

ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

İHA İLE GÖRÜNTÜ İŞLEME TEKNİKLERİNİ KULLANARAK YONCADA
VERİM VE KALİTE PARAMETRELERİ İÇİN UYGUN BİTKİ
İNDEKSLERİNİN ELDE EDİLMESİ

Veysel GÜL

TARIM MAKİNALARI VE TEKNOLOJİLERİ MÜHENDİSLİĞİ
ANABİLİM DALI

ANKARA
2024

Her hakkı saklıdır

ÖZET

Doktora Tezi

İHA İLE GÖRÜNTÜ İŞLEME TEKNİKLERİNİ KULLANARAK YONCADA VERİM KALİTE PARAMETRELERİ İÇİN UYGUN BİTKİ İNDEKSLERİNİN ELDE EDİLMESİ

Veysel GÜL

Ankara Üniversitesi

Fen Bilimleri Enstitüsü

Tarım Makinaları ve Teknolojileri Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Abdullah BEYAZ

Bu çalışma, Kırşehir ekolojik koşullarında beş lokasyonda İHA ile görüntü işleme tekniği kullanılarak yoncada (*Medicago sativa* L.) verim ve kalite parametrelerini belirlemek için uygun bitki indekslerini elde etmek amacıyla yürütülmüştür. Araştırmada İHA ile elde edilen görüntülerden çıkarılan bitki indeks değerleriyle sahadan toplanan yonca örneklerinin kimyasal analiz sonuçlarını ilişkilendirmek için doğrusal regresyon analizi kullanılmıştır. Araştırma sonuçlarına göre GNDVI indeksi bitki boyunu $R^2=0.819$, NDRE indeksi yaş ot verimini $R^2=0.935$, TGI indeksi ise kuru ot verimini $R^2=0.974$ düzeyinde tahmin ederek güçlü bir ilişki göstermiştir. Ham protein oranını NDRE indeksi ($R^2=0.765$), NDF oranını CL_{REDEGE} indeksi ($R^2=0.698$) ve ADF oranını da NDRE indeksi ($R^2=0.678$) kabul edilebilir doğrulukta tahmin etmiştir. Ancak kalite parametrelerinden elde edilen bu ilişki önemli olmakla birlikte, verim parametreleri için elde edilen değerlerin oldukça altında kalmıştır. Bu nedenle kalite parametrelerinin tahmin doğruluk değerlerini artırmak için NDRE ve CL_{REDEGE} indekslerinin spektral özellikleri ayarlanarak modifiye indeksler geliştirilmiştir. Bu indeksler modifiye edilirken toprak yansıma değerleri azaltılmış ve spektral hassasiyetleri yakın kızılötesi (NIR) aralığına kaydırılarak MPNDRE, $MNCL_{REDEGE}$ ve MANDRE indeksleri elde edilmiştir. Bu modifikasyonlar sonucunda, MPNDRE indeksi ham protein oranını %82, $MNCL_{REDEGE}$ indeksi NDF oranını %72.6 ve MANDRE indeksi ADF oranını %70.5 doğrulukta tahmin etmiştir. Araştırma sonuçları, İHA tabanlı uzaktan algılama ve görüntü işleme tekniklerinin yoncada verim ve kalite parametrelerini yüksek doğrulukla etkili bir şekilde tahmin edebileceğini ve değişen ekolojik koşullar altında belirli agronomik özelliklerin tahmin edilmesindeki performanslarını artırmak için klasik bitki örtüsü indekslerinin modifiye edilerek geliştirilebileceklerini göstermiştir. Bu yaklaşım ürün özelliklerin hızlı, doğru ve mekânsal olarak ayrıntılı bir şekilde değerlendirirken, aynı zamanda da verim ve kalite parametrelerinin belirlenmesinde farklı yöntemlerin kullanılmasının da önünü açacaktır.

Eylül 2024, 115 sayfa

Anahtar Kelimeler: Akıllı tarım, İHA, Bitki örtüsü indeksi, Görüntü analizi, Yonca, Verim, Kalite

ABSTRACT

PhD Thesis

OBTAINING APPROPRIATE PLANT INDICES FOR YIELD AND QUALITY PARAMETERS IN ALFALFA USING IMAGE PROCESSING TECHNIQUES WITH UAV

Veysel GÜL

Ankara University

Graduate School of Natural and Applied Sciences

Department of Agricultural Machinery and Technologies Engineering

Supervisor: Doç. Dr. Abdullah BEYAZ

This study was conducted at five locations under Kırşehir ecological conditions to obtain appropriate plant indices to determine alfalfa (*Medicago sativa* L.) yield and quality parameters using image processing techniques by using UAV. In the study, linear regression analysis was used to correlate the plant index values extracted from the images obtained from UAV with the chemical analysis results of the alfalfa samples collected from the field. According to the study results, GNDVI index predicted plant height by $R^2=0.819$, NDRE index predicted wet grass yield by $R^2=0.935$, and TGI index predicted dry grass yield by $R^2=0.974$, showing a strong relationship. The NDRE index ($R^2=0.765$) predicted crude protein ($R^2=0.765$), the CL_{REDEGE} index ($R^2=0.698$) predicted NDF ($R^2=0.698$) and the NDRE index ($R^2=0.678$) predicted ADF ($R^2=0.678$) with acceptable accuracy. However, although significant, these relationships obtained from quality parameters were well below the values obtained for yield parameters. Therefore, modified indices were developed by adjusting the spectral characteristics of the NDRE and CL_{REDEGE} indices to improve the accuracy of the estimation of quality parameters. While modifying these indices, soil reflectance values were reduced, and spectral sensitivities were shifted to the near-infrared (NIR) range to obtain MPNDRE, $MNCL_{REDEGE}$ and MANDRE indices. As a result of these modifications, the MPNDRE index estimated crude protein content with 82% accuracy, the $MNCL_{REDEGE}$ index estimated NDF content with 72.6% accuracy, and the MANDRE index estimated ADF content with 70.5% accuracy. The results showed that UAV-based remote sensing and image processing techniques could effectively predict yield and quality parameters in alfalfa with high accuracy and can be improved by modifying classical vegetation indices to enhance their performance in predicting specific agronomic traits under changing ecological conditions. This approach will enable rapid, accurate, and spatially detailed assessment of crop traits while paving the way for using different methods to determine yield and quality parameters.

September 2024, 115 pages

Key Words: Smart agriculture, UAV, Vegetation index, Image analysis, Alfalfa, Yield, Quality

ÖNSÖZ VE TEŞEKKÜR

Öncelikle, danışmanım Sayın Doç. Dr. Abdullah BEYAZ'a, eğitim sürecim boyunca verdiği sürekli destek, rehberlik ve yönlendirmeleri için teşekkürlerimi sunarım. Akademik kariyerimde bana ışık tutan, saha çalışmalarım da her zaman yanımda olan ve bilgi birikimi ile kariyerime yön veren Tez İzleme Komitesi üyesi Sayın Prof. Dr. Tamer YAVUZ'a derin bir teşekkürü borç bilirim. Onun tecrübeleri ve tavsiyeleri bu süreçte karşılaştığım zorlukları aşmamda ve akademik hedeflerime ulaşmamda büyük katkı sağlamıştır. Tez sürecinde olumlu katkılarından dolayı Tez İzleme Komitesi üyesi ve aynı zamanda Ankara Üniversitesi Tarım Makinaları ve Teknolojileri Mühendisliği Bölüm Başkanı Sayın Prof. Dr. Ahmet ÇOLAK'a, gelecekteki akademik çalışmalarım için ufuk açıcı tavsiyelerde bulunan Tez İzleme Komitesi üyesi Sayın Prof. Dr. Ali KOÇ'a teşekkür ederim.

Laboratuvar analizlerinde bana rehberlik eden ve her aşamada desteğini esirgemeyen Merkezi Araştırma ve Uygulama Laboratuvarı Müdürü Sayın Doç. Dr. Hakan KIR'a teşekkür ederim. Ayrıca, tez sürecinde sürekli yapıcı katkılar sağlayan ve beni her zaman destekleyen Sayın Prof. Dr. Aydan YILMAZ'a da en içten teşekkürlerimi sunarım. Tarım ve Jeotermal Koordinatörlüğü'ndeki rehberliği ile sürece önemli katkı sağlayan Sayın Prof. Dr. Mustafa KURT'a, tezimi titizlikle inceleyen Tarım ve Jeotermal Koordinatörü Sayın Prof. Dr. Rüştü HATİPOĞLU'na ve süreç boyunca sabırlı, anlayışlı yaklaşımıyla bana destek olan Kırşehir Ahi Evran Üniversitesi Ziraat Fakültesi Dekanı Sayın Prof. Dr. Selahattin ÇINAR'a içtenlikle teşekkür ederim.

Tez çalışmamda Malya Tarım İşletmesi (TİGEM) arazisinde çalışmalar yapmama olanak sağlayan Malya Tarım İşletmesi Müdürü Sayın Ahmet GEZER ile arazilerini çalışmama açan dört değerli çiftçimize katkılarından dolayı teşekkür ederim.

Verdikleri sürekli ve koşulsuz destekle karşılaştığım zorlukları yenmeme yardımcı olan aileme, özellikle de emekçi ruhuyla ve gösterdiği özveriyle bana ilham kaynağı olan babama sonsuz teşekkürlerimi sunarım.

Son olarak, yoğun çalışma sürecimde ona yeterince vakit ayıramamış olmama rağmen, gösterdiği anlayış ve desteği için eşim Gökçen GÜL'e teşekkür ederim.

Veysel GÜL
Ankara, Eylül 2024

İÇİNDEKİLER

TEZ ONAY SAYFASI	
ETİK.....	i
ÖZET.....	ii
ABSTRACT.....	iii
ÖNSÖZ VE TEŞEKKÜR.....	iv
SİMGELER VE KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	5
3. MATERYAL VE YÖNTEM.....	13
3.1 Materyal	13
3.1.1 Araştırma kullanılan insansız hava aracının (İHA) özellikleri.....	14
3.2 Yöntem	16
3.2.1 Çalışma alanı	16
3.2.2 Multispektral İHA ile görüntülerin alınması	19
3.2.3 Çalışmada kullanılan bitki indeksleri	23
3.2.4 Modifiye bitki indekslerinin geliştirilmesi	28
3.2.5 Modifiye edilmiş protein normalize fark kırmızı kenar (MPNDRE).....	31
3.2.6 Modifiye edilmiş NDF klorofil kırmızı kenar (MNCL _{REDEEDGE})	32
3.2.7 Modifiye edilmiş ADF normalize fark kırmızı kenar (MANDRE).....	33
3.2.8 Sahadan örneklerin alınması	34
3.2.9 Kimyasal analiz	37
3.2.10 Regrasyon analizi	37
4. BULGULAR VE TARTIŞMA	39
4.1 Bitki Boyu	39
4.2 Yaş Ot Verimi.....	46
4.3 Kuru Ot Verimi	53
4.4 Ham Protein Oranı	59
4.5 NDF Oranı	66
4.6 ADF Oranı	74
5. SONUÇLAR VE ÖNERİLER	82
KAYNAKLAR	84
EKLER.....	98
ÖZGEÇMİŞ.....	115

SİMGELER VE KISALTMALAR DİZİNİ

%	Yüzde
°C	Santigrat derece
r^2	Regresyon denklemi belirleme katsayısı
ms^{-1}	Metre bölü saniye
$kg\ da^{-1}$	Kilogram bölü dekar

Kısaltmalar

ADF	Asit Deterjan Lif
ANN	Yapay Sinir Ağları
BB	Bitki Boyu
BNDVI	Mavi Normalize Fark Bitki İndeksi
$CL_{Rededge}$	Klorofil Kırmızı Kenar Bitki İndeksi
DOM	Dijital Ortofoto Harita
DVI	Dikey Bitki İndeksi
EVI	Geliştirilmiş Bitki İndeksi
GNDVI	Yeşil Normalize Fark Bitki İndeksi
GRVI	Yeşil-Kırmızı Bitki Örtüsü İndeksi
GVMİ	Küresel Bitki Örtüsü Nem İndeksi
HPO	Ham Protein Oranı
İHA	İnsansız Hava Aracı
KOV	Kuru Ot Verimi
LAI	Yaprak Alan Bitki İndeksi
LCI	Yaprak Klorofil Bitki İndeksi
MANDRE	Modifiye Edilmiş ADF Normalize Kırmızı Kenar Bitki İndeksi
MCARI	Modifiye Edilmiş Klorofil Emilim Oranı Bitki İndeksi
$MNCL_{REDEGE}$	Modifiye Edilmiş NDF Klorofil Kırmızı Kenar Bitki İndeksi
MPLS	Modifiye En Küçük Kareler Regresyonu
MPNDRE	Modifiye Edilmiş Protein Normalize Kırmızı Kenar Bitki İndeksi
MSI	Multispektral Görüntü
NDF	Nötral Deterjan Lif
NDII	Normalleştirilmiş Fark Kızılötesi İndeksi
NDRE	Normalize Fark Kırmızı Kenar Bitki İndeksi
NDSI	Normalize Edilmiş Spektral Bitki İndeksi
NDVI	Normalize Fark Bitki İndeksi
NDWI	Normalleştirilmiş Fark Su İndeksi
nm	Nanometre
OSAVI	Optimize Edilmiş Toprak Düzeltilmiş Bitki İndeksi
PLS	Kısmi En Küçük Kareler Regresyonu

POS	Hava Fotoğraflarını Yönelim Sistemiyle Hizalama
RE	Kırmızı Kenar
REIP	Kırmızı Kenar Dönüm Noktası
RF	Rastgele Orman Algoritması
RTK	Gerçek Zamanlı Hareket
RVI	Radar Bitki İndeksi
SIPI	Yapıya Duyarsız Pigment Bitki İndeksi
SKM	Sindirilebilir Kuru Madde
SMLR	Kademeli Çoklu Doğrusal Regresyon
SR	Basit Oran Bitki İndeksi
SVM	Destek Vektör Makinesi
TCARI	Dönüştürülmüş Klorofil Emilim Oranı Bitki İndeksi
TGI	Üçgen Yeşillik Bitki İndeksi
VARI	Görünür Atmosferik Direnç Bitki İndeksi
YOV	Yaş Ot Verimi

ŞEKİLLER DİZİNİ

Şekil 3.1 Araştırmanın yürütüldüğü lokasyonlar	13
Şekil 3.2 Araştırmada kullanılan multispektral kameralı İHA.....	14
Şekil 3.3 Araştırmada kullanılan 1 m ² 'lik çerçevenin görünümü	17
Şekil 3.4 Araştırmada kullanılan 1 m ² 'lik çerçevelerin araziye yerleştirilmesi.....	18
Şekil 3.5 Araştırmada kullanılan çerçevelerin homojen yerleştirilmesinde uygulanan yöntem.....	18
Şekil 3.6 DJI GS Pro platformunda uçuş planlaması.....	19
Şekil 3.7 İHA ile görüntülerin alınması	20
Şekil 3.8 Pix4Dfields yazılımı ile 1m x 1m'lik çerçevelerin kırılması.....	21
Şekil 3.9 Pix4Dfields yazılımı ile 0.25 m x 0.25 m'lik alanların kırılması	22
Şekil 3.10 Yeşil bir yaprağın hücre yapısı ve elektromanyetik radyasyonla etkileşimi .	29
Şekil 3.11 Bitki örtüsünün spektral yansıma eğrileri.....	30
Şekil 3.12 Toprak yansıma çizgisinin mesafe tabanlı indeks ile ölçümü	30
Şekil 3.13 Bitki boyu ölçümü	35
Şekil 3.14 Araziden yaş ot örnek alımı	35
Şekil 3.15 Yaş ot örnek tartımı	36
Şekil 3.16 Kalite parametrelerinin ölçümü için örneklerin hazır hale getirilmesi	36
Şekil 4.1 Bitki boyunun belirlenmesinde GNDVI, BNDVI, CL _{REDEGE} ve DVI bitki indekslerinin model-tahmin regresyon grafikleri	42
Şekil 4.2 Bitki boyunun belirlenmesinde EVI, LCI, NDRE ve NDVI bitki indekslerinin model-tahmin regresyon grafikleri	43
Şekil 4.3 Bitki boyunun belirlenmesinde SR, RVI, OSAVI ve MCARI bitki indekslerinin model-tahmin regresyon grafikleri	44
Şekil 4.4 Bitki boyunun belirlenmesinde VARI, TGI, TCARI ve SIPI bitki indekslerinin model-tahmin regresyon grafikleri	45
Şekil 4.5 Yaş ot veriminin belirlenmesinde kullanılan GNDVI, BNDVI, CL _{REDEGE} ve DVI bitki indekslerinin model-tahmin regresyon grafikleri.....	49
Şekil 4.6 Yaş ot veriminin belirlenmesinde kullanılan EVI, LCI, NDRE ve NDVI bitki indekslerinin model-tahmin regresyon grafikleri.....	50
Şekil 4.7 Yaş ot veriminin belirlenmesinde kullanılan SR, RVI, OSAVI ve MCARI bitki indekslerinin model-tahmin regresyon grafikleri.....	51
Şekil 4.8 Yaş ot veriminin belirlenmesinde kullanılan VARI, TGI, TCARI ve SIPI bitki indekslerinin model-tahmin regresyon grafikleri.....	52

Şekil 4.9 Kuru ot veriminin belirlenmesinde kullanılan GNDVI, BNDVI, CL _{REDEDGE} ve DVI bitki indekslerinin model-tahmin regresyon grafikleri.....	55
Şekil 4.10 Kuru ot veriminin belirlenmesinde kullanılan EVI, LCI, NDRE ve NDVI bitki indekslerinin model-tahmin regresyon grafikleri.....	56
Şekil 4.11 Kuru ot veriminin belirlenmesinde kullanılan SR, RVI, OSAVI ve MCARI bitki indekslerinin model-tahmin regresyon grafikleri.....	57
Şekil 4.12 Kuru ot veriminin belirlenmesinde kullanılan VARI, TGI, TCARI ve SIPI bitki indekslerinin model-tahmin regresyon grafikleri.....	58
Şekil 4.13 Ham protein oranının belirlenmesinde kullanılan GNDVI, BNDVI, CL _{REDEDGE} ve DVI bitki indekslerinin model-tahmin regresyon grafikleri.....	62
Şekil 4.14 Ham protein oranının belirlenmesinde kullanılan EVI, LCI, NDRE ve NDVI bitki indekslerinin model-tahmin regresyon grafikleri.....	63
Şekil 4.15 Ham protein oranının belirlenmesinde kullanılan SR, RVI, OSAVI ve MCARI bitki indekslerinin model-tahmin regresyon grafikleri.....	64
Şekil 4.16 Ham protein oranının belirlenmesinde kullanılan VARI, TGI, TCARI ve SIPI bitki indekslerinin model-tahmin regresyon grafikleri.....	65
Şekil 4.17 Ham protein oranının belirlenmesinde geliştirilen modifiye protein normalize edilmiş kırmızı kenar (MPNDRE) bitki indeksinin model-tahmin regresyon grafikleri.....	66
Şekil 4.18 NDF oranının belirlenmesinde kullanılan GNDVI, BNDVI, CL _{REDEDGE} ve DVI bitki indekslerinin model-tahmin regresyon grafikleri.....	69
Şekil 4.19 NDF oranının belirlenmesinde kullanılan EVI, LCI, NDRE ve NDVI bitki indekslerinin model-tahmin regresyon grafikleri.....	70
Şekil 4.20 NDF oranının belirlenmesinde kullanılan SR, RVI, OSAVI ve MCARI bitki indekslerinin model-tahmin regresyon grafikleri.....	71
Şekil 4.21 NDF oranının belirlenmesinde kullanılan VARI, RVI, OSAVI ve SIPI bitki indekslerinin model-tahmin regresyon grafikleri.....	72
Şekil 4.22 NDF oranının belirlenmesinde geliştirilen modifiye NDF klorofil kırmızı kenar (MNCL _{REDEDGE}) bitki indeksinin model-tahmin regresyon grafikleri.....	73
Şekil 4.23 ADF oranının belirlenmesinde kullanılan GNDVI, BNDVI, CL _{REDEDGE} ve DVI bitki indekslerinin model-tahmin regresyon grafikleri.....	76
Şekil 4.24 ADF oranının belirlenmesinde kullanılan EVI, LCI, NDRE ve NDVI bitki indekslerinin model-tahmin regresyon grafikleri.....	77
Şekil 4.25 ADF oranının belirlenmesinde kullanılan SR, RVI, OSAVI ve MCARI bitki indekslerinin model-tahmin regresyon grafikleri.....	78
Şekil 4.26 ADF oranının belirlenmesinde kullanılan VARI, TGI, TCARI ve SIPI bitki indekslerinin model-tahmin regresyon grafikleri.....	79
Şekil 4.27 ADF oranının belirlenmesinde geliştirilen modifiye ADF kırmızı kenar (MANDRE) bitki indeksinin model-tahmin regresyon grafikleri.....	80

ÇİZELGELER DİZİNİ

Çizelge 3.1 Araştırma alanlarına ait koordinat ve yükseklik bilgileri.	14
Çizelge 3.2 Multispektral kameralı İHA'ya ait teknik özellikler.....	15
Çizelge 3.3 İHA ile elde edilen multispektral görüntülerin spektral bölgesi ve dalga boyu aralığı	16
Çizelge 3.4 Lokasyon ve biçim sayısına göre İHA görüntü alma tarihleri.....	21
Çizelge 4.1 Lokasyon ve biçim sayısına göre yonca bitki boyu değerleri (cm)	39
Çizelge 4.2 Bitki boyunun belirlenmesinde kullanılan bitki indekslerinin model- tahmin regresyon değerleri ve denklemleri.....	40
Çizelge 4.3 Lokasyon ve biçim sayısına göre yonca yaş ot verim değerleri (kg da ⁻¹)....	46
Çizelge 4.4 Yaş ot veriminin belirlenmesinde kullanılan bitki indekslerinin model-tahmin regresyon değerleri ve denklemleri.....	47
Çizelge 4.5 Lokasyon ve biçim sayısına göre yonca kuru ot verim değerleri (kg da ⁻¹)	53
Çizelge 4.6 Kuru ot veriminin belirlenmesinde kullanılan bitki indekslerinin model-tahmin regresyon değerleri ve denklemleri.....	54
Çizelge 4.7 Lokasyon ve biçim sayısına göre yonca ham protein oranı değerleri (%)... 59	
Çizelge 4.8 Ham protein oranının belirlenmesinde kullanılan bitki indekslerinin model-tahmin regresyon değerleri ve denklemleri.....	60
Çizelge 4.9 Lokasyon ve biçim sayısına göre yonca NDF oranı değerleri (%).....	66
Çizelge 4.10 NDF oranının belirlenmesinde kullanılan bitki indekslerinin model- tahmin regresyon değerleri ve denklemleri	68
Çizelge 4.11 Lokasyon ve biçim sayısına göre yonca ADF oranı değerleri (%).....	74
Çizelge 4.12 ADF oranının belirlenmesinde kullanılan bitki indekslerinin model- tahmin regresyon değerleri ve denklemleri	75

1. GİRİŞ

Yonca (*Medicago sativa* L.), yüksek protein içeriğiyle birlikte farklı toprak ve iklim koşullarına karşı adaptasyonu sayesinde tüm dünyada yaygın olarak yetiştirilen en önemli çok yıllık baklagil yem bitkisidir (Radović vd. 2009; Feng vd. 2020). Derin kök yapısı sayesinde toprağın fiziksel özelliklerinin gelişmesini sağlarken (Shi vd. 2017; Hrbáčková vd. 2020), aynı zamanda azot bağlama özelliğiyle de toprağın kimyasal özelliklerini iyileştirerek azotlu gübre ihtiyacını azaltır ve sürdürülebilir tarım sistemine katkı sağlar (Moyo vd. 2010; Gámez vd. 2024).

Yonca uzun zamandan beri sürdürülebilir ve karlı bir üretim sistemini sağlaması nedeniyle üreticiler tarafından ilgi görmektedir (Elfanssi vd. 2018; S. Wang vd. 2022). Ülkemizde 2000-2021 yılları arasındaki yem bitkisi üretiminin yaklaşık %65'ini yonca oluşturmaktadır (Ayyıldız ve Meliha 2022). Yoncunun özellikle süt hayvancılığı sektöründeki üretici açısından yüksek ekonomik kazançta ulaşmak için gereken verimle, tüketici için gereken kalite arasındaki dengeyi sağlamada oldukça önemli bir rolü vardır (Undersander vd. 1997; F. Zhang vd. 2023). Bu nedenle, yonca verim ve kalitesinin hasattan önce tahmin edilmesi çiftçilerin üretim uygulamalarını optimize etmelerine, hayvanların performansını iyileştirmelerine ve karlılığı artırmalarına olanak tanır (Zhang vd. 2024). Aynı zamanda bu bilgilerin elde edilmesi ithalat ve ihracat durumunu değerlendirerek tarım politikalarının belirlenmesi açısından da önemlidir (Jha vd. 2019).

