmiş verilerine dayanarak geliştirilen ağ, karmaşık bilgiyi öğrenerek, herhangi bir dış faktör veya değişkene ihtiyaç duymadan geleceğe yönelik bitki örtüsü miktarını tahmin etmektedir.



Şekil 5: Öngörülen bitki örtüsü dağılımı

4. Sonuç

Son yıllarda bitki örtüsü yoğunluğu tahmini konusu ciddi önem kazanmıştır. Bitki örtüsü

yoğunluğuna bağlı olarak gıda güvenliği ve gıda sistemlerinin dengesi konusu ön plana çıkmaktadır. Doğru bitki örtüsü tahmini verileri, kaynaklardaki kıtlığa karşı erken uyarı olacak ve risklerin azaltılması konusunda yöneticilere kayda değer ölçüde bilgi sunacaktır. Aynı zamanda bitki örtüsü yoğunluğunun öngörülmesi, halkın bilinçlendirilmesi sağlamakta ve buna bağlı olarak doğal çevre korunarak zararlı etkiler azalmaktadır. Bu çalışmada, bitki örtüsü yoğunluğu dinamikleri yapay sinir ağları kullanılarak tahmin edilmiştir. Dokuz aşamada ayrı araçlar geliştirilmiştir ve veri işleme bu aşamalardan geçirilerek gerçekleştirilmiştir. Çalışma alanı olarak düzce ili sınırları içerisinde kalan bölge seçilmiştir. Orta Çözünürlüklü Görüntüleme Spektrometre (MODIS) uydusundan alınan görüntüler kullanılarak elde edilen normalize edilmiş fark bitki örtüsü indeksi (NDVI) görüntüleri, bitki örtüsü yoğunluğu zaman serisinin veri setlerini üretmek için kullanılmıştır. MODIS uydusu görüntüleri, Amerika Birleşik Devletleri jeolojik araştırma (USGS) web sitesinden indirilmiştir. Yaklaşık son 19 yıl boyunca, her 16 günde bir kaydedilen görüntülerden %10'dan daha fazla bulut içeren görüntüler ayıklandıktan sonra geriye kalan 300 görüntü kullanılmıştır. Veri setleri ve görüntüleri işlemek ve çıkarımlar yaparak tahminde bulunmak için Matlab ve ArcGIS yazılımları kullanılmış. Bilgisayarın donanımlarını verimli kullanmak, bellek tüketimini azaltmak ve paralel programlama ile işlem süresini kısaltmak için özdeş karelere ayırma yöntemi kullanılmıştır. Geleceğe yönelik bitki örtüsü tahmini için mekânsal-zamansal uydu görüntüleri üzerinde piksel tabanlı işlemler yapılmıştır. Çalışmada, normalize edilmiş fark bitki örtüsü indeksi (NDVI) görüntüsünün bir adım sonrası için önceden tahmin programı hazırlanmıştır. Veri seti eğitim ve test veri seti olmak üzere ikiye bölünmüştür. Performans doğruluğu değerlendirme ölçütü olarak ortalama kare hatası (MSE) yöntemi kullanılmıştır. Sonuç olarak, genel tahmin doğruluğu 0.741 ile tatmin edici düzeydedir. Bu bağlamda çalışma, yapay sinir ağları modelinin mekânsal-zamansal uydu görüntüleri üzerinde geleceğe yönelik NDVI değerlerini tahmin etme yeteneğini ortaya koymuştur.

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

- [1] 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.
- [2] 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.
- [3] 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.
- [4] Li, Deren, Shuliang Wang, and Deyi Li. 2015. "Spatial data mining."
- [5] 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.
- [6] 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.
- [7] 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.
- [8] 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.
- [9] Sempergreen. 2019. “Benefits of Green Ground Cover.” Retrieved February 24, 2019 (<https://www.sempergreen.com/us/solutions/green-ground-covering/benefits-green-ground-cover>).
- [10] 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.
- [11] Stepchenko, Arthur. 2016. “NDVI Index Forecasting Using a Layer Recurrent Neural Network Coupled with Stepwise Regression and the PCA.” Pp. 130–35 in.
- [12] 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.
- [13] 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.
- [14] 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.
- [15] 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.
- [16] 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.