Geleneksel yöntemlerle verim ve kalite parametrelerini belirlemek maliyetli, zaman alıcı ve yoğun emek isteyen süreçlere dayanmaktadır (Noland vd. 2018). Bununla birlikte, bu yöntemler mekânsal heterojenliğe sahip geniş alanlar için doğru sonuçlar vermeyebilir (Feng vd. 2022). Bu parametreler dar alanlardan çok geniş alanlara kadar hızlı ölçüm potansiyeline sahip olan uzaktan algılama teknolojilerine sahip insansız hava araçlarıyla (İHA) tespit edilebilir (Sapkota vd. 2023). Tarımsal arazilerin haritalanması, mahsullerde meydana gelecek değişimin izlenmesi, hastalık zararlı tespiti, bitki besin elementlerinin durumu, biyotik ve abiyotik stres koşullarının verim ve kaliteye etkisi gibi birçok süreçte İHA'larla elde edilen görüntüler çeşitli yapay zekâ algoritmalarında işlenerek klasik yöntemlere eşdeğer ve daha işlevsel sonuçlar elde edilebilir (Clay vd. 2006; Duchemin

vd. 2015; Debats vd. 2016; Jin vd. 2020). Nitekim son zamanlarda geliştirilen İHA'ların üzerinde bulunan farklı sensörler sayesinde elde edilen yüksek çözünürlüklü görüntüler hassas tarımda yaygın olarak kullanılmaktadır. Hassas tarım, bu bağlamda çevresel etkileri azaltırken tarımsal verimliliği artırmak için sahadan toplanan verileri yoğun bir şekilde kullanmaya yönelik yeni bir yaklaşım olarak ortaya çıkmıştır (McBratney vd. 2005; Liakos vd. 2018). Bu yaklaşım, hassas tarım için uygun bir araç olarak kullanılan İHA'ların çok yönlülüğünü, tarımsal arazi yönetimini ve tarım endüstrisi üzerindeki potansiyel etkisini açıkça ortaya koymaktadır (Szypuła 2024).

İHA'larda bulunan gelişmiş görüntüleme, mesafe ve konumlandırma sensörleri sayesinde santimetre düzeyinde elde edilen görüntüler, genellikle bitki örtüsünün özelliklerini izlemek için kullanılır. Düşük irtifalarda daha ayrıntılı piksel boyutlarında İHA'larla elde edilen bu görüntülerle, bitkilerin farklı gelişim aşamalarındaki spektral dalga boyları hassas bir şekilde tespit edilebilir (Floreano ve Wood 2015; Schirrmann vd. 2016). Bu spektral verilerin anlamlı göstergelere dönüştürülmesi ve bitkiler tarafından farklı dalga boylarındaki ışık emilimiyle birlikte yansıma ilişkisinin yorumlanabilmesi için çok sayıda spektral bitki örtüsü indeksi geliştirilmiştir (Huete vd. 2002; D. Zhao vd. 2005; Beck vd. 2007; Galvão vd. 2009). Bitki örtüsü indeksleri yakın kızılötesi (NIR) bandının görünür spektruma (400-700 nm) oranıyla veya matematiksel olarak normalleştirilmiş farkları hesaplanarak elde edilir (Tucker 1979; Sellers 1985; Leprieur vd. 1994).

Bitkilerin karakteristik özelliklerinin belirlenmesinde geniş alanlarda zor ve zaman alıcı olan geleneksel yöntemlerin yerine kullanılan bitki örtüsü indekslerinin temel amacı, dalga boylarından çıkarılan spektral yansıma verilerinden elde edilen bilgileri geliştirerek bu özelliklerin tespitini zorlaştıran toprak ve atmosfer gibi çevre faktörlerinin etkisini en aza indirmektir (Bannari vd. 1995; Moulin 1999; Marino vd. 2013; Marino vd. 2014; Prudnikova vd. 2019).

Genellikle bitki örtüsü indeksleri, verim ve bitki klorofil içeriğini tahmin etmek için yaygın olarak kullanılmaktadır. Spektral yansımalar doğrudan verim tahmininde kullanılsa da bitki örtüsünün taç çapı ve yoğunluğu yaprak alanı ile ilişkili olduğundan kolaylıkla verim tahmini yapılabilir (Myneni vd. 1995; Gitelson, Kaufman ve Merzlyak

1996; Hill 2004). Klorofilin belirlenebilmesi için yapılan ilk arařtırmalarda, belirli dalga boylarının ışık yansımalarındaki deęişimlerin bitki yapraklarındaki klorofil konsantrasyonuyla ve bunun da bitkinin azot içerięiyle güçlü bir ilişkili içinde olduęu fark edilmiştir (Curran 1989). Bu ilişki fotosentez olayının gerçekleştirilmesinden sorumlu ana pigment olan klorofilin yüksek oranda yeşil ve yakın kızılötesi (NIR) dalga boylarındaki ışığı yansıtırken, spektrumun mavi ve kırmızı kısımlarındaki ışığı emdiğinin fark edilmesi sonucunda belirlenmiştir (Curran vd. 1990; Gitelson, Zur, vd. 2002).

Bu alandaki çalışmalar için en önemli aşama kırmızı ve yakın kızılötesi yansıma arasındaki kontrasttan yararlanarak bitki örtüsünün yeşilliğini ve yoğunluęunu deęerlendiren Normalleştirilmiş Fark Bitki Örtüsü İndeksinin (NDVI) geliştirilmesidir (Rouse vd. 1974; Tucker 1979). NDVI, biyokütle ve yaprak alanını tahmin etmek için yaygın olarak benimsenen bir araç haline gelmesine rağmen, özellikle yoğun bitki örtüsünde klorofile karşı duyarlılığı sınırlıdır. Kısıtlayıcı bu durum, spektrumun kırmızı kenar bandındaki dalga boyunu NIR dalga boyu aralığına entegre ederek, klorofil dalgalanmalarına karşı duyarlılığı artırmayı amaçlayan çok sayıda bitki indeksinin geliştirilmesine yol açmıştır (Roujean ve Breon 1995; Gitelson 2004; Jiang vd. 2008).

Bitki örtüsünün kırmızı ve NIR yansıması arasında, kırmızı kenar (RE) bandı olarak bilinen bölgede (670-760 nm) ani bir dalga boyu deęişimi meydana gelmektedir. Bu deęişim yaprağın yapısı nedeniyle klorofilin kırmızı dalga boyu aralığındaki ışığı emmesini ve NIR dalga boyu aralığındaki ışığı dağıtmasını ifade etmektedir (Gitelson ve Merzlyak 1998; F. Li vd. 2014; Jorge vd. 2019). Kırmızı, kırmızı kenar ve NIR bantları bitkilerin tüm fizyolojik süreçlerinin belirlenmesinde daha fazla hassasiyet sağladıkları için bitki indekslerinin deęiştirilmesi veya iyileştirilmesinde yoğun olarak kullanılmaktadırlar. Uzaktan algılama teknolojileri ile elde edilen bitki indeksleri ile bir tarımsal ürünün ayırt edici özelliklerini tespit etmek için, her bitki indeksinin ürün parametreleri ve büyüme aşamalarıyla ilişkilendirilebilen benzersiz bir dalga bantları kombinasyonuna sahip olması nedeniyle daha fazla bitki örtüsü indeksi kullanılması önerilmektedir (Hatfield ve Prueger 2010). Ayrıca bu dalga boyları arasındaki ayrımlar, fark alma ve oranlamaya dayalı tekniklerle önemli ölçüde güçlendirilerek etkili bir şekilde farklı ürün ve koşullara uyarlanarak geliştirilebilir (Liu ve Mason 2013).

Yem bitkilerinde İHA veya uydu gibi uzaktan algılama teknolojileri kullanılarak tarımsal ürünün verim ve kalitesinin değerlendirilmesine yönelik çalışmalar oldukça azdır ve mevcutta olanlar da kaliteden ziyade biyokütle verimliliğine odaklanmaktadır (Loudjani 2014). Nitekim literatürde uzaktan algılama yöntemleriyle yem bitkilerinde yapılan biyokütle arařtırmaları yeterince yer almasına rağmen, yoncada hem biyokütle hem de kalite parametrelerinin değerlendirilmesiyle ilgili arařtırmalar oldukça azdır (Tedesco vd. 2022).

Bu çalışmanın amacı bitki boyu, yaş ot ve kuru ot gibi verimle ilgili özelliklerin yanında laboratuvar ortamında maliyetli, uzun ve zaman alıcı süreç isteyen ham protein, NDF ve ADF oranı gibi kalite parametrelerinin İHA ile görüntü işleme tekniklerini kullanarak mevcut ve yeni geliştirilecek bitki indeksleriyle belirlenmesidir.

2. KAYNAK ÖZETLERİ

Hancock ve Dougherty (2007), Landsat uydu görüntülerine mavi ve kırmızı bant tabanlı bitki örtüsü indeksleri uygulayarak, yaprak alanı ve yonca verimi arasındaki ilişkiyi araştırmışlardır. Bitkinin taç yansıma dalga boyları, hasattan önce spektrometre ile ölçülmüş ve bazı vejetasyon indekslerini çıkarmışlardır. Hem mavi hem de kırmızı tabanlı indekslerin yaprak alanı ve verim tahmininde doygunluğa ulaştığını belirtmişlerdir. Ayrıca yaprak alanı verilerinin mavi ve kırmızı bantların yanı sıra NIR bölgesini içeren indekslerle entegre edilmesinin yoncada verim tahmininin doğruluğunu artırabileceğini vurgulamışlardır.

Trotter vd. (2008), yaptıkları araştırmada, Crop Circle™ aktif bitki sensörünü kullanarak sorgum, tritikale, yonca ve mera alanlarındaki biyokütle miktarlarını tespit etmeyi amaçlamışlardır. Sensörden elde ettikleri dalga boylarından hesapladıkları bitki örtüsü indekslerinin (NDVI, SAVI, SR) tahmin doğruluklarını belirlemek için geleneksel biyokütle ölçümleri ile karşılaştırmalar yapmışlardır. Çalışmanın sonuçlarına göre, en yüksek korelasyon tritikalede, sensör 1,5 metre yüksekliğinde tutulduğunda, SAVI indeksinde $R^2=0,874$ olarak elde etmişlerdir. Sorgum bitkisinde ise, sensör 1 metre yüksekliğinde kullanıldığında NDVI, SR ve SAVI indekslerinin değerleri sırasıyla $R^2=0,680$, $R^2=0,717$ ve $R^2=0,693$ değerlerinde güçlü bir şekilde ilişkili çıktığını belirtmişlerdir. Buna karşın, mera alanlarında tüm bitki örtüsü indeksleri için korelasyonların değerlerinin $R^2=0,2$ 'nin altında kaldığı belirtmişlerdir. Yonca biyokütle tespitinde ise, sensör 1 metre yükseklikte kullanıldığında NDVI, SR ve SAVI indekslerinin sırasıyla $R^2=0,032$, $R^2=0,050$ ve $R^2=0,054$ ile oldukça zayıf korelasyonlar gösterdiği vurgulanmıştır.

Biewer vd. (2009), baklagil-çim karışımlarında metabolize edilebilir enerji, kül içeriği, ham protein ve asit deterjan lif oranını belirlemek için, arazi koşullarında spektrometre ile ölçümler yaparak tahmin etmek istemişlerdir. Farklı baklagil oranlarına (kuru maddenin %0-100'ü) ve büyüme aşamalarına (kardeşlenmeden çiçeklenme sonuna kadar) sahip toplam 200 *Lolium perenne* L., *Trifolium repens* L. ve *Trifolium pratense* L. popülasyonu analiz etmişlerdir. Hiperspektral veri setine (350-2500 nm) üç analitik

yöntem iki dalga bandı yansıma oranları, modifiye kısmi en küçük kareler (MPLS) regresyonu ve kademeli çoklu doğrusal regresyon (SMLR) uygulamışlardır. Yem kalitesi değişkenleri ile yansıma oranlarının zayıf korelasyonlar sergilediğini, MPLS ve SMLR $R^2=0.70$ ile $R^2=0.94$ arasında ise yüksek oranda ilişkili çıktığını belirtmişlerdir. Azaltılmış spektral aralıklarda (630-1000 nm) bile, MPLS ve SMLR kül içeriğini $R^2=0.62$ ile $R^2=0.78$ ve ham protein oranını $R^2=0.83$ ile $R^2=0.86$ tatmin edici değerlerde güvenilir tahminler sağladıklarını ortaya koyarak, saha spektroskopisinin kalite parametrelerinde uygulanabilirliğini göstermişlerdir. Ayrıca azaltılmış hiperspektral veri setinin analizinde ise (620-1000 nm, 10 nm çözünürlük) ADF oranının tahmin edilmesinin diğer parametrelere göre daha zor olduğunu ancak kül içeriğinin ve ham protein oranının belirlenmesinde daha tatmin edici sonuçlar verebileceğini dile getirmişlerdir.

Fricke ve Wachendorf (2013), yaptıkları çalışmada, yonca (*Medicago sativa* L.) ile çok yıllık çim (*Lolium perenne* L.) karışımlarının biyokütlesini belirlemek için ultrasonik mesafe sensörü ve spektral-radyometrik yansımalar kullanmışlardır. Biyokütle tahminlerinin doğruluk oranlarını artırmak için bitki indeksleri ile ultrasonik tesis boyu verilerini kullanılmışlardır. Karışımlarında en yüksek tahmin doğruluğunu $R^2=0.83$ normalleştirilmiş spektral bitki indeksi (NDSI) ve ultrasonik tesis boyu kombinasyonlarından elde ettiklerini vurgulamışlardır. Kırmızı/NIR tabanlı indekslerin tatmin edici bir sonuç vermediğini fakat NIR yansımasının yüksek olduğu indekslerin daha iyi sonuçlar verdiğini dile getirmişlerdir. Bant genişliği ve NDSI bant kombinasyonlarının, geniş alanlarda baklagil ve çim karışımlarının verimini tespit etmeyi kolaylaştırabileceğini belirtmişlerdir.

Marshall ve Thenkabail (2015), Kaliforniya'da en çok yetiştirilen ürünlerin (pirinç, mısır, pamuk ve yonca) saha ve Landsat uydusundan aldıkları verileri entegre ederek biyokütlelerini belirlemeye çalışmışlardır. Kaliforniya Üniversitesi, Davis araştırma alanında yürütülen çalışmada sahada örnekler alındıktan sonra, uydu platformundaki görüntülere 60x60 m büyüklüğünde kesitler oluşturularak dalga boylarını çıkartmışlardır. Araştırma sonucunda ürünlerinin biyokütlelerini, pirinç için $R^2=0.84$, mısır için $R^2=0.59$,

pamuk için $R^2=0.91$ ve yonca için ise $R^2=0.86$ yüksek doğrulukla tahmin ettiklerini belirtmişlerdir.

Safari vd. (2016), yaptıkları çalışmada, merada yaş ot verimini belirlemek için ultrasonik ve spektral sensörlerle donatılmış bir mobil cihazın performansını değerlendirmiş ve tahmin doğruluğunu statik sensör ölçümleri ile karşılaştırmışlardır. Mobil sensör sistemiyle merada manuel olarak belirlenen yaş ot verimini %63 doğruluk oranında tahmin etmişlerdir. Araştırmacılar, otlatma yoğunluğu arttıkça tahmin doğruluğunun arttığını, otlatma yoğunluğu düştükçe yoğun bitki örtüsünde ise azaldığını vurgulamışlardır. Ancak araştırmalarında gelişmiş sensör sistemlerinin heterojen otlaklarda, özellikle de hafif otlatılan meralarda yaş ot veriminin belirlenmesinde karşılaştığı zorluklara vurgu yaparak sensör teknolojisinin geliştirilmesine yönelik daha fazla araştırma yapılması gerektiğini dile getirmişlerdir.

Kayad vd. (2016), Suudi Arabistan'da Landsat-8 uydu görüntülerini ve verim monitöründen elde ettikleri verileri, bitki örtüsü indeksleriyle ilişkilendirerek yonca yaş verimini tespit etmek için araştırma yapmışlardır. Araştırma, dört yonca biçiminde balya makinesine monte edilmiş verim monitörü ve bitki örtüsü indekslerinin çıkarılması için arazi yapısını homojen biçimde temsil edecek şekilde 18 adet Landsat-8 uydu görüntüsü kullanılmışlardır. Verim monitörü ile ölçülen gerçek yonca verimi, kullandıkları tüm bitki örtüsü indekslerini tahmini verimle karşılaştırmışlardır. Çalışma sonucunda, en yüksek korelasyon değerlerini $R^2=0.69$, $R^2=0.68$ ve $R^2=0.63$ ile sırasıyla NIR, SAVI ve NDVI indekslerinden elde ettiklerini vurgulamışlardır. Verim monitöründen elde edilen veriler ve uzaktan algılama teknolojilerinin entegre edilmesiyle geniş alanlar için verim haritaları oluşturulabileceğini belirtmişlerdir.

Yegül (2016), yaptığı çalışmada buğdayın verim ve kalite parametrelerini modellemek amacıyla azot sensörleri ve bitki yansıma indekslerinin kullanımını araştırmıştır. Hassas tarım tekniklerinin kullanımıyla azot yönetimini optimize ederek buğday verimi ve protein içeriğini artırmayı amaçlayan çalışmasında, iki farklı buğday çeşidi (Bezostaya 1 ve Ahmetağa) çeşitlerini kullanmıştır. Araştırmasında beş farklı azot oranı (0, 80, 120, 160, 200 kg N/ha) uygulayarak, bu oranların verim ve protein içeriği üzerindeki etkilerini

incelemiş, NDVI (Normalize Edilmiş Vejetasyon İndeksi) ile NBI indeksini (Azot Denge İndeksi) kullanarak da azot eksiklikleri ve bitki biyokütlesini değerlendirmiştir. Elde edilen sonuçlara göre, NDVI ve hasat verimleri arasındaki ilişkiyi açıklamak için hesaplanan RI_{NDVI} ve RI_{Hasat} değerleri arasında yapılan regresyon analizlerine göre, 4. okuma döneminde $R^2=77.51$ ile en yüksek korelasyon değerini elde ettiğini ve diğer okuma dönemlerinde ise belirtme katsayısı (R^2) değerlerini sırasıyla $R^2=69.37$ ile $R^2=76.57$ arasında değiştiğini tespit etmiştir. Araştırma sonucunda NDVI ve NBI verilerinin buğday verim ve kalite parametrelerini tahmin etmede etkin bir yöntem olduğunu vurgulamıştır.

Yuan vd. (2017), araştırmada basit rastgele örnekleme (SRS) ve tabakalı rastgele örnekleme (STR) yöntemlerinden elde etikleri veri setleri kullanılarak, farklı büyüme dönemlerinde soya fasulyesinde yaprak alan indeksini (LAI) tahmin etmek için çeşitli regresyon modelleriyle çalışmışlardır. Karşılaştırdıkları modeller arasında rastgele orman (RF), yapay sinir ağı (ANN), destek vektör makinesi (SVM) ve kısmi en küçük kareler regresyonu (PLS) yer almıştır. Rastgele orman modeli, tüm büyüme dönemlerinde alınan STR örneklemeyle sırasıyla $R^2=0.741$, $R^2=0.031$, $R^2=0.106$ ve $R^2=0.005$ doğruluk değerlerine ulaşmıştır. Tek bir büyüme aşaması için ise yapay sinir ağı modeli, yine STR örneklemeyle sırasıyla $R^2=0.452$, $R^2=0.132$, $R^2=0.086$ ve $R^2=0.009$ değerlerinde tahmin edildiğini tespit etmişlerdir.

Noland vd. (2018), oluşturdukları lidar kameralı bir platformu ile yonca yaş ot verimini ve besin kalite parametrelerini tahmin etmek için tasarlamışlardır. Araştırmacıların ilk olarak, yoncada bitki örtüsün yansıma dalga boylarını tespit etmişlerdir. Daha sonra hava sıcaklığı ve çevresel faktörlerden kaynaklı bitki örtüsü yansımaları ile platformdan elde ettiklerini birleştirerek bir yöntem geliştirmişlerdir. Araştırma sonucunda yaş ot verimini $R^2=0.84$, ham protein oranını $R^2=0.87$ ve NDF oranını $R^2=0.86$ düzeylerinde tahmin edebildiklerini belirtmişlerdir. Araştırmacılar, bu çevresel büyüme göstergelerinin uzaktan algılama teknolojileri ölçümleriyle birleştirilmesinin, her iki yaklaşım içinde tek başına kullanılmasından daha yüksek tahmin doğruluğu ile sonuçlanacağını vurgulamışlardır. Aynı zamanda çalışmalarının yoncanın verim ve kalite parametrelerinin

verimliliğinin doğruluğunun artırma potansiyelinin olduğunu, geleneksel yaklaşımlara kıyasla umut verici bir alternatif sunduklarını dile getirmişlerdir.

Sanches vd. (2018), şeker kamışı tarlalarında verim tahmini yapabilmek için İHA'dan elde ettikleri RGB (kırmızı, yeşil, mavi) görüntülerinin kullanımını araştırmışlardır. Çalışmalarında, İHA görüntülerinden elde edilen Yeşil-Kırmızı bitki örtüsü indeksinin (GRVI) mahsul veriminin genel durumunu etkili bir şekilde yansıtabileceğini gösterdiğini belirtmişlerdir. Ayrıca bu indeks diğer indekslerle entegre edildiğinde, verim tahminini önemli ölçüde arttırdığını ve şeker kamışı yetiştiriciliğinde yüksek verimli fenotipleme için İHA tabanlı görüntülemenin potansiyelini vurgulamışlardır.

Cazenave vd. (2019), araştırmalarında RGB kameralı İHA el tipi sensör ve manuel ölçümler olmak üzere üç farklı metodoloji uygulayarak yoncanın bitki boyunu yaş ot ve kuru ot verimi tahmin etmeyi amaçlamışlardır. Araştırma sonucunda NDVI indeksi yaş ve kuru ot verimi tahmininde $R^2= 0.48$ ile $R^2= 0.68$ arasında bitki boyunu tahmin etmede ise $R^2=0.65$ ile $R^2= 0.82$ aralığında tespit etmişlerdir. Bu durumun İHA ve sensörden elde edilen verilerin araziden alınan fiziksel ölçümlerle yakından ilişkili olduğunu tespit ettiklerini ifade etmişlerdir. Yazarlar yüksek verimli saha tabanlı fenotipleme yöntemlerinin bitki özelliklerini hızlı ve verimli bir şekilde değerlendirmek için etkili araçlar olduğunu ve bunun da bitki ıslah programlarının verimliliğini artırmada kullanılabilineceğini vurgulamışlardır.

İleri (2020), 2017-2018 yıllarında yaptığı araştırmada Sündiken Sırdadağları'nın Bozdağ yöresine ait meralarında bitki örtüsü, yem üretimi ve kalitesindeki mevsimsel değişimleri belirlemek amacıyla uzaktan algılama teknolojilerini kullanmıştır. Araştırmasında, meraların kuzey ve güney yöneyleriyle zirvede bulunan bitkilerin, botanik kompozisyonu, yem kalitesi ve miktarının zaman içindeki değişimini gözlemlemek için NDVI bitki indeksinden yararlanmıştır. Araştırmacı Sentinel 2A uydusundan elde ettiği NDVI yansıma değerleri ile elverişli yem miktarının genel ortalamalar üzerinden tahmin edilemeyeceği, bunun nedenini ise iklimsel değişkenlik ve odunsu bitkilerin yansıma değerlerini bozmasından kaynaklı olduğunu belirtmiştir. Dönemsel incelemelerinde özellikle temmuz-ağustos ve ekim aylarında NDVI indeksinin yem üretimindeki

değişimini tespit ettiğini vurgulamıştır. Araştırmanın sonucunda Ham protein oranı $R^2=0,56$ düzeyinde, NDF oranı $R^2=0,070$ ile $R^2=0,293$ değerleri arasında tahmin edilmiştir. Araştırmacı ADF ve Sindirilebilir kuru madde (SKM) oranlarını ise orta düzeyde $R^2 = 0,40$ ile $R^2=0,41$ değerlerinde tespit ettiğini bildirmiştir.

Prestes vd. (2020), yaptıkları çalışmada İHA ile elde ettikleri görüntülerden çıkardıkları bitki örtüsü indekslerini kullanarak soya fasulyesi verimini tahmin etmeye odaklanmışlardır. Çalışmalarında, RGB tabanlı Görünür Atmosferik Direnç İndeksinin (VARI) soya fasulyesi verim tahmini için en iyi korelasyon değerlerine sahip olduğunu belirlemişlerdir. Araştırmalarında, İHA görüntülerinin makine öğrenmesi teknikleriyle birlikte kullanılmasının soya fasulyesi için verim tahmin modellerin geliştirilerek hassas tarım uygulamalarında etkili bir şekilde kullanılabileceğinin altını çizmişlerdir.

Wijesingha vd. (2020), Almanya'nın Hessen eyaletinde hiperspektral kameralı İHA ile sekiz merada ham protein ve asit deterjan lif konsantrasyonlarını yem kalitesini tahmin etmek için araştırma yürütmüşlerdir. Ham protein oranını en yüksek normalize edilmiş karekök ortalama hata ile %10, ADF oranını ise %13.4 olarak tespit etmişlerdir. Araştırma sonucunda mekânsal dağılım haritaları, farklı otlaklar ve yönetim uygulamaları arasında yem kalitesinde önemli değişkenlikler olduğunu ve heterojen ortamlarda yem kalitesini değerlendirmek için İHA ile uzaktan algıma tekniklerinin etkin olduğunu vurgulamışlardır.

Dvorak vd. (2021), yaptıkları çalışmada İHA ile görüntüleri alındıktan sonra ve arazide belirli konumlara yerleştirilen çerçevelerden yonca yaş ot örneklerini haftalık olarak topladıklarını belirtmişlerdir. Bitki boyu, olgunluk seviyesi, yabancı ot durumu, böcek zararı ve hastalık zararı gibi tahmin değişkenleri ile denetimli makine öğrenmesi modelleri geliştirmişlerdir. Oluşturdukları modelle, yaş ot verim için $R^2=0.81$, Asit Deterjan Lif (ADF) için $R^2=0.81$, Nötral Deterjan Lif (NDF) için $R^2=0.78$ ve ham protein için $R^2=0.79$ değerlerinde ile doğru tahmin etmişlerdir.

Zhao vd. (2023), tekstür bilgilerinin spektral indekslerle birleştirilerek oluşturulan modellerin toprak tuzluluğun üzerindeki etkisini belirlemek için bir araştırma

yürütmüşlerdir. Araziden multispektral kameralı İHA ile görüntüler alındıktan sonra, yonca bitki örtüsü altındaki 0-15 cm, 15-30 cm ve 30-50 cm derinliğinde toprak örneklerini alarak, spektral yansımaya ve doku özelliklerini çıkarmışlardır. Bitki indeksi geliştirmek için, kırmızı kenar bandı ve hassas özellikleri seçmek amacıyla gri korelasyon analizi uyguladıklarını belirtmişlerdir. En yüksek ilişkiyi 0-15 cm derinlikteki toprak tuzluluğu modeli ile bitki indeksi ve doku indekslerinin oluşturduğunu vurgulamışlardır.

Sapkota vd. (2023), Güney Kaliforniya'daki multispektral ve termal İHA ile elde ettikleri görüntüler ve dört farklı yonca tarlasında bir biçimde araziden 180 noktadan aldıkları örneklerle yaş ot verimini çoklu regresyon yöntemiyle tahmin etmek istemişlerdir. Oluşturdukları modeller arasında normalleştirilmiş fark vejetasyon indeksinin (NDVI) $R^2=0.76$ ile en güçlü korelasyonu gösterdiğini tespit etmişlerdir. Araştırmada elde ettikleri sonuçların ve uyguladıkları yöntemin Güney Kaliforniya'da yonca verimini tahmin etmek için uygulanabilir olduğunu belirtmişlerdir.

Li vd. (2023), yaptıkları araştırmada biçim zamanlarında yonca yem verimini tahmin etmek için uydu tabanlı uzaktan algılama teknolojilerini kullanmışlardır. Araştırmada kullandıkları küresel bitki örtüsü nem indeksi (GVMI), normalleştirilmiş fark su indeksi (NDWI) ve normalleştirilmiş fark kızılötesi indeksi (NDII) gibi nemle ilgili bitki örtüsü indekslerinin, ilk biçimde yonca yem verimini tahminde etmede $R^2=0.50$, başarı düzeyinde tespit etmişlerdir. En yüksek korelasyon ilişkisini ise NDWI indeksinde $R^2=0.60$ elde etmişlerdir. Araştırma sonucunda nemle ilgili indekslerin tek parametrelili modeller için etkili olduğunu, makine öğrenmesi tabanlı çok parametrelili modellerin ise, büyük ölçekli yonca veriminin tahmin edilmesinde daha yüksek doğrulukla kullanılabilineceğini vurgulamışlardır.

Wang vd. (2023), yoncanın (*Medicago sativa* L.) bitki boyu ve yaş verimini belirlemek için İnsansız Hava Aracı (İHA) tabanlı multispektral görüntülerden (MSI) potansiyelini belirlemek amacıyla bir araştırma yürütmüşlerdir. Bitki boyunu yüksek çözünürlüklü multispektral görüntülerden çıkararak sayısal arazi modelini oluşturduklarını ve bitki boyu ile yer ölçümleri arasında $R^2=0.50$ ile $R^2=0.56$ ilişkili olduğunu dile getirmişlerdir. Yaş ot verimini ise geleneksel Normalize fark bitki örtüsü (NDVI) indeksi ile $R^2=0.73$

güçlü bir şekilde ilişkili olduğunu tespit etmişlerdir. Yaş ot verimini daha yüksek doğrultuda tahmin edememelerinin nedeninin NDVI indeksinin belirli doygunluğa ulaşmasından kaynaklı olabileceğini vurgulamışlardır.

Hernandez vd. (2024), multispektral sensörlü yüksek çözünürlüklü İHA görüntülerini kullanarak yarı kurak alanlarda meralarda yaş ot verimini tahmin etmek için modeller geliştirmeye çalışmışlardır. Yoğun bitki örtüsünün bulunduğu alanlar için, meradaki otların üç boyutlu (3D) ölçümünü çıkararak basit doğrusal regresyon modelleri ile $R^2=0.70$ doğrulukta, seyrek bitki örtüsünün bulunduğu alanlar için ise $R^2=0.53$ doğrulukta tahmin ettiklerini belirtmişlerdir. Araştırmada İHA platformları kullanılarak kabul edilebilir verim tahminlerinin hızlı bir şekilde yapılabileceğini dile getirmişlerdir.

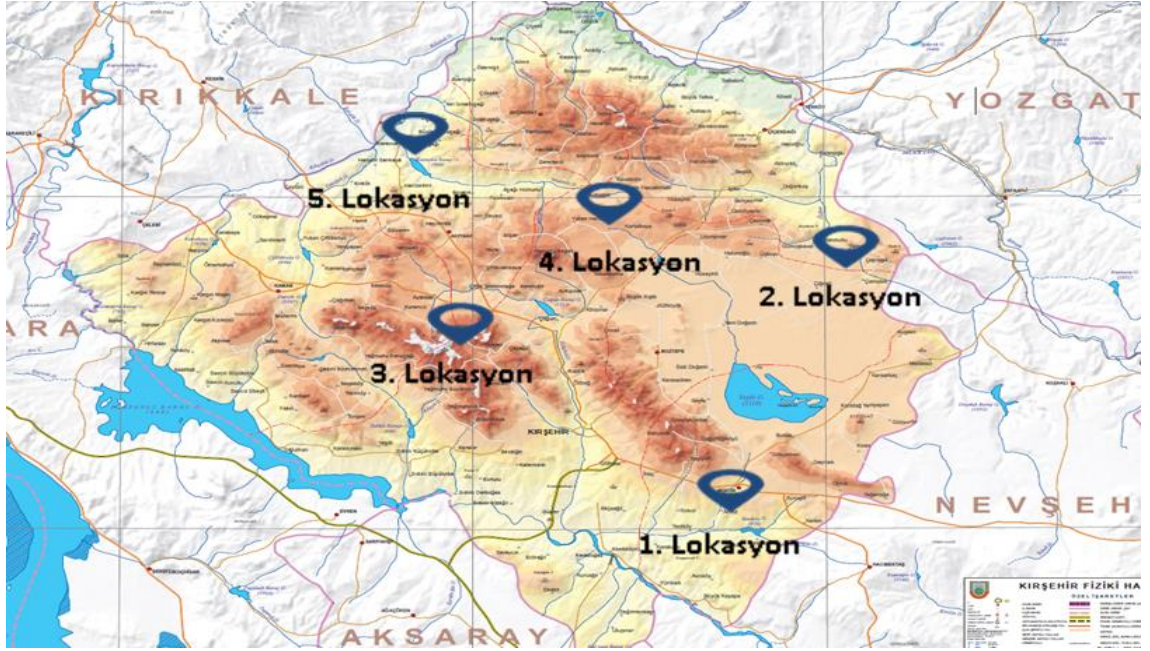
Gámez vd. (2024), Kuzey İspanya'nın Aragon bölgesinde yaptıkları araştırmada, sahadan el tipi hiperspektral spektrometreyle (350-2500 nm) topladıkları dalga boyu verilerini kullanarak yoncanın kalite parametrelerini tahmin etmek istemişlerdir. Elde ettikleri yansıma değerlerini biyokütle, pigmentler, şekerler, protein ve mineraller ile ilişkilendirmişlerdir. En yüksek korelasyon ilişkisini biyokütle için $R^2=0.71$ olarak belirlemişlerdir. Diğer parametreleri ise, sakkaroz $R^2=0.65$, flavonoidler için $R^2=0.56$ ve azot için $R^2=0.70$ olarak tahmin etmişlerdir.

Bao vd. (2024), İHA ile mısır verimini tahmin etmek için NDVI ve EVI bitki örtüsü indekslerini uygulamışlardır. Ürün fenolojik ölçütleriyle birleştirildiğinde, tahmin doğruluğunun daha da arttığını ve kademeli çoklu doğrusal regresyonun (SMLR) en yüksek $R^2=0.894$, en düşük RMSE'de ($1,238 \times 10^3 \text{ kg ha}^{-1}$) ulaştığını dile getirmişlerdir. Araştırmalarında, İHA'dan elde ettikleri görüntülerden çıkardıkları bitki örtüsü indekslerinin mısır verimi arasında yüksek bir korelasyon $R^2=0.92$ olduğunu belirlemişlerdir. Çalışmalarında İHA tabanlı bitki örtüsü indekslerin fenolojik verilerle entegre edilmesinin mısır bitkisinin verim tahminlerinin doğruluk oranlarını önemli ölçüde iyileştirebileceğini vurgulamışlardır.

3. MATERYAL VE YÖNTEM

3.1 Materyal

Bu tez çalışmasının ana materyallerini; 2023-2024 üretim sezonunda Kırşehir ili Kaman ilçesine bağlı İshocacı köyü, Boztepe ilçesine bağlı Yenidoğanlı köyü sınırları içinde yer alan Malya Tarım İşletmesi (TİGEM), merkeze bağlı Karahıdır, Terziali ve Değirmenkaşı köylerinde olmak üzere beş farklı lokasyondaki yonca tarlaları oluşturmuştur (Şekil 3.1).



Şekil 3.1 Araştırmanın yürütüldüğü lokasyonlar

Araştırma alanlarının koordinat ve yükseklik bilgileri Çizelge 3.1’de verilmiştir.

Çizelge 3.1 Araştırma alanlarına ait koordinat ve yükseklik bilgileri

Lokasyon	Koordinat		Yükseklik (m)
	Kuzey	Doğu	
Değirmenkaşı	38°52'14"	34°12'44"	932
İsahocalı	39°25'02"	33°54'30"	1275
Karahıdır	39°21'43"	34°04'59"	1190
Terziali	39°16'26"	33°59'43"	1352
Malya (TİGEM)	39°21'28"	34°06'03"	1219

3.1.1 Araştırma kullanılan insansız hava aracının (İHA) özellikleri

Araştırma alanlarından yüksek çözünürlüklü görüntüler elde etmek için DJI Phantom 4 Multispektral tarımsal İnsansız Hava Aracı (İHA) kullanılmıştır. İHA bir adet görünür ışık bandı ile kırmızı (R), yeşil (G), mavi (B), kızılötesi (NIR) ve kırmızı kenar (RE) bantlarından oluşan multispektral entegre bir görüntüleme sistemi ile donatılmıştır (Şekil 3.2 ve Çizelge 3.2).



Şekil 3.2 Araştırmada kullanılan multispektral kameralı İHA

Çizelge 3.2 Multispektral kameralı İHA'ya ait teknik özellikler

Kalkış Ağırlığı	1487 gr
Çapraz Mesafe (Pervaneler Hariç)	350 mm
Deniz Seviyesinden Maksimum Hizmet Yüksekliği	6000 m (19685 ft)
Maksimum yükselme Hızı	6 m/s (otomatik uçuş); 5 m / s (manuel kontrol)
Maksimum alçalma Hızı	3 m/s
Maksimum Hızı	31 mil (50 km/s) (P modu); 36 mil (58 km/s) (A modu)
Maksimum Uçuş Süresi	Yaklaşık 27 dakika
Çalışma sıcaklığı	0 °- 40 ° C (32 °- 104 ° F)
Çalışma frekansı	2.4000 GHz- 2.4835 GHz (Avrupa, Japonya, Kore) 5.725 GHz- 5.850 GHz (Diğer ülkeler / bölgeler)
İletim Gücü (EIRP)	2.4 GHz: <20 dBm (CE / MIC / KCC) 5.8 GHz: <26 dBm (FCC / SRRCC / NCC)
Hover Doğruluk Aralığı	RTK etkin ve düzgün çalışıyor: Dikey: ± 0.1 m; Yatay: ± 0.1 m RTK devre dışı: Dikey: ± 0.1 m (görüş konumlandırma ile); ± 0.5 m (GNSS konumlandırılmalı) Yatay: ± 0.3 m (görüş konumlandırma ile); ± 1.5 m (GNSS konumlandırılmalı)
Görüntü Konum Telafisi	Altı kameranın CMOS merkezinin ve yerleşik D-RTK anteninin faz merkezinin göreceli konumları kalibre edilmiş ve her görüntünün EXIF verilerine kaydedilmiştir.

İHA'nın görüntü çözünürlüğü 5.74 mm odak lensi ile 1600 × 1300 pikseldir. RGB ve multispektral sensör sayesinde aynı anda mavi, yeşil, kırmızı, kırmızı kenar ve yakın

kızılötesi bantlarda görüntü toplayabilmektedir. İHA'ya ait her bir bandın merkezi dalga boyu ve yarı-maksimum dalga genişliği Çizelge 3.3'te verilmiştir (Anonim 2024a).


Çizelge 3.3 İHA ile elde edilen multispektral görüntülerin spektral bölgesi ve dalga boyu aralığı

Bant	Dalga boyu aralığı (nm)
Mavi	450 ± 16
Yeşil	560 ± 16
Kırmızı	650 ± 16
Kırmızı kenar	730 ± 16
Kızılötesi	840 ± 26

3.2 Yöntem

3.2.1 Çalışma alanı

Araştırma sahasından İHA ile alınacak görüntülerin yonca örnekleriyle eşleştirilmesi için 1m x 1m ebatlarında 3 adet çerçeve hazırlanmıştır. Hazırlanan çerçevelerin her biri 0.25 m² alanı temsil edecek şekilde 3 köşesi farklı renge boyanırken, 1 köşesi ise boyasız olarak bırakılmıştır (Şekil 3.3). Daha sonra arazi yapısı incelenerek çerçeveler bitki örtüsü özelliklerini temsil edecek şekilde her bir lokasyonda 3 farklı noktaya yerleştirilerek İHA ile görüntü alındıktan sonra yonca örnekleri alınmıştır (Şekil 3.3, Şekil 3.4 ve Şekil 3.5).



Şekil 3.3 Araştırmada kullanılan 1 m²'lik çerçeveni görünümü




Şekil 3.4 Araştırmada kullanılan 1 m² 'lik çerçevelerin araziye yerleştirilmesi



Şekil 3.5 Araştırmada kullanılan çerçevelerin homojen yerleştirilmesinde uygulanan yöntem

3.2.2 Multispektral İHA ile görüntülerin alınması

Araştırmada, Şekil 3.2'de gösterildiği gibi, görünür spektrumun görüntülenmesi için bir RGB sensörü ve çoklu spektral görüntüleme için beş monokromatik sensör içeren 6 1/2.9 CMOS kullanan yüksek çözünürlüklü görüntü toplama amacıyla uzaktan algılama platformu olarak DJI Phantom 4 Multispektral tarımsal İHA kullanılmıştır. İHA'nın konumlandırma doğruluğunu artırmak ve uçuş rotasının planlanması için tüm uçuş görevleri DJI GS Pro (Ground Station Pro) platformunda gerçekleştirilmiştir (Şekil 3.6). DJI GS Pro platformu, DJI üretimi İHA'lar da kullanılmak üzere tasarlanmış profesyonel bir uçuş kontrol uygulamasıdır. Bu platformda görev planlama, 3D haritalama ve modelleme, sanal çit oluşturma, gerçek zamanlı veri izleme, çoklu uçuş kontrolü, özelleştirilebilir eylemler gibi çeşitli işlevler gerçekleştirilebilmektedir (Anonim 2024b).



Şekil 3.6 DJI GS Pro platformunda uçuş planlaması

İHA yerden 20 m yükseklikte, 5 m s⁻¹ hızda, piksel başına 0.86 cm görüntü çözünürlüğünde %80 boylamsal %80 yanal örtüşme ile uçacak şekilde ayarlanmıştır. Aynı zamanda DJI Gerçek Zamanlı Hareket (RTK) modülü etkinleştirilip İHA'nın konumlama hassasiyeti dikeyde ve yatayda olarak ± 0.1 m olacak şekilde DJ GS Pro platformuna girilmiştir.

Araştırmada kullanılan İHA'da güneş ışığı sensörü bulunmasına rağmen, verilerin araştırma koşullarında tekrarlanabilirliğini sağlamak amacıyla tüm saha uçuşları, yonca bitkisinin %10 çiçeklenme aşamasında ve hasattan bir gün önce sabah 10:00-14:00 saatleri arasında gerçekleştirilmiştir (Şekil 3.7).




Şekil 3.7 İHA ile görüntülerin alınması

Beş farklı lokasyondan alınan 14060 adet görüntü belirli zaman aralıklarıyla 6 saat 58 dakikalık İHA uçuşu ile elde edilmiştir (Çizelge 3.4).

Çizelge 3.4 Lokasyon ve biçim sayısına göre İHA görüntü alma tarihleri


Lokasyon	Biçim			
	1. Biçim Zamanı	2. Biçim Zamanı	3. Biçim Zamanı	4. Biçim Zamanı
Değirmenkaşı	13 Mayıs 2023	22 Haziran 2023	27 Temmuz 2023	4 Eylül 2023
İsahocalı	27 Mayıs 2023	30 Haziran 2023	8 Temmuz 2023	15 Eylül 2023
Karahıdır	21 Haziran 2023	26 Temmuz 2023	25 Ağustos 2023	30 Eylül 2023
Terziali	21 Mayıs 2023	29 Haziran 2023	4 Ağustos 2023	10 Eylül 2023
TİGEM (MALYA)	15 Mayıs 2023	24 Haziran 2023	26 Temmuz 2023	4 Eylül 2023

Araştırma sahasında elde edilen hava fotoğraflarını konum ve yönelim sistemiyle (POS) hizalamak ve çalışma alanının dijital ortofoto haritasını (DOM) oluşturmak için Pix4D tarafından geliştirilen ve tarımsal haritalama yazılımı olan lisanslı Pix4Dfields (sürüm 2.7.2) uygulaması kullanılmıştır (Şekil 3.8). Pix4Dfields yazılımında, İHA ile elde edilen görüntülerden hassas 3B modeller ve yüksek çözünürlüklü ortomozaikler oluşturmak için Hareketten Yapı (SfM) algoritmaları kullanılmıştır.



Şekil 3.8 Pix4Dfields yazılımı ile 1m x 1m'lik çerçevelerin kırılması

Araştırmada tüm lokasyonların biçim sayılarına göre çekilen görüntüler doğru bir şekilde coğrafi olarak referanslandırıldıktan sonra üst üste binen birden fazla görüntü bir araya getirilmiş ve ortomozaik görüntüleri oluşturulmuştur (EK 1-10). Daha sonra her lokasyonun farklı noktalarına yerleştirilen çerçevelerin içerisinde bulunan bitkilerin spektral dalga boylarını ve bitki indeks değerlerini hesaplamak için Pix4Dfields yazılımı aracılığıyla ilgili alanlar kırılmıştır (Şekil 3.9).



Şekil 3.9 Pix4Dfields yazılımı ile 0.25 m x 0.25 m'lik alanların kırılması

Araştırma alanında saha verisiyle eş değer olacak şekilde çerçevelerin 0.25 m x 0.25 m kısmı tekrardan kırılıp, ilgili alanların içerisine on adet nokta atılarak ortalama bitki örtüsü indeks değerleri çıkarılmıştır. Çerçevelerdeki 0.25 m x 0.25 m'lik kısımların kırılması işlemi örnekleme alanını standartlaştırarak farklı bölgelerden elde edilen verilerin karşılaştırılmasını sağlamak amacıyla yapılmıştır. Bu ölçü, yeterince küçük olup bitki örtüsü indeksinin daha hassas ve homojen bir şekilde hesaplanmasına olanak

tanırken, aynı zamanda yeterli büyüklükte olduğu için istatistiksel olarak anlamlı sonuçların çıkmasını sağlamıştır.

3.2.3 Çalışmada kullanılan bitki indeksleri

Araştırma alanlarından çeşitli kalite parametrelerini elde etmek için 16 adet bitki örtüsü indeksi ve 6 farklı spektral dalga boyu kullanılmıştır. Araştırmada kullanılan bitki örtüsü indekslerinin seçiminde gölgelik yansımalarını, toprak arka plan gürültülerini ve atmosferik yansımaları minimum düzeye indiren ve araştırmada incelenen kalite parametreleri için literatürde yaygın olarak kullanıldığı bildirilen bitki indekslerinin seçilmesine dikkat edilmiştir. Söz konusu indeksler ve formülleri aşağıda gösterilmiştir.

Yeşil Normalleştirilmiş Fark Bitki İndeksi (GNDVI): GNDVI bitki indeksi, 540 ile 570 nanometre arasındaki yeşil spektrumunu ölçtüğü için klorofil konsantrasyonuna karşı daha duyarlıdır. GNDVI indeksinin yeşil spektrumu kullanması, özellikle klorofil içeriği açısından bitki örtüsündeki değişikliklere karşı NDVI indeksine kıyasla ek hassasiyet sağlar (Gitelson ve Merzlyak 1998). İndeks -1 ile +1 değeri aralığındadır.

$$GNDVI = \frac{(NIR - GREEN)}{(NIR + GREEN)}$$

Mavi Normalleştirilmiş Fark Bitki İndeksi (BNDVI): BNDVI, klorofil içeriğine duyarlı alanlar için görünür mavi bandı kullanır. Kırmızı bandı bulundurmeyen bir indekstir (Wang vd. 2007). BNDVI, NDVI indeksine benzer şekilde çalışmakta, ancak mavi spektruma odaklanarak bitki örtüsünün sağlığını ve canlılığını izlemek için kullanılmaktadır. İndeks -1 ile +1 değeri aralığındadır.

$$BNDVI = \frac{(NIR - BLUE)}{(NIR + BLUE)}$$

Klorofil Kırmızı Kenar Bitki İndeksi (CL_{Rededge}): NIR ve kırmızı kenar bantlarındaki yansıtma oranını kullanarak yapraklardaki klorofil içeriğini tahmin etmek için kullanılan bitki örtüsü indeksidir (Gitelson vd. 2005). İndeks 0 ile +1 değeri aralığındadır.

$$CLREDEGE = \left(\frac{(NIR)}{(REDEGE)} - 1 \right)$$

Dikey Bitki Örtüsü Bitki İndeksi (DVI): Bitki örtüsünün varlığını ve durumunu değerlendirmek için kullanılan en temel bitki örtüsü indekslerinden biridir. Toprak ve bitki örtüsü arasında ayırım yapar, fakat atmosferik etkilerin neden olduğu yansıtma değişikliklerine karşı hassasiyeti azdır (Tucker 1979). Yakın kızılötesi (NIR) ve kırmızı spektral bantlardaki yansıtma arasındaki farkı ölçmektedir. DVI indeksi normalize edilerek NDVI indeksi türetilmiştir. İndeksin sabit bir değer aralığı yoktur, sensörün yansıtma değerlerine bağlı olarak değişebilmektedir.

$$DVI = (NIR - RED)$$

Geliştirilmiş Bitki İndeksi (EVI): EVI indeksi ilk olarak Orta Çözünürlüklü Görüntüleme Spektrometresi uydusundan (MODIS) elde edilen verilerle yüksek yaprak alanlarına sahip bölgelerin bitki örtüsünü tespit etmek için kullanılmıştır (Huete vd. 1997). NDVI indeksinin geliştirilmiş versiyonudur. NDVI indeksinin doygunluğa ulaştığı durumlarda kullanılır. Bu indeks toprak arka plan sinyallerini düzeltmek ve atmosferik etkileri azaltmak için mavi yansıtma bölgesini kullanır. İndeks -1 ile +1 değeri aralığındadır fakat sağlıklı bitki örtüsü indeksi için genellikle 0 ile +1 değerindedir.

$$EVI = 2.5 * \left(\frac{(NIR - RED)}{(NIR + 6 RED - 7.5 * BLUE + 1)} \right)$$

Yeşillik Klorofil Bitki İndeksi (LCI): İndeks klorofil emiliminin neden olduğu yansıma değişimine duyarlılığından dolayı bitkilerde klorofil içeriğini tahmin etmek için kullanılmaktadır (Piekkielek ve Fox 1992). İndeks 0 ile +1 değeri aralığındadır.

$$LCI = \frac{(NIR - REDEGE)}{(NIR + RED)}$$

Normalize Edilmiş Kırmızı Kenar Bitki İndeksi (NDRE): NDRE, uzaktan algılamada bitkilerdeki klorofil içeriğini ve bitkilerin canlılığını ölçmek için kullanılan bir bitki örtüsü indeksidir. Yakın Kızılötesi (NIR) bandı ile görünür kırmızı ve NIR bandı arasındaki kırmızı kenar (Rededge) aralığının bir kombinasyonu kullanılarak türetilmiştir (Maccioni vd. 2001; Sims ve Gamon 2002). İndeks -1 ile +1 değeri aralığındadır.

$$NDRE = \frac{(NIR - REDEGE)}{(NIR + REDEGE)}$$

Normalize Edilmiş Fark Bitki İndeksi (NDVI): NDVI, sağlıklı yeşil bitki örtüsünün yoğunluğunu ve bitki sağlığındaki değişimleri belirlemek için en yaygın kullanılan bitki örtüsü indeksidir (Rouse vd. 1974). Bununla birlikte, biyokütlenin arttığı, yoğun bitki örtüsü koşullarında doygunluğa ulaşabilmektedir. İndeks -1 ile +1 değeri aralığındadır.

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)}$$

Basit Oran Bitki İndeksi (SR): Bu indeks bitki örtüsü için en yüksek yansıtmaya sahip dalga boyu ile en derin klorofil emiliminin dalga boyuna oranıdır (Jordan 1969). Temel indekslerden biri olarak kabul edilir. Ancak, yoğun bitki örtüsüne sahip alanlarda NDVI gibi doygunluğa ulaşmaktadır. İndeks 0 ile +30 değeri aralığındadır.

$$SR = \frac{(NIR)}{(RED)}$$

Ters Yansıma Bitki İndeksi (RVI): RVI, kırmızı yansımanın, yakın kızılötesi (NIR) yansımaya oranı şeklinde formülize edilmiştir. Bitki örtüsünü toprak yüzeyinden ayırt etmek amacıyla geliştirilmiştir. RVI indeksi, biyokütle miktarına duyarlılığıyla bilinen bir parametredir (Rondeaux vd. 1996). İndeks 0 ile +1 değeri aralığındadır.

$$RVI = \frac{(RED)}{(NIR)}$$

Optimize Edilmiş Toprak Ayarlı Bitki İndeksi (OSAVI): Bu indeks toprak düzeltilmiş bitki örtüsü indeksinin (SAVI) optimize edilmiş halidir. Bitki örtüsü arka planındaki gölgelik değerini ayarlamak için 0.16'lık standart bir değer kullanılmaktadır. Rondeaux vd. (1996) bu değer yetersiz bitki örtüleri için SAVI indeksinden daha fazla toprak çeşitliliğine duyarlı olduğunu, fakat %50'den fazla bitkiyle kaplı alana sahip bitki örtülerinde daha fazla hassasiyet gösterdiğini vurgulamıştır. Dolayısıyla toprağın görülebildiği nispeten seyrek bitki örtüsüne sahip alanlarda daha iyi sonuç vermektedir. İndeks 0 ile +1 değeri aralığındadır.

$$OSAVI = \frac{(NIR - RED)}{(NIR + RED + 0.16)}$$

Modifiye Edilmiş Klorofil Emilim Oranı Bitki İndeksi (MCARI): MCARI indeksi Daughtry vd. (2000) tarafından toprak arka planı ve atmosferik koşullardan kaynaklı dış faktörlerden gelen yansımaların etkisini azaltarak bitkilerdeki klorofil içeriğini tahmin etmek için CARI indeksinden modifiye edilerek geliştirilmiştir. İndeksin sabit bir aralığı yoktur, değerler belirli yansıma ölçümlerine göre değişebilmektedir.

$$MCARI = \left(\frac{(REDEEDGE - RED) - 0.2 * (REDEEDGE - GREEN)}{(REDEEDGE)} \right) * (RED)$$

Görünür Atmosferik Direnç Bitki İndeksi (VARI): VARI indeksi, özellikle atmosferik etkilere karşı düşük hassasiyete sahip alanların bitki örtüsünün oranını tahmin etmek için geliştirilmiştir (Gitelson, Stark, vd. 2002). İndeks -1 ile +1 değeri aralığındadır.

$$VARI = \frac{(GREEN - RED)}{(GREEN + RED - BLUE)}$$

Üçgen Yeşillik Bitki İndeksi (TGI): Üçgen Yeşillik İndeksi (TGI) olarak adlandırılan bu indeks adında da anlaşılacağı gibi köşeleri kırmızı, yeşil ve mavi dalga boylarında olan bir yaprak yansıma spektrumunu sınırlayan bir üçgenin alanını temsil edecek şekilde geliştirilmiştir (Hunt vd. 2011; Hunt vd. 2013). TGI indeksinin formülasyonunda kırmızı, yeşil ve mavi dalga boyu merkezleri için 10 nm bant genişliğiyle 670 nm 550 nm ve 480 nm kullanmıştır. İndeksin sabit bir aralığı yoktur, değerler belirli yansıma ölçümlerine göre değişebilir.

$$TGI = (GREEN - 0.39 * RED) - (0.61 * BLUE)$$

Üçgen Klorofil Emilim Oranı Bitki İndeksi (TCARI): TCARI, toprak ve diğer çevresel faktörler gibi fotosentetik olmayan unsurların etkisini en aza indirerek bitki yapraklarındaki klorofil içeriğini tahmin etmek için geliştirilmiştir. Bu indeks özellikle bitki sağlığını, besin durumunu ve verimliliği değerlendirmek içinde kullanılmaktadır (Haboudane vd. 2002). İndeksin sabit bir aralığı yoktur, değerler belirli yansıma ölçümlerine göre değişebilmektedir.

$$TCARI = \frac{(REDEdge - RED)}{(REDEdge - GREEN)} - 0.2 * \left(\frac{(REDEdge - GREEN)}{(REDEdge)} \right) * RED$$

Yaprak Pigment bitki indeksi (SIPI): SIPI indeksi, bitki yapraklarındaki karotenoid konsantrasyonunu tahmin etmek için tasarlanmıştır (Peñuelas vd. 1995). Bu da onu, özellikle pigment bileşimiyle ilgili olarak bitkinin fizyolojik durumunu tespit etmek için yararlı bir indeks haline getirmektedir. İndeks genellikle bitki örtüsündeki yapısında yüksek değişkenlik olan ormancılık alanlarında kullanılmak için geliştirilmiştir.

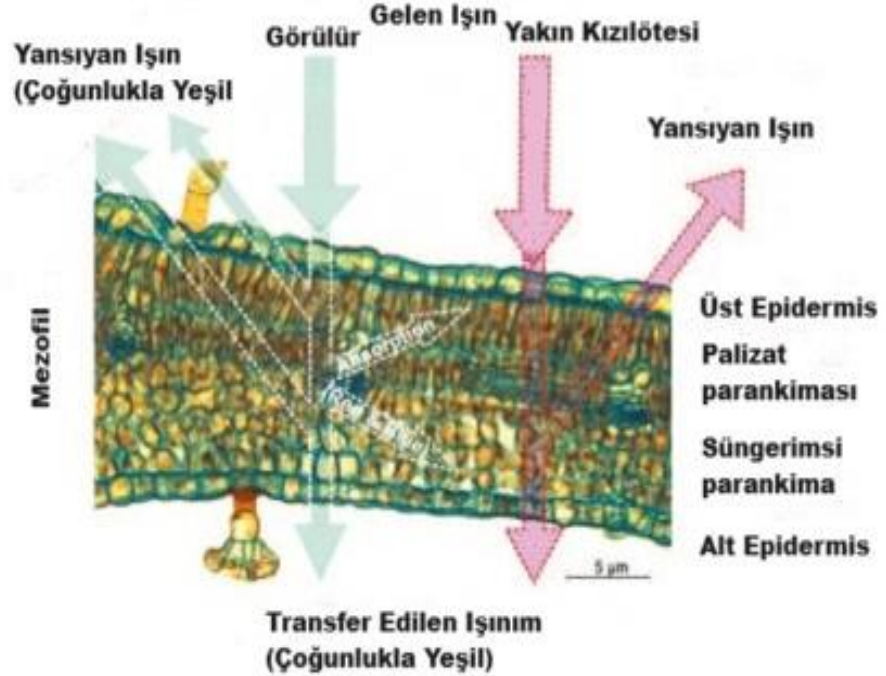
$$SIPI = \frac{(NIR - GREEN)}{(NIR - RED)}$$

3.2.4 Modifiye bitki indekslerinin geliştirilmesi

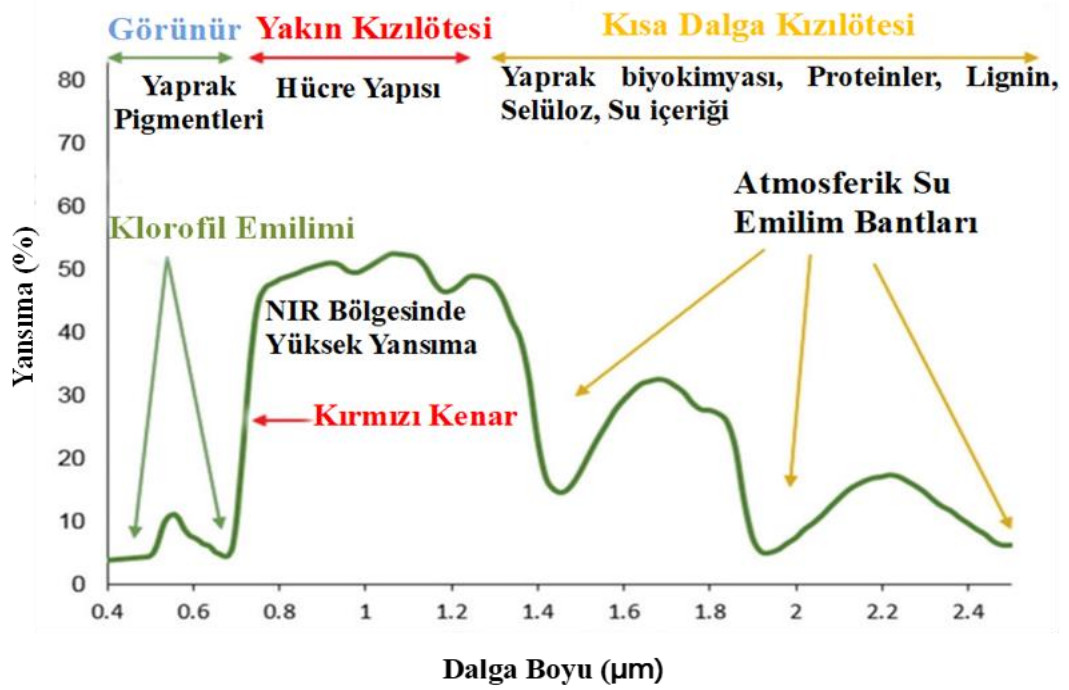
Uzaktan algılama teknolojileri ile klasik bitki indekslerinin türetilmesinde kullanılan en yaygın yöntem iki veya daha fazla spesifik dalga bandını basit oranlarla birleştirerek spektral indeksler oluşturmaktır (Pinter Jr vd. 2003; Hatfield vd. 2008; Ollinger 2011). Birçok bitki indeksi iki bandın oranları veya normalize edilmiş farkları kullanılarak hesaplanmıştır. Klasik bitki örtüsü indeksleri, bitki örtüsünde meydana gelen değişikliklere karşı farklı derecelerde duyarlıdır ve bu nedenle hassas ölçümlerde saçılmalar oluşabilmektedir (Şekil 3.10). Bu da bir indeksin sahada biyokütle yoğunluğundaki farklılıkların ayarlanabileceği kombine indekslerin geliştirilmesi gerekliliğini ortaya koymaktadır.

Tek bir spektral bandın içerdiği bilgi genellikle bitki örtüsü durumunu karakterize etmek için yetersiz olduğundan, bitki örtüsü indeksleri genellikle iki veya daha fazla spektral bandın birleştirilmesiyle geliştirilmektedir. Bu spektral bantların birleştirilmesiyle ilgili literatürde iki yöntem vardır. Bunlardan ilki eğim tabanlı, ikinci ise mesafe tabanlı bitki örtüsü indekslerini kullanarak yapılan kombinasyonlardır (Jackson ve Huete 1991; Clevers ve Gitelson 2013).

Eğim tabanlı indeksler spektral bantlar arasındaki orana veya farka dayanarak türetilen indekslerdir. Bu indeksler, bitki örtüsünün farklı yansıma özelliklerinden yararlanmak için genellikle kırmızı, kırmızı kenar ve yakın kızılötesi (NIR) bantlar olmak üzere, bantlar arasındaki eğime odaklanan indekslerdir (Jackson ve Huete 1991; Vescovo vd. 2012). Bu eğim tabanlı indeks yöntemi NIR bandından uzaklaşan veya dalga boyu yansımaları dağılan indeksleri, NIR dalga boyu aralıklarına yakınlaştırmak için kullanılır (Şekil 3.11).

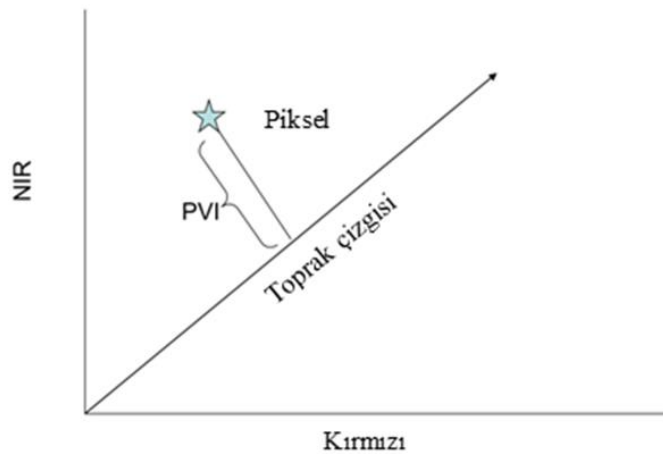


Şekil 3.10 Yeşil bir yaprağın hücre yapısı ve elektromanyetik radyasyonla etkileşimi (Roman ve Ursu 2016)



Şekil 3.11 Bitki örtüsünün spektral yansımaya eğrileri (Roman ve Ursu 2016; Jorge vd. 2019)

Mesafe tabanlı vejetasyon indeksleri spektral uzaydaki bir nokta (farklı bantlardaki yansıma değerleriyle tanımlanan) ile çıplak toprağı temsil eden bir referans çizgi veya nokta arasındaki öklid mesafesini ölçerek, bir pikselin yansımasının tipik toprak yansımasından ne kadar uzakta olduğunu belirleyen ve toprak arka planının etkisini en aza indirmek için geliştirilen indekslerdir (Richardson ve Wiegand 1977) (Şekil 3.12).



Şekil 3.12 Toprak yansıma çizgisinin mesafe tabanlı indeks ile ölçümü (Richardson ve Wiegand 1977)

Modifiye edilerek geliştirilen yeni indeksler, farklı matematiksel işlemler ve bant kombinasyonlarıyla bitkinin farklı fizyolojik süreçlerinde biyokütle, klorofil ve ham protein oranı gibi çeşitli parametreleri belirlemede daha hassas hale gelmektedirler (Haboudane vd. 2002; Haboudane vd. 2004; Eitel vd. 2009; Li vd. 2014). Hassasiyetin artırılması için, bitki örtüsündeki değişkenlik, toprak yansımaları ve atmosferik etkiler göz önünde bulundurulmalıdır. Bu etkileri minimize etmek için indeksler belirli katsayılar ile düzeltilerek modifiye edilmektedir. Bitki indekslerindeki söz konusu modifikasyonlar, belirli bitki özelliklerini daha hassas ölçebilmek ve bu indeksleri çevresel koşullara daha duyarlı hale getirmek için yapılmaktadır (Houborg vd. 2009; Jacquemoud vd. 2009).

Genel bir model oluşturmak ve modifiye bir bitki örtüsü indeksi elde etmek için tüm lokasyonlardan ve biçim zamanlarından elde edilen verilerin birleştirilerek analiz edilmesi en uygun yaklaşımdır (Haboudane vd. 2002). Bu yaklaşım, modelin daha geniş bir kullanım alanına sahip olmasını sağlamakla birlikte, farklı koşullar altında daha tutarlı ve güvenilir sonuçlar vermesine imkân tanır. Aynı zamanda indeksleri belirli ekosistemlere veya bitki örtüsü tiplerine daha iyi uyacak şekilde değiştirmek, çeşitli ortamlarda uygulanabilirliğini ve doğruluğunu da artırır.

Çalışmada yonca bitkisinde protein, NDF ve ADF oranlarının tespit edilmesi için NDRE ve $CL_{REDEEDGE}$ bitki indeksleri modifiye edilerek $MPNDRE$, $MNCL_{REDEEDGE}$ ve $MANDRE$ indeksleri geliştirilerek haritaları çıkarılmıştır (Ek 11-15).

3.2.5 Modifiye edilmiş protein normalize fark kırmızı kenar (MPNDRE)

Multispektral sensörlerde bulunan ek bantlar sayesinde proksimal sensörlere kıyasla kırmızı kenar tabanlı indekslerin hesaplanabilmesi önemli bir avantaj sağlamaktadır. Bunların arasında NDRE indeksi en yaygın kullanılanıdır (Santos vd. 2021).

$MPNDRE$ indeksi, $OSAVI$ ve $NDRE$ indeksinin güçlü yönleri birleştirilerek, $OSAVI$ indeksini $NDRE$ indeksinin karekökünü içeren bir faktörle normalleştirilerek elde edilmiştir. Bu formülasyon hem toprak hem de bitki özelliklerine dengeli bir duyarlılık

sağlayarak, bitki sağlığında ve bitkinin biyokimyasal özelliklerindeki spesifik değişiklikleri tespit etmek için geliştirilmiştir. Geliştirilen MPNDRE indeksinin formülü aşağıda gösterildiği gibidir;

$$MPNDRE = \frac{(OSAVI)}{(1 + \sqrt{NDRE})}$$

Formülasyon geliştirilirken arařtırmada kullanılan tüm bitki indekslerinin kombinasyonları denenmiş ve toprak arka plan yansımından kaynaklı gürültü yansımalarının protein oranını belirlemede olumsuz etki yarattığı gözlemlenmiştir. Bu yüzden protein oranını belirlemede en yüksek doğruluğu veren NDRE indeksine, toprak arka planından kaynaklı ortaya çıkan yansımaların etkilerini en aza indirmek için OSAVI indeksi entegre edilmiştir. OSAVI indeksinin geliştirilen indekse dahil edilmesi, toprak arka plan etkilerini en aza indirmesinin yanında deęişen saha koşullarında da yüksek hassasiyetle çalışmasını sağlamıştır.

3.2.6 Modifiye edilmiş NDF klorofil kırmızı kenar (MNCL_{REEDGE})

Klorofil içeriğini tahmin etmek için kullanılan bitki örtüsü indeksleri, ışığın yansımaya değeri ile bitkilerin biyokimyasal özellikleri arasındaki ilişkiden yararlanır. NIR ve kırmızı kenar bandı, klorofil de dahil olmak üzere çeşitli hücresel bileşenlerden etkilenen yaprakların iç yapısına karşı duyarlıdır (Cho vd. 2008; Kanke vd. 2016).

Bu indeksler tipik olarak elektromanyetik spektrumdaki belirli dalga boylarından, özellikle de yakın kızılötesi (NIR) ve görünür dalga boyu aralıklarından yararlanmaktadır. Bu dalga boyları manipüle edildiğinde indekslerin hassasiyeti artmakta ve klasik bitki indekslerinden elde edilen sonuçlara göre daha doğru sonuçlar elde edilmektedir (Pilon vd. 2010).

İndeks modifiye edilmeden önce diğer bitki indeksler ile yapılan denemelerde, indeksin NIR bandı bölgesine yakınlştırılması gerekliliđi görölmüştür. Bu nedenle formölasyonun pay kısmına NIR bandının karesi ve payda kısmına ise diğer bitki indeksleriyle yapılan uygulamalarda en yüksek NDF oranının tespit edildiđi CL_{REDEGE} indeksinin karesi alınarak yeni bir modifiye bitki indeksi geliştirilmiştir.

CL_{REDEGE} indeksinin karesinin alınmasının sebebi, indeksin bant kombinasyonunda bulunan kırmızı kenar bandının duyarlılıđını arttırmak, ince farklılıkları daha belirgin hale getirmek ve hassasiyeti güçlendirmektir. Kırmızı kenar bandı (Red-edge), genellikle bitki sađlıđındaki deđişiklikleri diğer bantlara göre daha hassas bir şekilde tespit edebilmektedir. Bu nedenle bant üzerindeki modifikasyonlar bitki indeksinin dođruluđunu artırmak için yapılmaktadır (Cho vd. 2008). Söz konusu işlemler, indeksin deđişikliklere karşı duyarlılıđını arttırmakta ve diğer bitki indekslerine kıyasla daha fazla hassasiyet sađlayan CL_{REDEGE} indeksinin performansını optimize etmektedir.

Formölün payda kısmında, kırmızı kenar bandı bulduran CL_{REDEGE} indeksinin bulunmasının nedeni, bitkide meydana gelen klorofil deđişimlerinin etkisinin normalleştirilerek, indeksin sabitlenmesi ve deđişimlerden dolayı ortaya çıkabilecek gürültü yansımalarının azaltılmasıdır. Diğer bir etken ise bitkide klorofil miktarı artıkça NDF oranının düşüş eğiliminde olması ve bitkinin hücre çeperi yapısının da buna bađlı olarak deđişmesidir. Geliştirilen MNCL_{REDEGE} indeksinin formölü aşıđıda gösterildiđi gibidir;

$$MNCLREDEGE = \frac{(NIR)^2 + 1}{(CLREDEGE)^2 + 1}$$

3.2.7 Modifiye edilmiş ADF normalize fark kırmızı kenar (MANDRE)

Araştırmada kullanılan bitkisel materyallerin ADF oranını belirlemek için modifiye indeks geliştirmeden önce, diğer bitki indeksleriyle yapılan denemelerde olduđu gibi indeksin NDF içeriđinin belirlenmesinde kullanılan yaklaşıma benzer şekilde NIR bandı bölgesine daha yakın olacak şekilde ayarlanması gerektiđini görölmüştür. Bu NIR bandı

ve kırmızı kenar bölgesi, bitki örtüsü yansımada keskin bir değişimin olduğu 680 ile 750 nm dalga boyu arasındaki spektral bölge olarak tanımlanmaktadır (Horler vd. 1983; Li vd. 2017). NIR tabanlı indeksler bitkileri lif içeriği ve bazı biyokimyasal özellikleriyle ilgili daha iyi korelasyonlar sağlamaktadır (Clevers ve Kooistra 2011).

İndeks modifiye edilirken NDF oranı belirlemede kullanılan formülasyon tekniğinin tersi uygulanmasına rağmen, bu modifiye indeksteki amaç ilgili spektral dalga boyunu NIR bölgesine yaklaştırmaktır. Buradaki farklılık aslında ADF parametresinin hücre duvarındaki yapısıyla ilgilidir. Buda aslında kırmızı bölgedeki klorofil emiliminin NIR bandının hücresel saçılmaya geçişinden kaynaklanmaktadır (Delegido vd. 2013; Xie vd. 2018). Bu nedenle ADF oranını tespit etmek, NDF oranını tespit etmekten daha zordur. Çünkü ilgili spektral dalga boyunda NIR bölgesinde dağılma (saçılma) meydana geldiğinden formülasyondaki NDF oranını belirlemede kullanılan yöntemin farklı bir durumu söz konusu olmuştur. Geliştirilen MANDRE indeksinin formülü aşağıda gösterildiği gibidir;

$$MANDRE = \frac{(NDRE + 1)}{(NIR)^2 + 1}$$

3.2.8 Sahadan örneklerin alınması


Tez çalışmasının yürütüldüğü beş farklı lokasyon ve dört biçim zamanında, arazinin farklı noktalarına yerleştirilen çerçevelerin içerisinde tesadüfen belirlenen 10 bitkinin her çerçevede toprak yüzeyinden bitki uç noktasına kadar olan yükseklikleri mm bölmeli cetvel ile ölçülmüştür (Şekil 3.13). Daha sonra 0.25 m x 0.25 m alanlar biçilerek kese kağıdına konularak tartım yapılmıştır ve bu değerlerden dekara yaş verimleri hesaplanmıştır (Şekil 3.14 ve Şekil 3.15).



Şekil 3.13 Bitki boyu ölçümü



Şekil 3.14 Araziden yaş ot örnek alımı



Şekil 3.15 Yaş ot örnek tartımı

Araziden alınan örnekler ön soldurma işlemi için 1-2 gün gazete kağıtlarının üzerinde bekletildikten sonra 60 °C'de sabit ağırlığa gelinceye kadar kurutulmuş daha sonra tartılmış ve dekara kuru ot verimleri hesaplanmıştır (Sleugh vd. 2000). Kuru ot verimleri hesaplandıktan sonra örnekler 0.1 mm eleği olan bir öğütme değirmeni yardımıyla öğütülmüş ve kalite parametrelerinin analizi için hazırlanmıştır (Şekil 3.16).



Şekil 3.16 Kalite parametrelerinin ölçümü için örneklerin hazır hale getirilmesi

3.2.9 Kimyasal analiz

Araştırma alanından yönteme uygun şekilde hazırlanan yonca örneklerinden ham protein, NDF ve ADF oranları belirlemek için kimyasal analiz işlemi gerçekleştirilmiştir.

Ham Protein Oranı (%): Yönteme uygun şekilde hazırlanan örneklerdeki toplam azot miktarları yaş yakma (Kjeldahl) yöntemiyle belirlenmiştir. Belirlenen toplam azot değerlerinin 6.25 katsayısıyla çarpılması sonucunda yonca kuru otunun ham protein oranları elde edilmiştir (AOAC 2005).

NDF Oranı (%): Yonca kuru otunun NDF oranlarının belirlenmesinde ANKOM200 Fiber Analyzer cihazı kullanılmış ve sonuçlar aşağıdaki formülden hesaplanmıştır (Anonim 2024a).

$$\text{NDF}_{\text{DM}} \% = \frac{(W_3 - (W_1 \times C)) \times 100}{W_2 \times \text{DM}}$$

W_1 = Ankom fiber torba ağırlığı

W_2 = Örnek ağırlığı

W_3 = Ekstraksiyon sonrası torba+örnek ağırlığı

DM= Kuru madde (%)

C= Boş torba (düzeltme faktörü)

ADF Oranı (%)

Alınan örneklerin ADF oranları ANKOM200 Fiber Analyzer cihazı kullanılarak, aşağıda verilen eşitlik yardımıyla hesaplanmıştır (Anonim 2021).

$$\text{ADF}_{\text{DM}} \% = \frac{(W_3 - (W_1 \times C)) \times 100}{W_2 \times \text{DM}}$$

W_1 = Ankom fiber torba ağırlığı

W_2 = Örnek ağırlığı

W3= Ekstraksiyon sonrası torba+örnek ağırlığı

DM= Kuru madde (%)

C= Boş torba (düzeltme faktörü)

3.2.10 Regresyon analizi

İHA kaynaklı bitki indeksleri kullanılarak yoncanın agronomik özelliklerini tahmin etmek için makine öğrenmesi tabanlı bir regresyon analizi yapılmıştır. Her lokasyonda 48 adet olmak üzere toplamda beş lokasyonda 240 adet örnek alınmıştır. Araştırmada elde edilen verilerin %80'i eğitim ve %20'si testte kullanılmak üzere iki sete ayrılarak, çıktı değişkenlerinin dağılımının her iki sette de tutarlı olmasını sağlamak amacıyla rastgele örnekleme yöntemi kullanılmıştır.

Doğrusal Regresyon Modeli: Bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi modellemek ve analiz etmek için kullanılan istatistiksel bir tekniktir. Amaç, bağımsız değişkenlerin bir fonksiyonu olarak bağımlı değişkeni en iyi tahmin eden doğrusal denklemi bulmaktır. Doğrusal regresyon modelinin genel formülü:
$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_p X_p + \epsilon \quad (1)$$

Y: Bağımlı değişken

β_0 : Bağımsız değişkenleri sıfıra eşit olduğunda y kesişimi

$\beta_1 X_1$: İlk bağımsız değişken (X_1) regresyon katsayısı

β_1 :ilk bağımsız değişkenin bağımlı değişken üzerindeki etki değeri

$\beta_p X_p$: Birden fazla girdi değerinin son bağımsız değişkenin

X_p : Regresyon katsayısı (β_p)

ϵ : Model hatası

Modelin bağımsız değişkenlerin, bağımlı değişkendeki varyasyonu ne ölçüde açıkladığını değerlendirmek için belirtme katsayısı olarak bilinen R^2 parametresi kullanılmıştır.

4. BULGULAR VE TARTIŞMA

4.1 Bitki Boyu

Araştırmada yonca bitki boyu ortalama değerleri lokasyonlara bağlı olarak 73.0-85.6 cm arasında, biçim sayılarına göre ise 59.9-94.1 cm arasında belirlenirken, ortalama bitki boyu değeri 78.1 cm olarak hesaplanmıştır (Çizelge 4.1).

Çizelge 4.1 Lokasyon ve biçim sayısına göre yonca bitki boyu değerleri (cm)

Lokasyon	Biçim				Ortalama
	1. Biçim	2. Biçim	3. Biçim	4. Biçim	
Değirmenkaşı	83.1	98.2	81.9	79.1	85.6
İsahocalı	96.9	85.1	76.4	45.8	76.1
Karahıdır	92.8	82.1	74.2	67.8	79.2
Terziali	98.0	88.0	62.0	46.0	73.0
Malya (TİGEM)	99.5	78.3	68.9	60.7	76.9
Ortalama	94.1	86.4	72.7	59.9	78.1

Yonca bitki boyunu belirlemede sahadan alınan bitki boyları ve İHA'dan alınan multispektral görüntülerin eşleştirilmesiyle oluşturulan modellere göre en yüksek belirtme katsayısı (R^2) değeri TCARI indeksinde, en düşük ise SIPI indeksinde elde edilmiştir (Çizelge 4.2). Buna karşın bitki boyunu belirlemek için oluşturulan tahmin denklemlerinde GNDVI'den en yüksek belirtme katsayısı $R^2= 0.819$ elde edilirken, en zayıf ilişki ise RVI bitki indeksinden $R^2= 0.196$ elde edilmiştir (Çizelge 4.2).

Bitki boyunu belirlemek için oluşturulan modellerin değerleri SIPI indeksi $R^2= 0.189$ dışında kalan diğer tüm indekslerdeki değerler $R^2= 0.826$ ile $R^2= 0.984$ arasında belirlenmiştir. Buna karşın oluşturulan tahmin modellerinin doğrusal regresyon denklemlerindeki değerleri GNDVI indeksine ek olarak yalnızca NIR ve kırmızı kenar bandı içeren LCI, CL_{REDEGE} ve NDRE indekslerinde sırasıyla $R^2=0.735$, $R^2=0.740$ ve $R^2=0.773$ kabul edilebilir düzeyin üzerinde olduğu görülmüştür.

Çizelge 4.2 Bitki boyunun belirlenmesinde kullanılan bitki indekslerinin model-tahmin regresyon değerleri ve denklemleri

İndeks	Model		Tahmin	
	R ²	Denklem	R ²	Denklem
GNDVI	0.967	y= -236+423 x GNDVI	0.819	y= 84.22+0.3888 x BB [‡]
BNDVI	0.902	y= -528.6+751.1 x BNDVI	0.195	y= 80.85+0.3288 x BB
CL _{REDEGE}	0.947	y= -6.799+125.4 x CL _{REDEGE}	0.740	y= 52.56+1.0211 x BB
DVI	0.968	y= -1.330+454.0 x DVI	0.422	y= 73.68+0.5227 x BB
EVI	0.965	y= -13.05+244.6 x EVI	0.480	y= 84.37+0.0601 x BB
LCI	0.972	y= -65.13+383.5 x LCI	0.735	y= 80.71+0.4715 x BB
NDRE	0.965	y= -44.12+491.4 x NDRE	0.773	y= 78.43+0.5421 x BB
NDVI	0.826	y= -301.5+430.9 x NDVI	0.302	y= 79.27+0.2866 x BB
SR	0.948	y= 13.17+3.816 x SR	0.671	y= 66.41+0.7801 x BB
RVI	0.966	y=10.92+1281 x RVI	0.196	y= -10.72+1.909 x BB
OSAVI	0.832	y= -41.28+247.9 x OSAVI	0.674	y= 85.75+0.1947 x BB
MCARI	0.931	y= -69.92+169.9 x MCARI	0.543	y= 123.5+0.4367 x BB
VARI	0.951	y= -28.86+184.7 x VARI	0.595	y= 83.40+0.3104 x BB
TGI	0.974	y= -27.15+193.4 x TGI	0.740	y= 94.29+0.2205 x BB
TCARI	0.984	y= 39.09+356.5 x TCARI	0.384	y= 88.81+0.2677 x BB
SIPI	0.189	y= -26.56+115.7 x SIPI	0.274	y= 80.95+0.0229 x BB

BB[‡]: Bitki Boyu

RVI genel olarak biyokütlenin belirlenmesinde kullanılan bir bitki indeksi olmakla birlikte, bitki boyu ile biyokütle arasındaki pozitif ilişki nedeniyle dolaylı olarak bitki boyunun belirlenmesinde de kullanılabileceği düşünülmektedir (Tang vd. 2021; Poudyal vd. 2023). Ancak RVI, GNDVI indeksi gibi toprak ve atmosferik koşulları minimuma indirecek kadar normalize edilmediği için beklenen yüksek doğrulukta sonuçları vermeyecektir (Xue ve Su 2017). Spektrumu yeşil bandına odaklanan GNDVI indeksi, bitkilerin klorofil içeriğine ve biyokütlesine daha duyarlı olduğu için bitki boylarının belirlenmesinde kullanılabilmektedir (Tucker 1979; Baldocchi vd. 2020). Araştırmadan elde edilen bulgular da bu doğrultudadır (Çizelge 4.2).

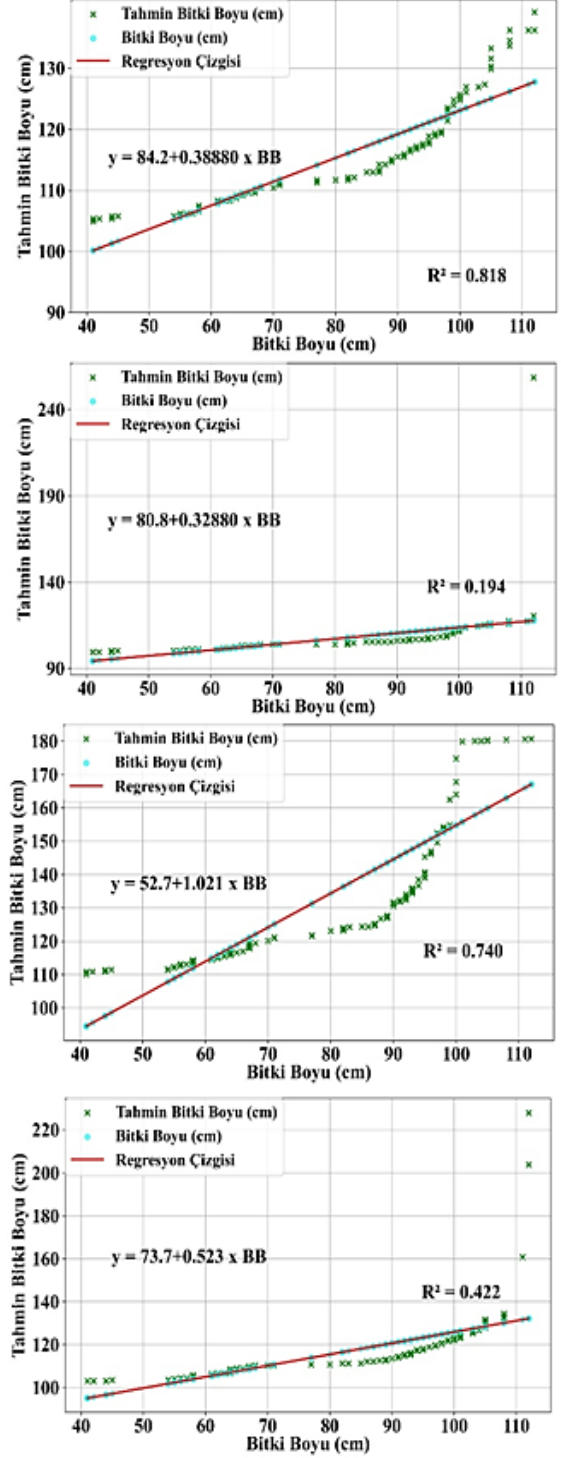
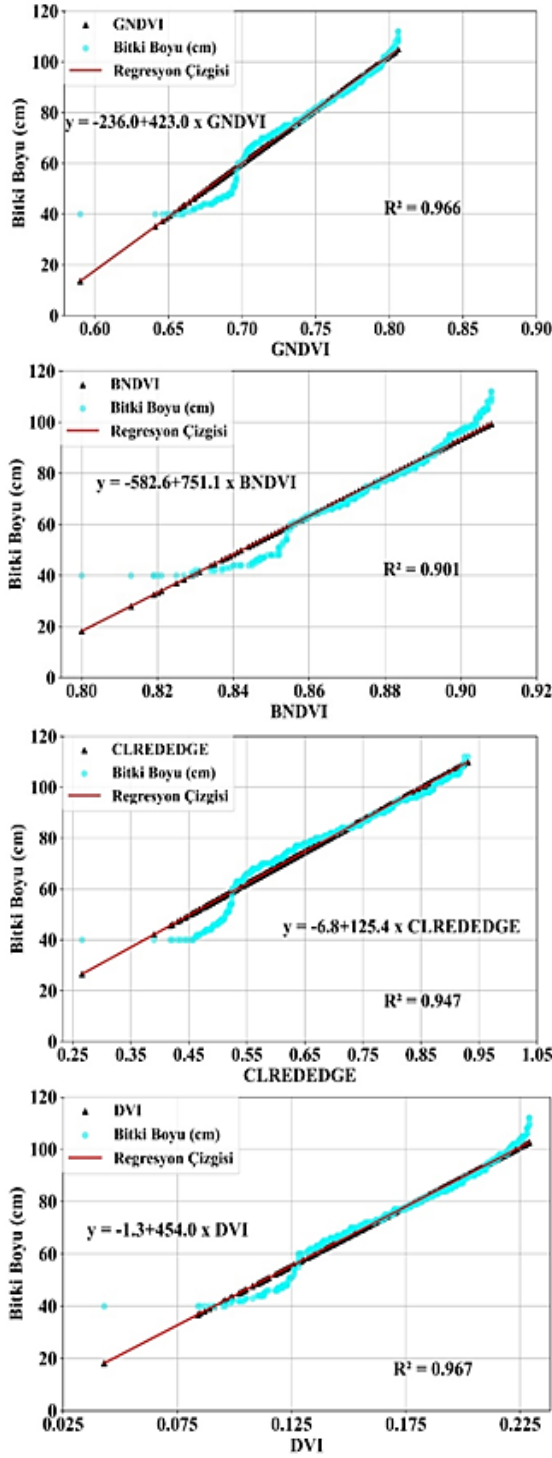
Araştırma sonucunda oluşturulan modellerin doğrusal regresyon grafikleri incelendiğinde, bitki indeksi modellerinin düşük bitki boyu değerlerini öğrenmede TCARI ve NDRE indeksleri dışındaki indekslerde hata verdiği görülmektedir. Bu durum TCARI ve NDRE indeksindeki aşırı öğrenmeden kaynaklanmaktadır. Nitekim modellerin değerleri içerisinde en yüksek TCARI indeksinde olmasına rağmen, bu indeksin tahmin modelinin değeri $R^2=0.384$ kabul edilebilir sınırın oldukça altında kalmaktadır. NDRE indeksi aşırı öğrenmeye karşın $R^2=0.773$ doğrulukta bitki boyunu tahmin etmiştir.

NDRE indeksinin tahmin modelinin R^2 değeri kabul edilebilir sınırlarda olmasına karşın, TCARI indeksinin R^2 değeri NDRE indeksine kıyasla oldukça düşük çıkmıştır. Bunun nedeni, her iki indeksin bitki örtüsü indeks değerleri aralıklarının ve hassasiyetlerinin farklı olmasından kaynaklanıyor olabilir. Buna ek olarak, bitki indeks değerleri 0.60 ile 0.80 aralığına sahip GNDVI indeksinin tahmin modeli, bazı düşük bitki boyu değerlerini hatalı öğrenmesine rağmen, bitki boyunu $R^2 = 0.819$ doğruluğunda tahmin ettiği görülmektedir (Şekil 4.1).

Tahmin modellerinin regresyon denklemlerine bakıldığında ise yüksek bitki boyu değerlerinin tahmin modeli tarafından hatalı tahmin edildiği görülmektedir (Şekil 4.1). Bu durumun, model denklemindeki aykırı değerlere bağlı olarak öğrenmenin tam anlamıyla gerçekleşmemesinden kaynaklanmış olabileceği söylenebilir.

MODEL

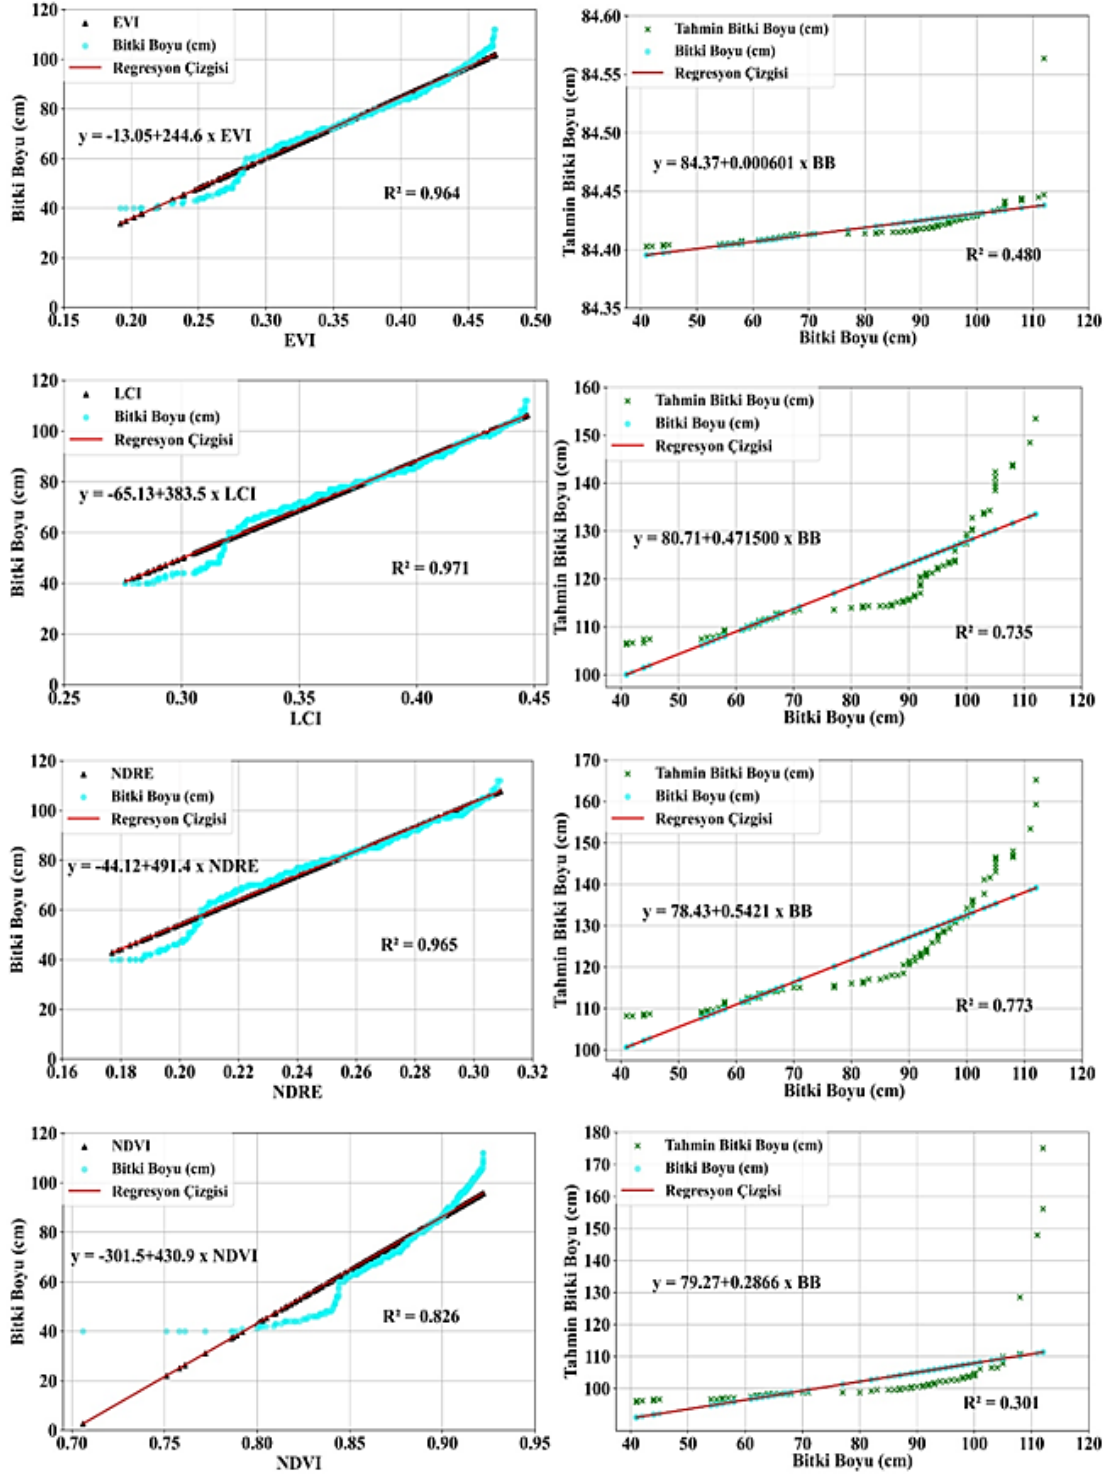
TAHMİN



Şekil 4.1 Bitki boyunun belirlenmesinde GNDVI, BNDVI, CL_{REDEGE} ve DVI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

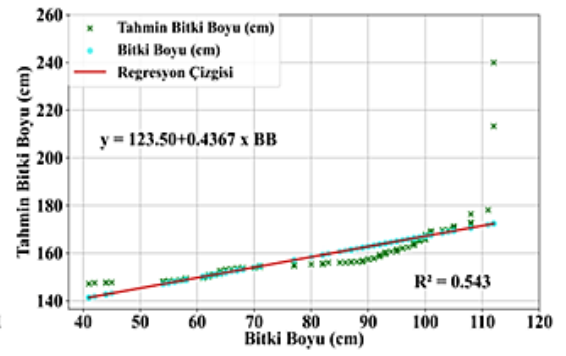
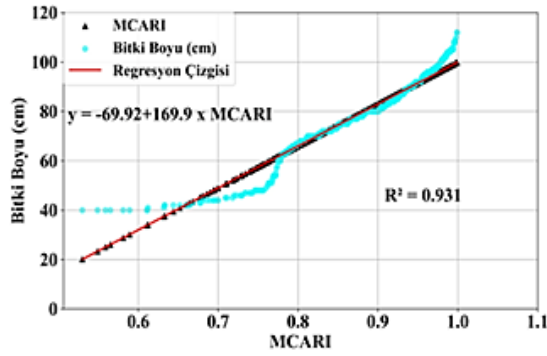
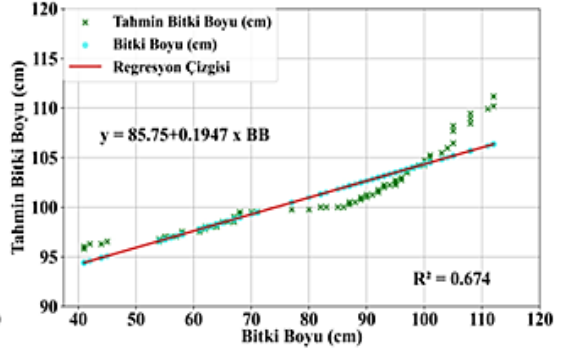
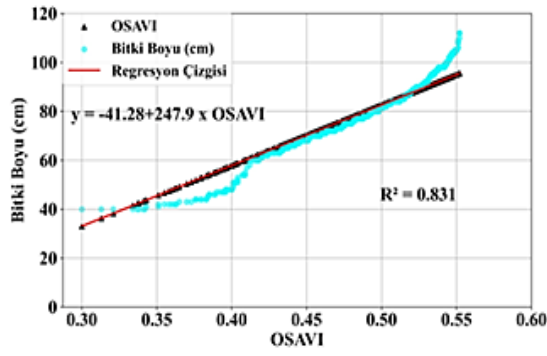
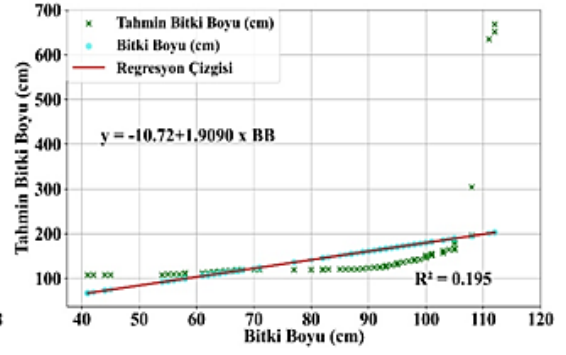
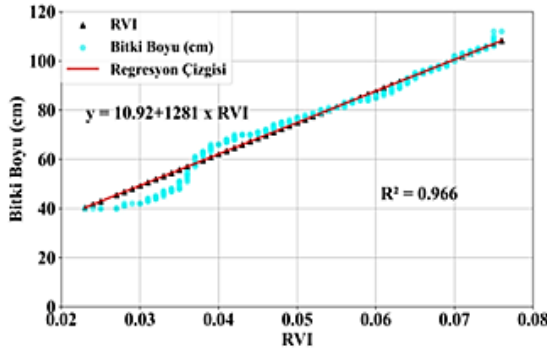

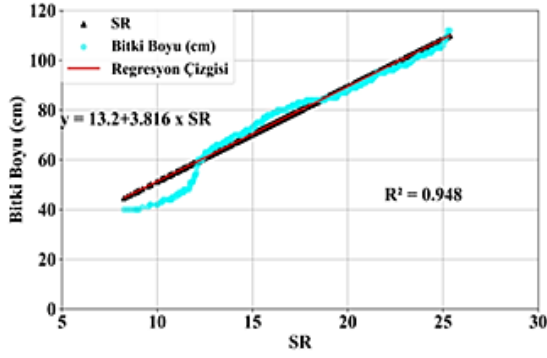
TAHMİN



Şekil 4.2 Bitki boyunun belirlenmesinde EVI, LCI, NDRE ve NDVI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

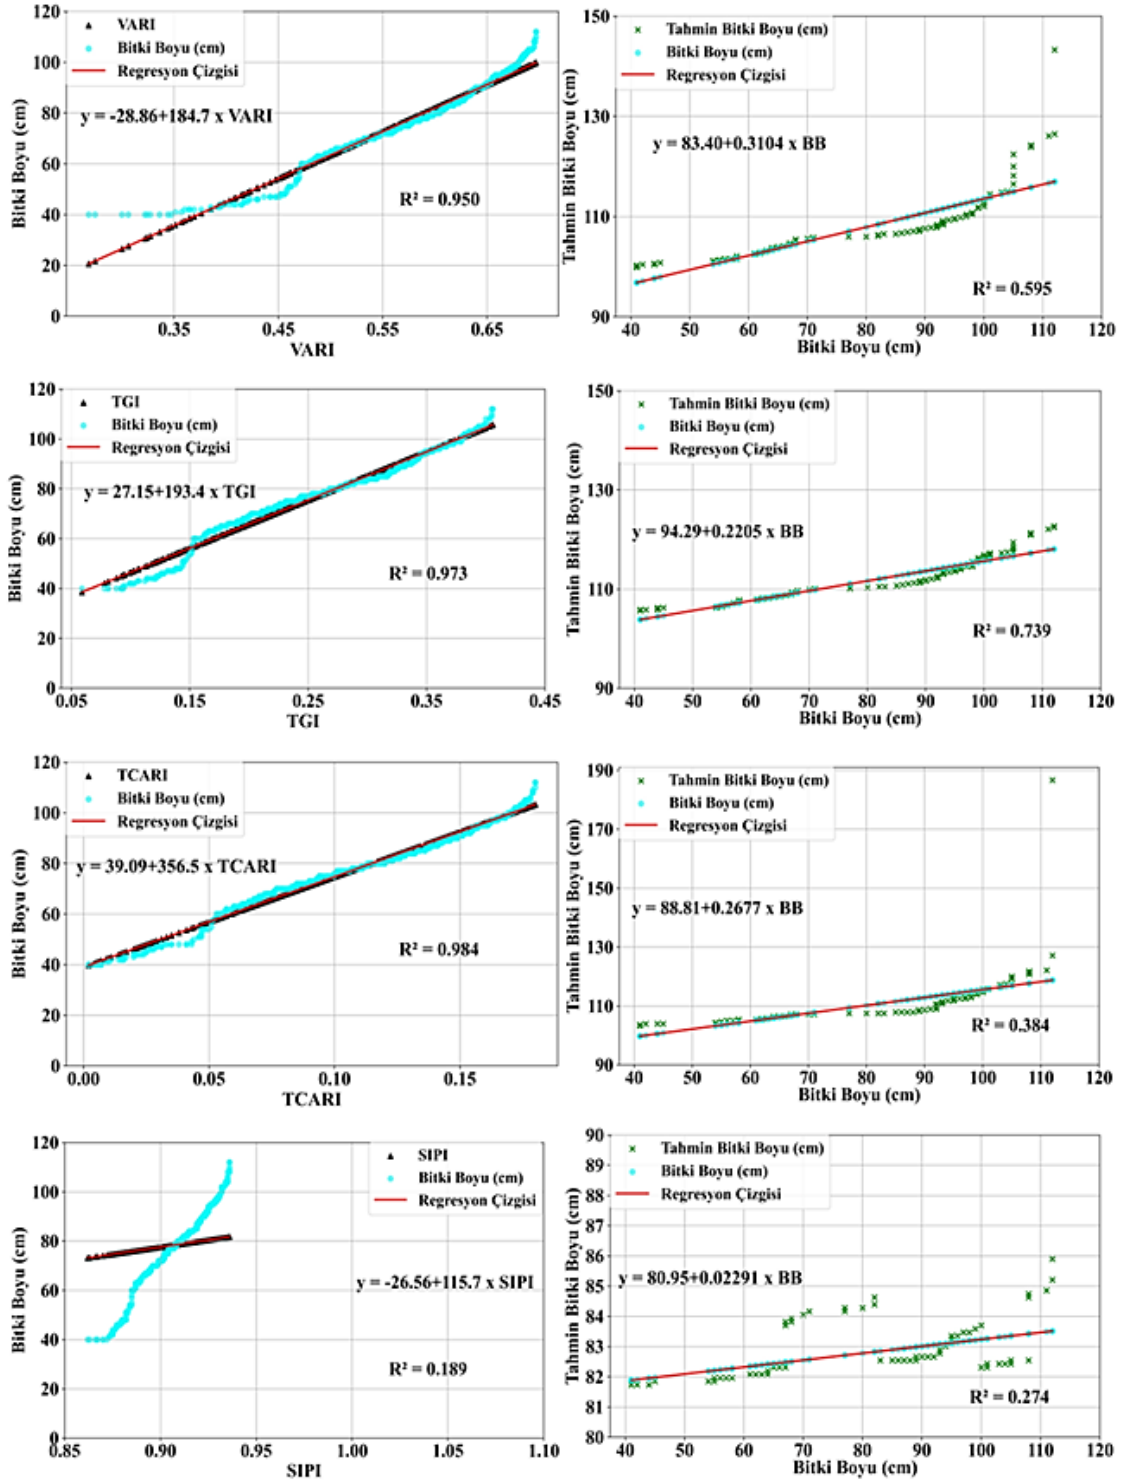
TAHMİN



Şekil 4.3 Bitki boyunun belirlenmesinde SR, RVI, OSAVI ve MCARI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

TAHMİN



Şekil 4.4 Bitki boyunun belirlenmesinde VARI, TGI, TCARI ve SIPI bitki indekslerinin model-tahmin regresyon grafikleri

4.2 Yaş Ot Verimi

Araştırmanın yürütüldüğü vejetasyon döneminde yapılan 4 biçimde ortalama yaş ot verim değerleri 1595.4-2493.8 kg da⁻¹ arasında değişirken, lokasyonlara bağlı olarak yaş ot verim değerleri ise 7159.0-8855.3 kg da⁻¹ arasında değişmiştir. Araştırmada tüm biçim zamanları ve lokasyonların ortalaması olarak yonca yaş ot verimi 8181.4 kg da⁻¹ olarak belirlenmiştir (Çizelge 4.3). Değirmenkaşı lokasyonunun 2. biçiminde hortumlu böcek zararı ve İsaııocalı lokasyonunun 3. biçiminde fare zararından dolayı yaş ot verim değerlerinde düşüş yaşanmıştır.

Çizelge 4.3 Lokasyon ve biçim sayısına göre yonca yaş ot verim değerleri (kg da⁻¹)

Lokasyon	Biçim				Toplam
	1. Biçim	2. Biçim	3. Biçim	4. Biçim	
Değirmenkaşı	2486.9	1750.3	2166.2	2074.1	8477.6
İsaııocalı	3171.8	2896.3	1018.6	1003.1	8089.9
Karahıdır	2190.5	2388.9	1922.4	1823.6	8325.5
Terziali	2114.8	1851.2	1874.9	1317.9	7159.0
Malya (TİGEM)	2504.9	2730.3	1861.7	1758.3	8855.3
Ortalama	2493.8	2323.4	1768.8	1595.4	8181.4

Yoncada yaş ot verim değerini tahmin etmek amacıyla Değirmenkaşı, İsaııocalı, Karahıdır, Terziali ve Malya (TİGEM) lokasyonlarından 4 farklı biçimde alınan yaş ot verim değerleri kullanılarak oluşturulan bitki indeksi modellerinin değerleri $R^2= 0.168$ ile $R^2= 0.996$ arasında değişmiştir (Çizelge 4.4). Oluşturulan modellerde en yüksek belirtme katsayılarının (R^2) elde edildiği NDRE indeksiyle birlikte, SIPI indeksi dışındaki diğer tüm bitki indeks modellerinin değerleri oldukça yüksek bir korelasyon ilişkisi ortaya koymuşlardır. Yaş ot verimiyle ilgili oluşturulan tahmin modellerinin değerleri $R^2= 0.240$ ile $R^2= 0.935$ arasında değişmiştir. En yüksek belirtme katsayısı değerinin elde edildiği NDRE bitki indeksiyle birlikte GNDVI, LCI, TGI, CL_{REDEGE}, MCARI, EVI, SR ve OSAVI indekslerinde de güçlü bir ilişki ortaya çıkmıştır.

Çizelge 4.4 Yaş ot veriminin belirlenmesinde kullanılan bitki indekslerinin model-tahmin regresyon değerleri ve denklemleri

İndeks	Model		Tahmin	
	R ²	Denklem	R ²	Denklem
GNDVI	0.980	y= -10497+16880 x GNDVI	0.934	y= 2281+0.6298 x YOY [§]
BNDVI	0.858	y= -23515+29046 x BNDVI	0.258	y= 2158+0.4999 x YOY
CL _{REDEEDGE}	0.989	y= -1402+5081 x CL _{REDEEDGE}	0.843	y= 242.2+2.129 x YOY
DVI	0.959	y= -1098+17917 x DVI	0.539	y= 242.6+0.00095 x YOY
EVI	0.951	y= -1550+9626 x EVI	0.688	y= 2294+0.5378 x YOY
LCI	0.991	y= -3696+15349 x LCI	0.906	y= 2207+0.7220 x YOY
NDRE	0.996	y= -2884+19786 x NDRE	0.935	y= 2177+0.8082 x YOY
NDVI	0.765	y= -12443+16436 x NDVI	0.559	y= 2255+0.3349 x YOY
SR	0.987	y= -588.1+154.3 x SR	0.719	y= 1523+1.295 x YOY
RVI	0.985	y= -650.9+51242 x RVI	0.369	y= -761.7+2.585 x YOY
OSAVI	0.784	y= -2556+9537 x OSAVI	0.698	y= 2228+0.3029 x YOY
MCARI	0.896	y= -3715+6602 x MCARI	0.786	y= 3949+0.5986 x YOY
VARI	0.909	y= -2109+7158 x VARI	0.658	y= 2195+0.5118 x YOY
TGI	0.990	y= 1.179+7730 x TGI	0.806	y= 2702+0.3468 x YOY
TCARI	0.981	y= 493.2+14110 x TCARI	0.496	y= 2486+0.4108 x YOY
SIPI	0.168	y= -1877+4326 x SIPI	0.240	y= 2156+0.02738 x YOY

YOY[§]: Yaş Ot Verimi

Spektrumun kırmızı kenar bandı, NDVI gibi geleneksel indekslerin sıklıkla tespit edemediği bitki sağlığındaki değişiklikleri ve biyokütle verimini tespit etmede oldukça kullanışlıdır (Gitelson ve Merzlyak 1994; Drusch vd. 2010; Zhang vd. 2012). Buna karşın NDRE indeksinin yonca verimini yüksek doğrulukta tahmin etmesi klorofil konsantrasyonuna duyarlı olması ve kırmızı kenar bandının dalga boyundaki çok küçük değişiklikleri yakalamasıyla ilişkilendirilebilmektedir. Kırmızı kenar bandının dolayısıyla NDRE bitki indeksinin avantajı NDVI, SR, VARI gibi geleneksel indeksler tarafından belirlenemeyen bitki örtüsündeki değişimleri tespit etmedeki hassasiyetinden kaynaklanmaktadır. (Gitelson vd. 2001; Clevers ve Gitelson 2013; Jorge vd. 2019). NDRE bitki indeksini diğer indekslerinden ayıran farklılıkların başında atmosferik etkilere karşı daha az duyarlı olması ve yoğun gölgelik koşullarında etkili olması gelmektedir. Bu da NDRE indeksini, geleneksel indekslerin doyumluğa ulaştığı veya

hatalı okumalar yaptığı yoğun bitki örtüsü ve yüksek biyokütlenin olduğu alanlar için özellikle uygun hale getirmektedir (Delegido vd. 2013).

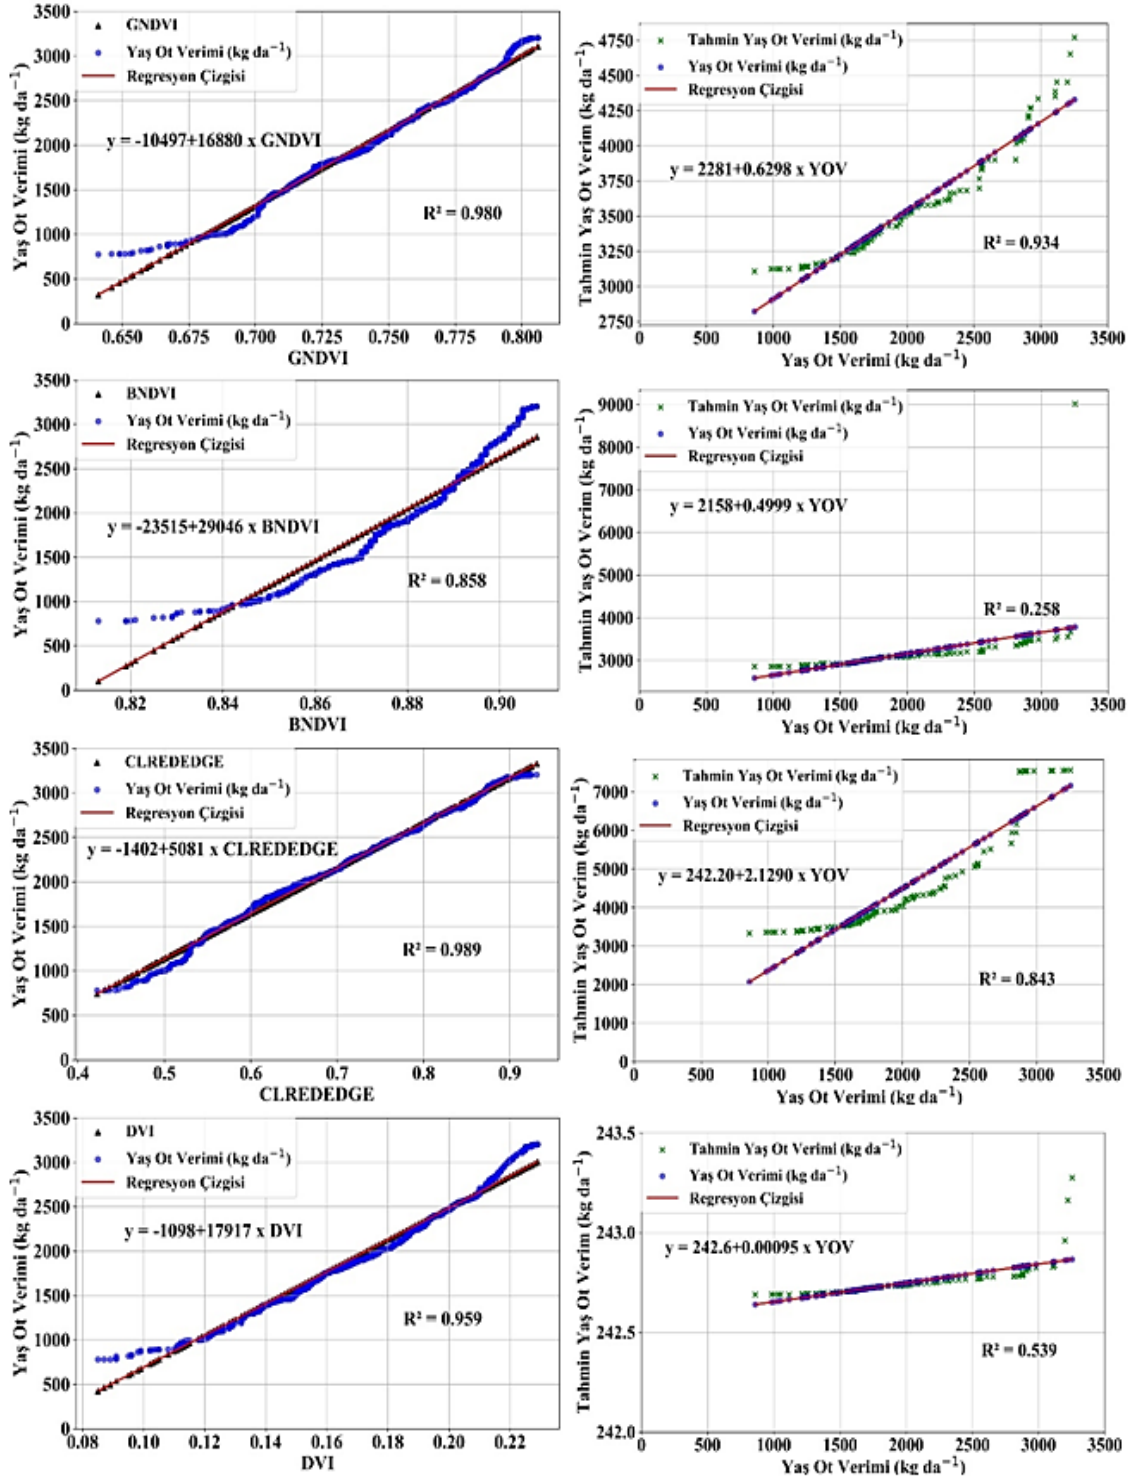
Bunun yanında bitki örtüsü ile mavi bantın yansımaları arasında güçlü bir ilişki olmasına rağmen mavi bantı kullanan indeksler biyokütle tahminlerinde güvenilir bir sonuç sağlayamamıştır (Sanjerehei 2014). Araştırmalar, arka plan gürültü sinyallerinin bitki örtüsünden gelen mavi bant yansımalarından daha yoğun olduğunu göstermektedir (Dymond ve Shepherd 2004). Bu da BNDVI indeksini diğer bitki örtüsü indekslerine kıyasla daha az etkili hale getirmektedir.

Araştırmada yaş ot verimini belirlemek için oluşturulan modellerin grafiklerinden de anlaşılacağı üzere, NDVI ve BNDVI gibi bazı bitki indeks modellerinin düşük yaş ot verimlerini öğrenmede yetersiz kalmaları, bu indekslerin tahmin modellerinin belirtme katsayılarının (R^2) düşük çıkmasından kaynaklı olduğunu düşünülmektedir (Şekil 4.5). Diğer taraftan da NDVI indeksinin bitki sağlığındaki olumsuzluklara rağmen tüm bitki örtüsünü homojen algılayarak doygunluğa ulaşması belirtme katsayısının değerinin düşük olmasına yol açmıştır (Liu ve Huete 1995; Gao 1996; Sasidhar vd. 2019; İleri ve Koç 2022).

EVI indeksinde olduğu gibi model grafiklerinde gözlemlenen yüksek regresyon ilişkilerine rağmen, tahmin modellerinde nispeten daha düşük doğrulukta değerlerin ortaya çıkması bitki indekslerinin bant kombinasyonlarının özelliklerinden kaynaklanmış olabileceği düşünülmektedir. Çünkü EVI indeksinin toprak arka planı veya atmosferik şartlar gibi abiyotik çevre koşullarının olumsuz etkilerini azaltmasına rağmen, kullanılan İHA'nın teknik özelliklerinden kaynaklanan topografik etkileri dikkate almadığı için tahmin modellerinin belirtme katsayılarının (R^2) beklenen oranın altında kalmıştır (Holben ve Justice 1981; Huete vd. 2002).

MODEL

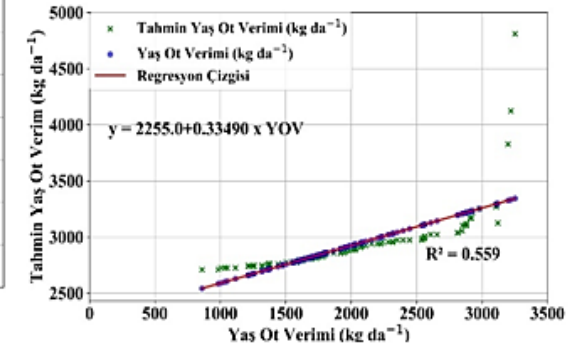


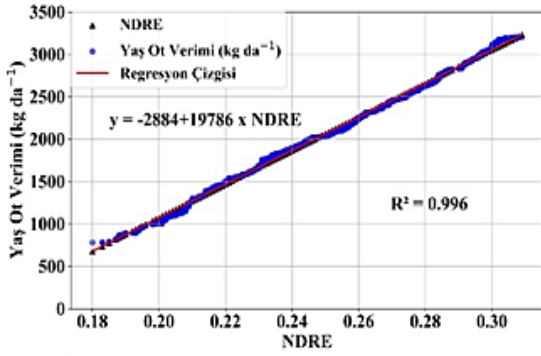
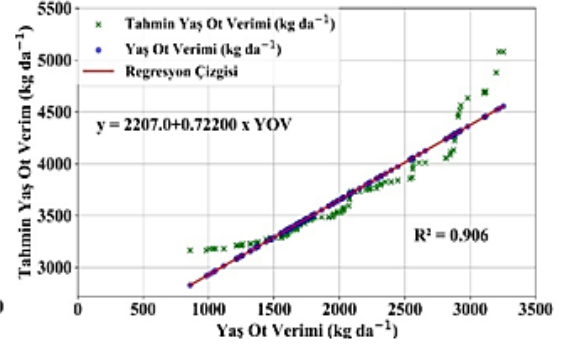
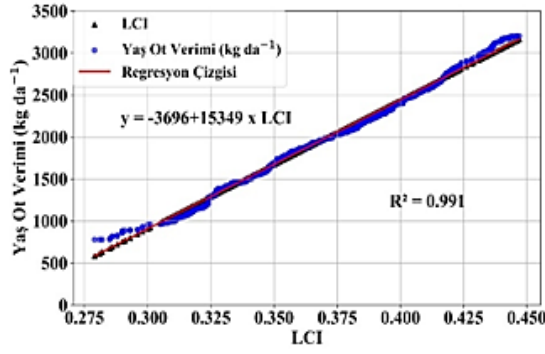


TAHMİN



Şekil 4.5 Yaş ot veriminin belirlenmesinde kullanılan GNDVI, BNDVI, CL_{REDEGE} ve DVI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

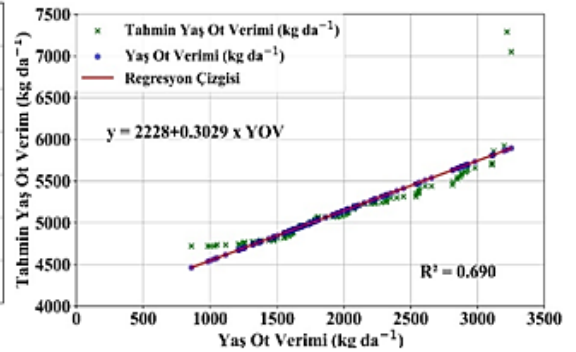
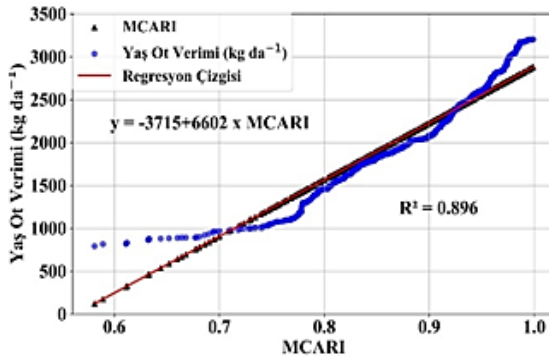






TAHMİN



Şekil 4.6 Yaş ot veriminin belirlenmesinde kullanılan EVI, LCI, NDRE ve NDVI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

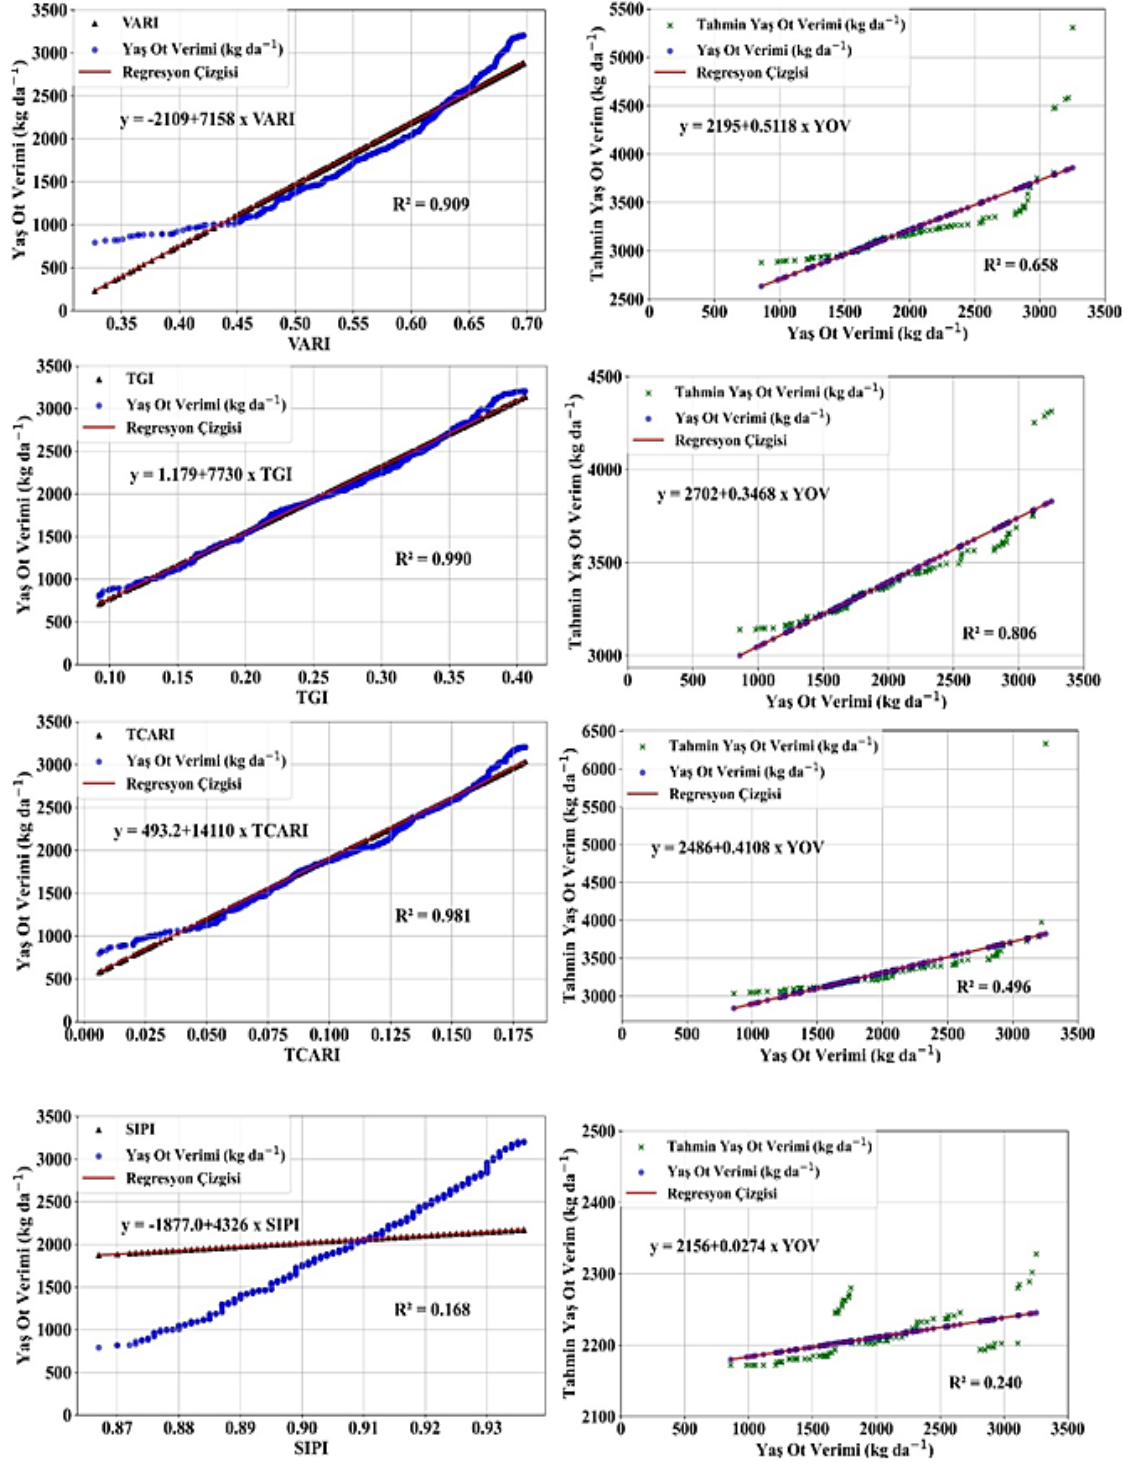
TAHMİN



Şekil 4.7 Yaş ot veriminin belirlenmesinde kullanılan SR, RVI, OSAVI ve MCARI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

TAHMİN



Şekil 4.8 Yaş ot veriminin belirlenmesinde kullanılan VARI, TGI, TCARI ve SIPI bitki indekslerinin model-tahmin regresyon grafikleri

4.3 Kuru Ot Verimi

Araştırmanın yürütüldüğü bitki büyüme döneminde yapılan 4 biçimin ortalama kuru ot verim değerleri 432.6-698.2 kg da⁻¹ arasında değişirken, lokasyonlara bağlı olarak toplam kuru ot verim değerleri ise 2047.3-2526.3 kg da⁻¹ arasında değişmiştir. Araştırmada tüm biçim zamanları ve lokasyonların ortalaması yonca toplam kuru ot verimi 2335.2 kg da⁻¹ olarak belirlenmiştir (Çizelge 4.5).

Çizelge 4.5 Lokasyon ve biçim sayısına göre yonca kuru ot verim değerleri (kg da⁻¹)

Lokasyon	Biçim				Toplam
	1. Biçim	2. Biçim	3. Biçim	4. Biçim	
Değirmenkaşı	696.3	507.5	649.9	539.2	2393.0
İsahocalı	888.1	839.9	305.5	300.9	2334.5
Karahıdır	613.3	692.7	576.7	492.3	2375.2
Terziali	592.1	536.8	562.4	355.8	2047.3
Malya (TİGEM)	701.3	791.7	558.5	474.6	2526.3
Ortalama	698.2	673.7	530.6	432.6	2335.2

Hem model hem de tahmin aşamalarında GNDVI, NDRE, CL_{REDEDGE}, TGI ve LCI için modeller arasında gözlemlenen yüksek belirtme katsayılarının değerleri bu indekslerin kuru ot verimindeki değişkenliği yakalamadaki tutarlılığının altını çizmektedir (Çizelge 4.6). Özellikle model değeri R²=0.975 ve tahmin değeri R²=0.967 GNDVI bitki indeksinde yaş ot veriminde olduğu gibi kuru ot verimini belirlemede de indeks ile bitki verimi arasında güçlü bir ilişki olduğunu göstermektedir (Çizelge 4.10. Şekil 4.11). Benzer şekilde NDRE indeksi en yüksek model değerini R²=0.988 vermesine rağmen, tahmin aşamasında bu değer R²=0.942 düştüğü görülmüştür. Bu, NDRE indeksinin sahadaki değişkenliği yakalamada oldukça etkili olmasına rağmen, ilk model eğitiminde hesaba katılmayan dış etkenlere karşı duyarlı olmasından kaynaklı olduğu düşünülmektedir (Adewopo vd. 2020).

Bu çevresel koşullar ve ürüne özgü faktörlerden kaynaklı dış etkenler aynı şekilde $CL_{REDEEDGE}$ ve LCI indeksinin de tahmin değerlerini sırasıyla $R^2=0.940$ ve $R^2=0.932$ model öğrenimindeki değerlere oranla düşmesine neden olmuştur. Buna karşılık en yüksek korelasyon ilişkisinin tespit edildiği TGI indeksinde model öğrenimi ve tahmin arasındaki değerlerinin birbirine oldukça yakın olması nedeniyle sırasıyla $R^2=0.989$ ve $R^2=0.974$ kuru ot verimini belirlemede diğer indekslerden farklı olarak ön plana çıkmasını sağlamıştır (Şekil 4.12). TGI indeksi her ne kadar geleneksel dijital kameralarda bulunan kırmızı, yeşil, mavi (RGB) bantlarından elde edilse de bitki örtüsündeki değişimi değerlendirmek (Jelínek vd. 2020) ya da biyokütle gibi çeşitli bitki özelliklerini belirlemek için kullanılmaktadır (Casadesús vd. 2007).

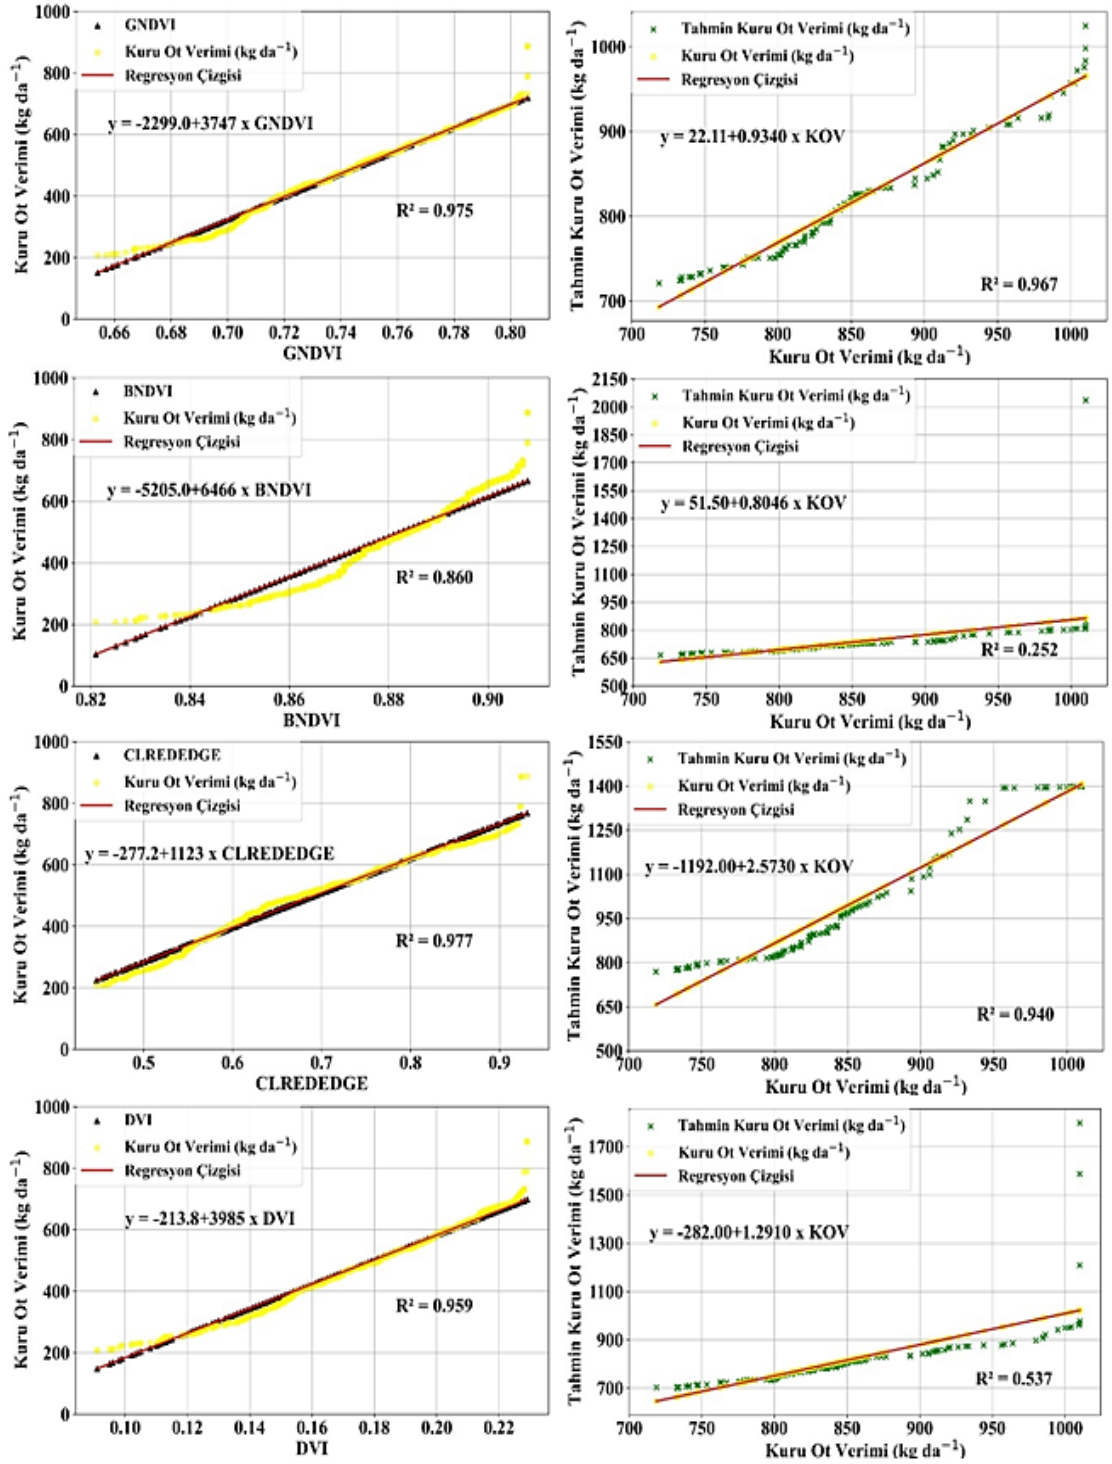
Çizelge 4.6 Kuru ot veriminin belirlenmesinde kullanılan bitki indekslerinin model-tahmin regresyon değerleri ve denklemleri

İndeks	Model		Tahmin	
	R^2	Denklem	R^2	Denklem
GNDVI	0.975	$y = -2299 + 3747 \times \text{GNDVI}$	0.967	$y = 22.11 + 0.9340 \times \text{KOV}^y$
BNDVI	0.860	$y = -5205 + 6466 \times \text{BNDVI}$	0.252	$y = 51.5 + 0.8046 \times \text{KOV}$
$CL_{REDEEDGE}$	0.977	$y = -277.2 + 1123 \times \text{CL}_{REDEEDGE}$	0.940	$y = -1192 + 2.573 \times \text{KOV}$
DVI	0.959	$y = -213.8 + 3985 \times \text{DVI}$	0.535	$y = -282.0 + 1.291 \times \text{KOV}$
EVI	0.951	$y = -314.8 + 2142 \times \text{EVI}$	0.582	$y = 11.29 + 0.9095 \times \text{KOV}$
LCI	0.985	$y = -788.0 + 3404 \times \text{LCI}$	0.932	$y = -154.4 + 1.176 \times \text{KOV}$
NDRE	0.988	$y = -606.7 + 4383 \times \text{NDRE}$	0.942	$y = -254.3 + 1.331 \times \text{KOV}$
NDVI	0.765	$y = -2742 + 3661 \times \text{NDVI}$	0.417	$y = 82.88 + 0.7144 \times \text{KOV}$
SR	0.969	$y = -95.48 + 34.02 \times \text{SR}$	0.849	$y = -717.4 + 1.952 \times \text{KOV}$
RVI	0.983	$y = -114.1 + 11389 \times \text{RVI}$	0.299	$y = -3386 + 5.239 \times \text{KOV}$
OSAVI	0.788	$y = -541.4 + 2128 \times \text{OSAVI}$	0.743	$y = 290.4 + 0.4635 \times \text{KOV}$
MCARI	0.898	$y = -798.3 + 1471 \times \text{MCARI}$	0.654	$y = 302.5 + 1.035 \times \text{KOV}$
VARI	0.913	$y = -440.8 + 1596 \times \text{VARI}$	0.764	$y = 136.4 + 0.7156 \times \text{KOV}$
TGI	0.986	$y = 31.41 + 1716 \times \text{TGI}$	0.974	$y = 385.9 + 0.4670 \times \text{KOV}$
TCARI	0.978	$y = 140.5 + 3134 \times \text{TCARI}$	0.492	$y = 203.3 + 0.6642 \times \text{KOV}$
SIPI	0.169	$y = -389.4 + 964.7 \times \text{SIPI}$	0.243	$y = 484.2 + 0.04492 \times \text{KOV}$

KOV^y: Kuru Ot Verimi

MODEL

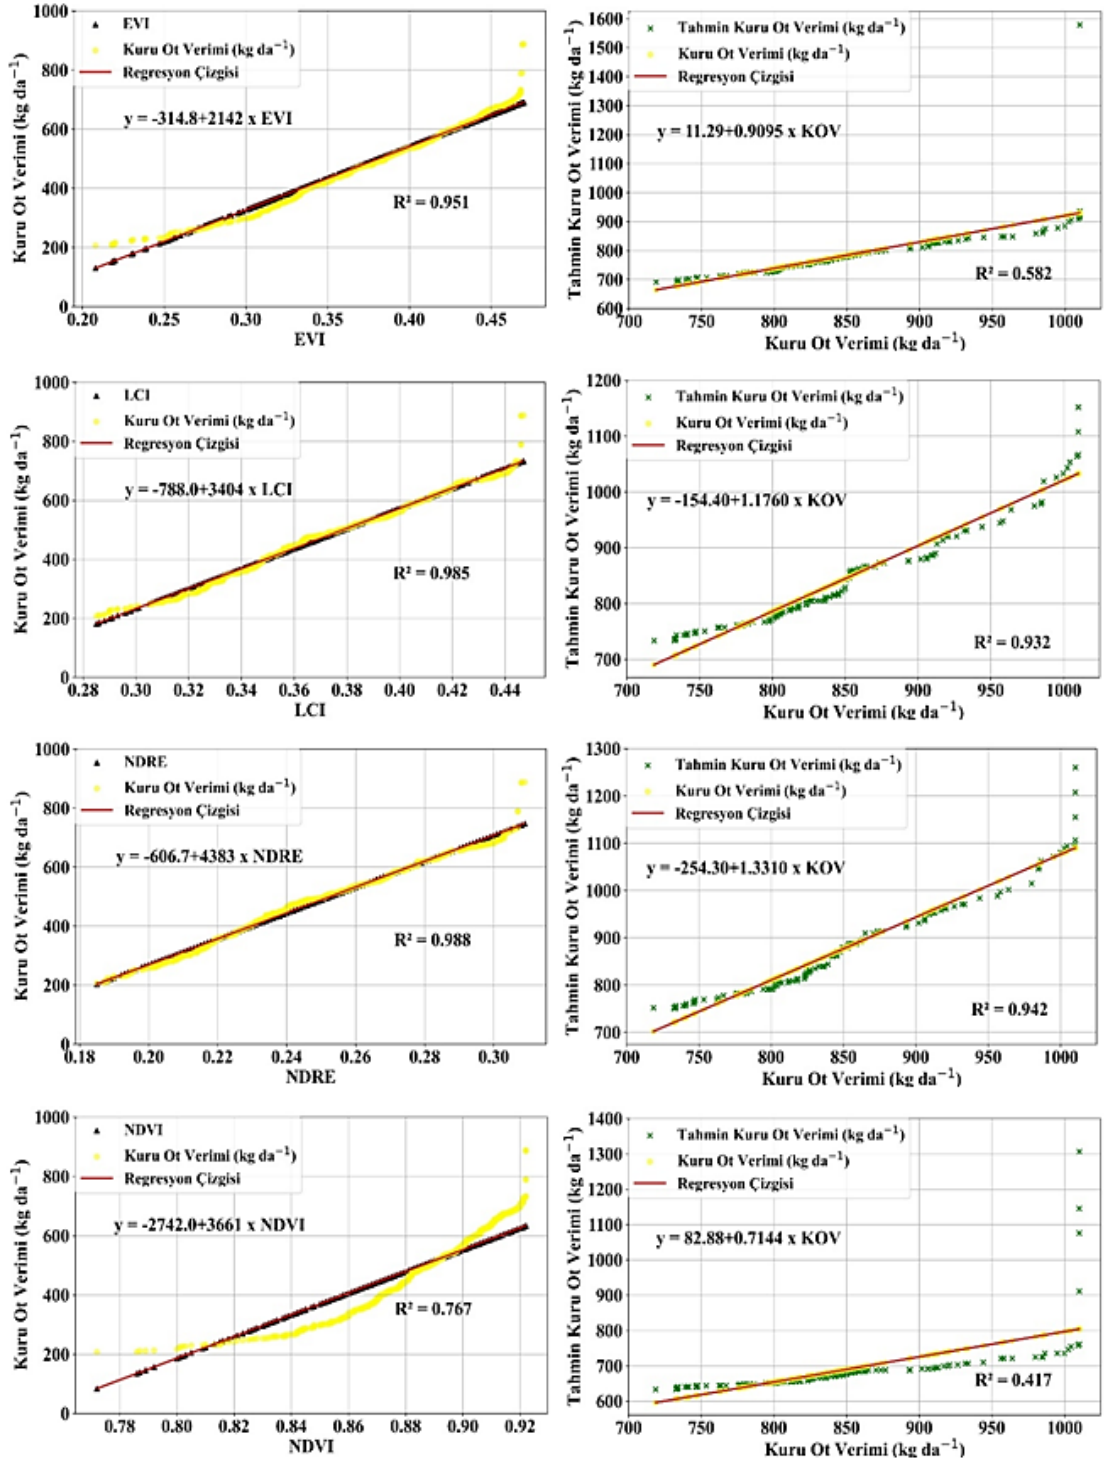
TAHMİN



Şekil 4.9 Kuru ot veriminin belirlenmesinde kullanılan GNDVI, BNDVI, CL_{REDEGE} ve DVI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

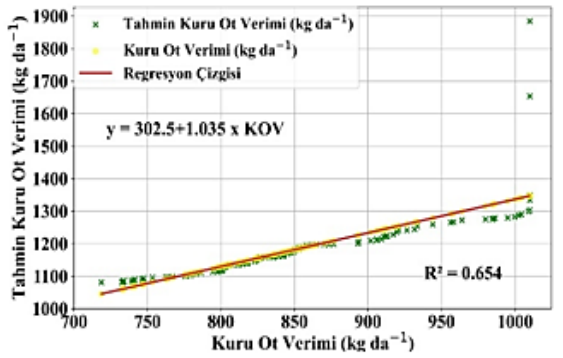

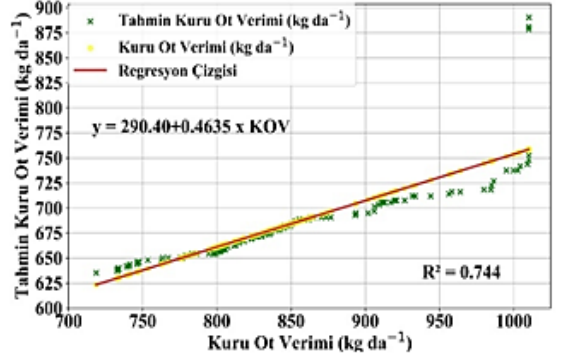



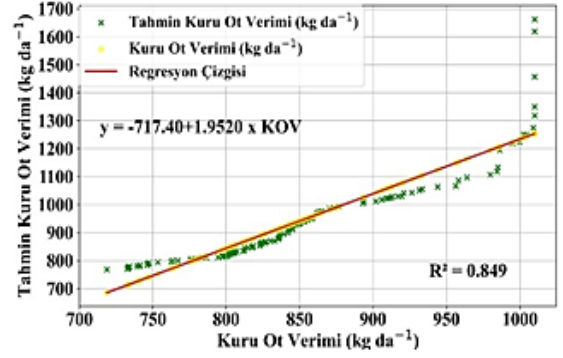
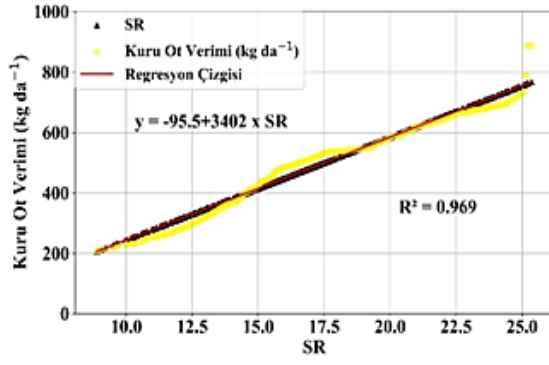
TAHMİN



Şekil 4.10 Kuru ot veriminin belirlenmesinde kullanılan EVI, LCI, NDRE ve NDVI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

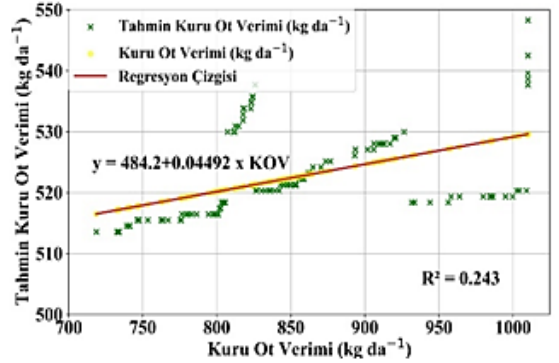


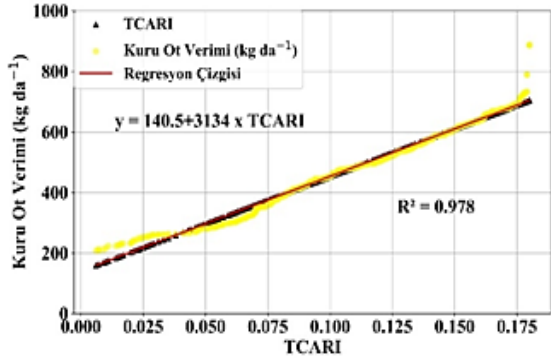
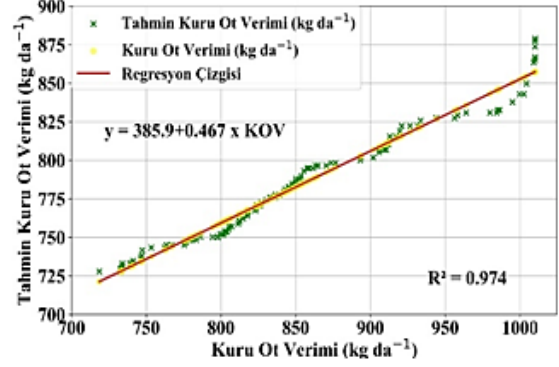

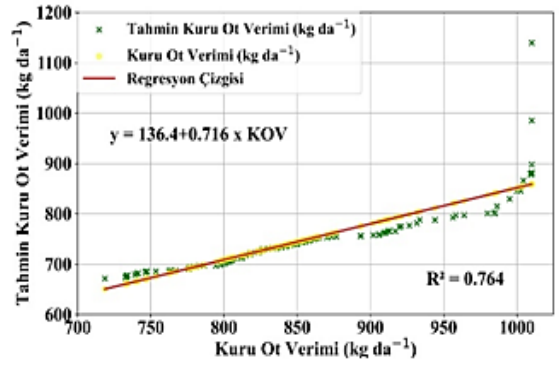
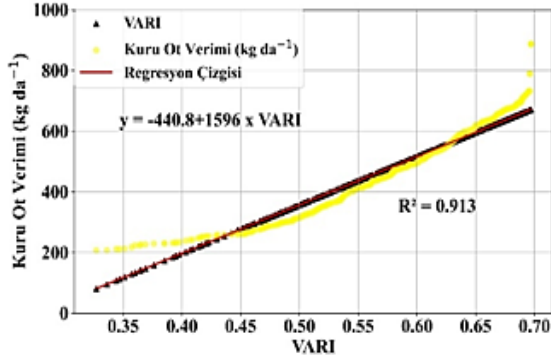
TAHMİN



Şekil 4.11 Kuru ot veriminin belirlenmesinde kullanılan SR, RVI, OSAVI ve MCARI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

TAHMİN



Şekil 4.12 Kuru ot veriminin belirlenmesinde kullanılan VARI, TGI, TCARI ve SIPI bitki indekslerinin model-tahmin regresyon grafikleri

Bitki örtüsünün spektral özelliklerine göre, yoğun bitki örtüsü olan bölgelerde kırmızı bantta düşük yansıma meydana gelirken, kuru biyokütle ve yaprakların klorofil içeriği ile yüksek bir korelasyon göstermiştir (Quan vd. 2011). Elde edilen bulgulara göre yoğun bitki örtüsü kaplı alanlarda yeşil ve kuru biyokütle tahminleri için klorofil içeriğinin tahmin edilmesinde kullanılan indekslerin (GNDVI, NDRE, CL_{REDEDGE}, LCI, TGI) bitki biyokütlesiyle iyi bir korelasyon göstermesi literatürde yapılan çalışmalarla da uyumludur.

4.4 Ham Protein Oranı

Araştırma sahalarından alınan yonca örneklerinin ham protein oranları lokasyonlara bağlı olarak %17.86-21.35 arasında, biçim sayıları bazında %19.04-20.58 arasında değişmiş ve ortalama ham protein oranı %19.88 olarak hesaplanmıştır (Çizelge 4.7).

Çizelge 4.7 Lokasyon ve biçim sayısına göre yonca ham protein oranı değerleri (%)

Lokasyon	Biçim				Ortalama (%)
	1. Biçim	2. Biçim	3. Biçim	4. Biçim	
Değirmenkaşı	21.28	22.28	21.53	20.41	21.35
İsahocalı	20.28	20.12	19.88	19.68	19.99
Karahıdır	21.76	19.48	19.26	18.85	19.83
Terziali	18.56	18.07	17.58	17.25	17.86
Malya (TİGEM)	21.03	20.83	20.60	19.05	20.37
Ortalama	20.58	20.15	19.77	19.04	19.88

Ham protein oranlarını belirlemek için kullanılan standart bitki indeksi modellerinin değerleri $R^2=0.178$ ile $R^2=0.991$ arasında, tahmin modellerinin değerleri ise $R^2=0.227$ ile $R^2=0.765$ arasında değişmiştir (Çizelge 4.6). Tahmin modelleri arasında en yüksek değer elde edildiği NDRE indeksi modifiye edildikten sonra elde edilen MPNDRE indeksiyle birlikte model değeri $R^2=0.917$ tahmin değeri ise $R^2=0.820$ olarak belirlenmiştir (Çizelge 4.8). Standart bitki örtüsü indeksleri, öncelikli olarak bitki örtüsü yoğunluğuna ve klorofil içeriğine odaklanmaktadır. Ancak, bu indeksler protein oranı, NDF ve ADF gibi kalite parametrelerini belirlemede yetersiz kalabilmektedir. NIR ve

kırmızı kenar bandının etkin olduğu NDRE indeksi, genel olarak bitki stresi ve klorofil içeriği ile ilgili özellikleri belirlemede kullanılmaktadır (Gitelson ve Merzlyak 1996; Wu vd. 2008; Clevers ve Kooistra 2011). Diğer taraftan bu indeks toprak arka planının ortaya çıkardığı olumsuz etkileri bir miktar azaltmasına karşın ham protein oranı gibi farklı özellikleri belirlemede istenen düzeyde sonuçlar vermemektedir. Aynı zamanda toprak yansımalarının NIR dalga boyundaki yeşil bitki örtüsünden daha düşük ve görünür dalga boyunda (400-700 nm) daha yüksek olması nedeniyle, bitki örtüsündeki artış NIR dalga boyunda yüksek görünür dalga boylarında ise düşük yansıma ile sonuçlanmaktadır (Guyot 1989). Bu nedenle NDRE indeksinde $NDRE = \frac{(NIR-REDEGE)}{(NIR+REDEGE)}$ toprak arka planının yansımalarından kaynaklanan olumsuz etkiler minimize edilerek ve araştırmada kullanılan diğer 16 bitki indeksiyle birlikte 6 farklı dalga boyunun kombinasyonları kullanılarak en yüksek belirtme katsayısı değerini $R^2=0.820$ veren MPNDRE indeksi $MPNDRE = \frac{(OSAVI)}{(1+\sqrt{NDRE})}$ elde edilmiştir.

Çizelge 4.8 Ham protein oranının belirlenmesinde kullanılan bitki indekslerinin model-tahmin regresyon değerleri ve denklemleri

İndeks	Model		Tahmin	
	R ²	Denklem	R ²	Denklem
GNDVI	0.972	y= -3.043+30.38 x GNDVI	0.549	y= -39.18+2.822 x HPO [¥]
BNDVI	0.888	y= -27.44+53.37 x BNDVI	0.425	y= -7.372+1.325 x HPO
CL _{REDEGE}	0.957	y= 13.40+9.028 x CL _{REDEGE}	0.663	y= -118.3+6.517 x HPO
DVI	0.973	y= 13.81+32.60 x DVI	0.426	y= -47.16+3.185 x HPO
EVI	0.969	y= 12.97+17.55 x EVI	0.526	y= -18.37+1.850 x HPO
LCI	0.983	y= 9.199+27.62 x LCI	0.650	y= -50.31+3.343 x HPO
NDRE	0.979	y= 10.70+35.43 x NDRE	0.765	y= -39.13+2.836 x HPO
NDVI	0.799	y= -7.223+30.35 x NDVI	0.500	y= -8.530+1.363 x HPO
SR	0.949	y= 14.86+0.2734 x SR	0.512	y= -254.9+12.81 x HPO
RVI	0.979	y=14.67+92.31 x RVI	0.380	y= -195.1+10.05 x HPO
OSAVI	0.821	y= 11.02+17.63 x OSAVI	0.260	y= -87.97+5.033 x HPO
MCARI	0.921	y= 8.978+12.09 x MCARI	0.707	y= -15.30+1.858 x HPO
VARI	0.941	y= 11.89+13.16 x VARI	0.396	y= -42.52+2.953 x HPO
TGI	0.989	y= 15.84+13.96 x TGI	0.488	y= -14.32+1.669 x HPO
TCARI	0.991	y= 16.71+25.62 x TCARI	0.747	y= -1.871+1.085 x HPO
SIPI	0.178	y= 12.23+8.048 x SIPI	0.227	y= 18.18+0.07608 x HPO
MPNDRE^Φ	0.917	y= 7.459+12.31 x MPNDRE	0.820	y= -5.914+1.265 x HPO

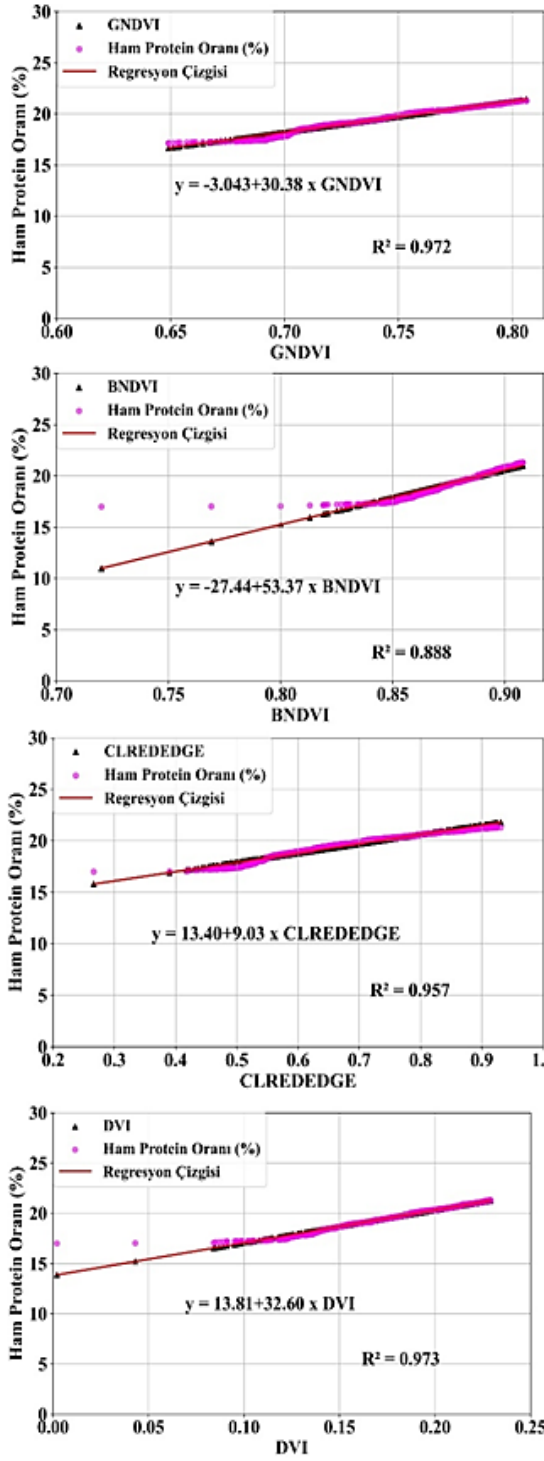
MPNDRE^Φ: Modifiye edilmiş protein normalize kırmızı kenar indeksi, HPO[¥]: Ham Protein Oranı

Bitki örtüsü indekslerinin, azot bileşiklerine duyarlı spektral bantlar ve yansımaları özellikleri dikkate alınarak modifiye edilmesi (Xue ve Su 2017) toprak, nem ve atmosfer koşulları gibi çevresel faktörlerin neden olduğu yansımaları gürültüsünü azaltmakta ve böylece protein içeriğinin daha güvenilir bir şekilde belirlenmesine olanak tanımaktadır (Qi vd. 1994; Hansen ve Schjoerring 2003). Bitki örtüsü NIR bölgesinde (700-1300 nm) yüksek yansımaya ve kırmızı bölgede (600-700 nm) düşük yansımaya gösterir. Bunun nedeni, bitki yapraklarının NIR ışığını güçlü bir şekilde yansıtan hücresel yapısı ve fotosentez için kırmızı ışığı emen klorofilin varlığıdır (Tucker 1979). Bant oranlarının kombinasyonlarını kullanan indeksler, toprak yansımadaki önemli değişimlerden daha az etkilenme eğilimindedirler.

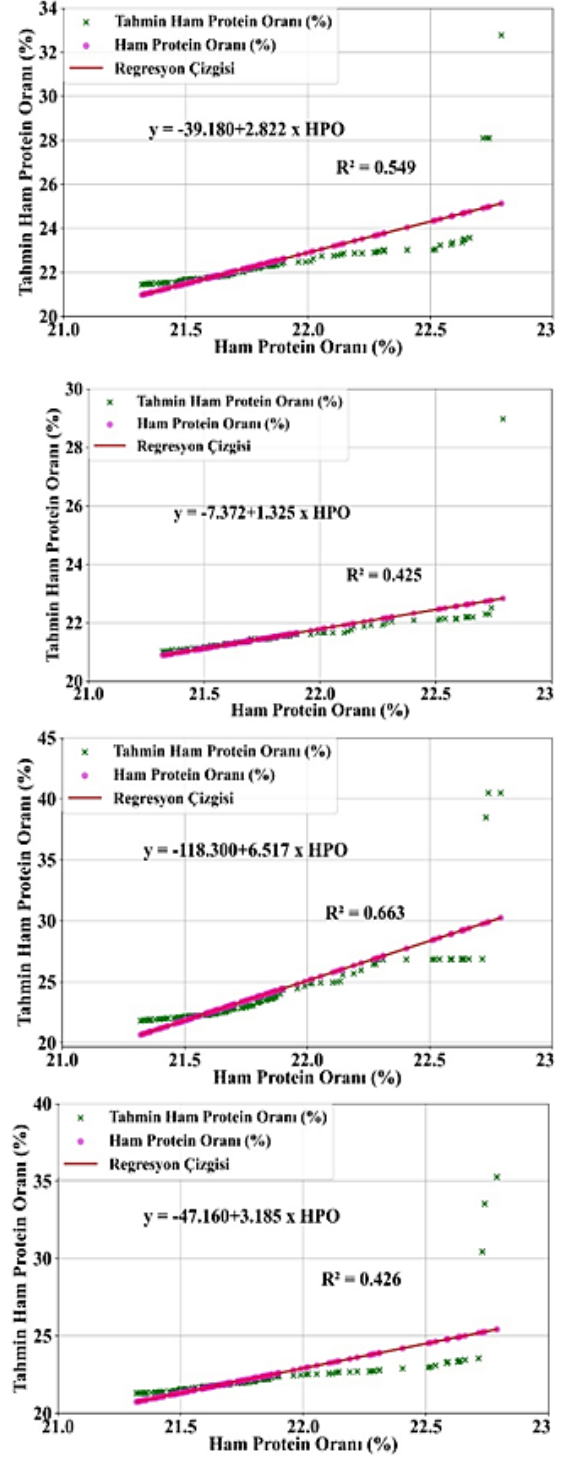
SIPI indeksi dışında araştırmada kullanılan tüm bitki indeksleri için oluşturulan modellerin oldukça yüksek belirtme katsayıları (R^2) değerlerine sahip öğrenme gerçekleştirdiklerini model grafiklerinde de görmek mümkündür (Çizelge 4.8 ve Şekil 4.4). Diğer yandan tahmin modellerinde kullanılan CL_{REDEGE} ($R^2=0.663$), MCARI ($R^2=0.707$), LCI ($R^2=0.650$), TCARI ($R^2=0.747$) ve NDRE ($R^2=0.765$) indekslerinin MPNDRE indeksinin tahmin modelinden ($R^2=0.820$) düşük olmakla birlikte ham protein oranını kabul edilebilir düzeyde doğru tahmin ettikleri belirlenmiştir (Şekil 4.14 ve Şekil 4.15). Model grafiklerine göre modifiye MPNDRE indeksi dışındaki diğer indekslerde ham protein oranı değerleri arttıkça modellerin yüksek ham protein oranlarını öğrenmede başarısız oldukları, buna karşın MPNDRE bitki indeksinde ise bu durumun nispeten azaldığı görülmektedir (Şekil 4.17). Buna karşın modifiye MPNDRE indeksi ham protein oranlarını $R^2=0.820$ doğrulukta tahmin etmeyi başarmıştır.

NIR bölgesi proteinlerin temel bileşeni olan azota karşı özellikle duyarlıdır ve bu da onu modifikasyon sürecinde önemli bir faktör haline getirmektedir. Bitki örtüsüne en hassas olan NIR ve kırmızı yansımaya odaklanan bu indeksler topraktan ve diğer bitkisel olmayan unsurlardan kaynaklanan arka plan gürültüsünü azaltmaktadır (Qi vd. 1994; Clevers ve Gitelson 2013).

MODEL



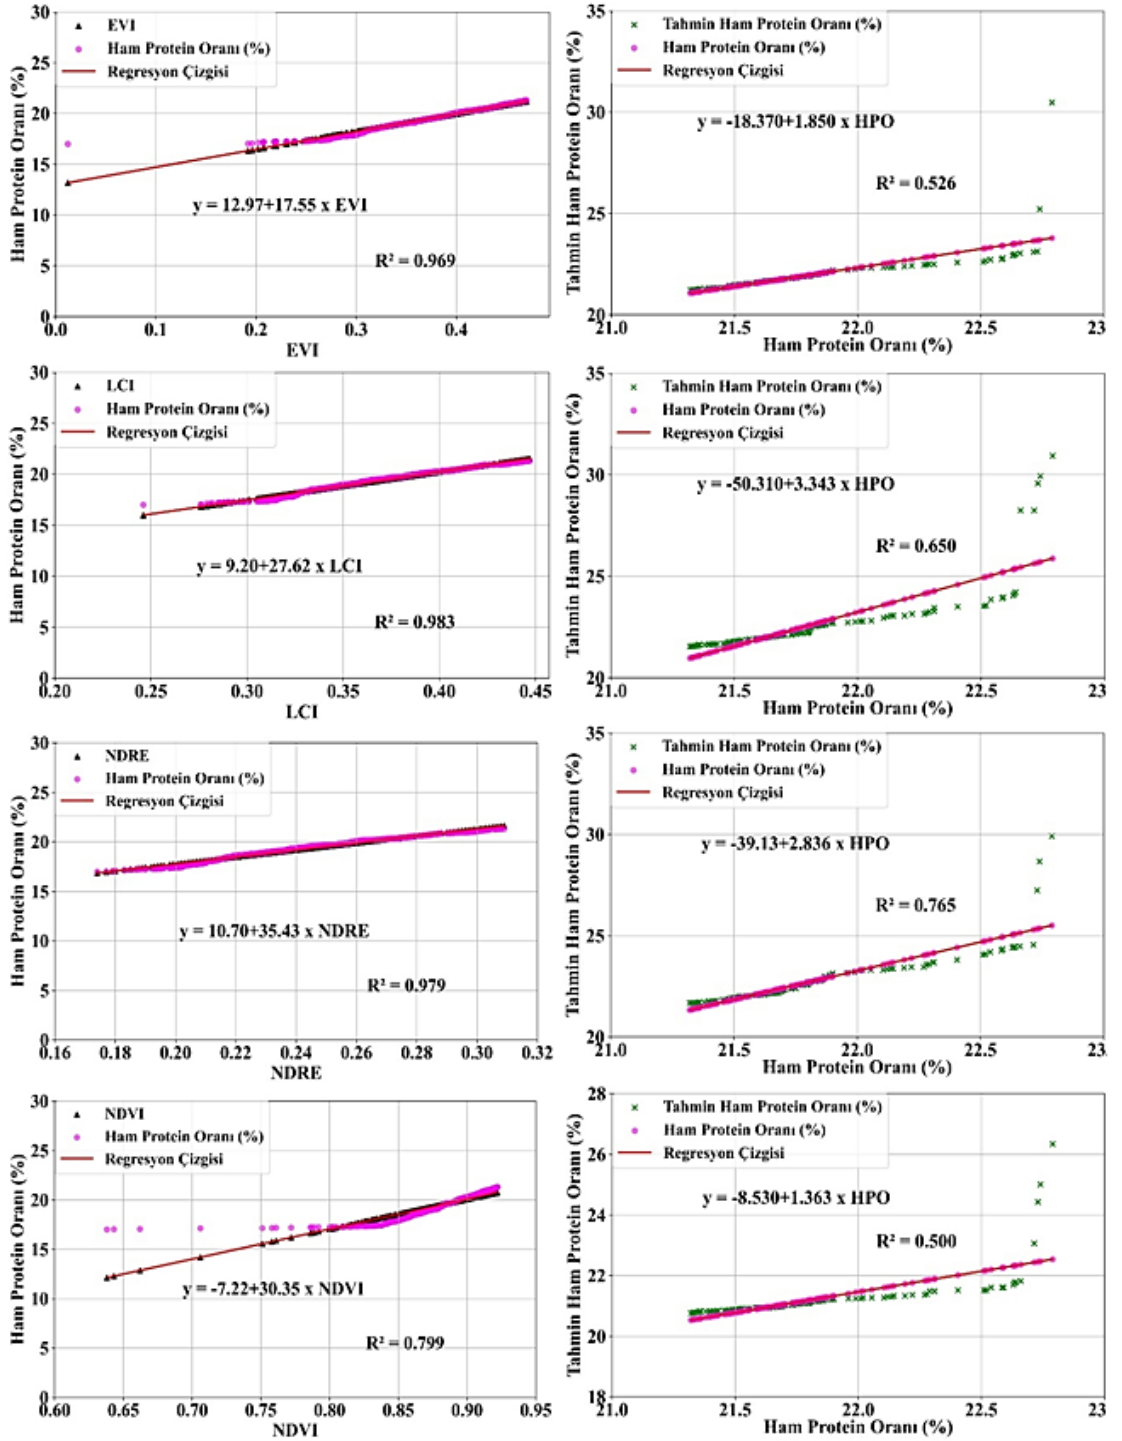
TAHMİN



Şekil 4.13 Ham protein oranının belirlenmesinde kullanılan GNDVI, BNDVI, CL_{REDEGE} ve DVI bitki indekslerinin model-tahmin regresyon grafikleri


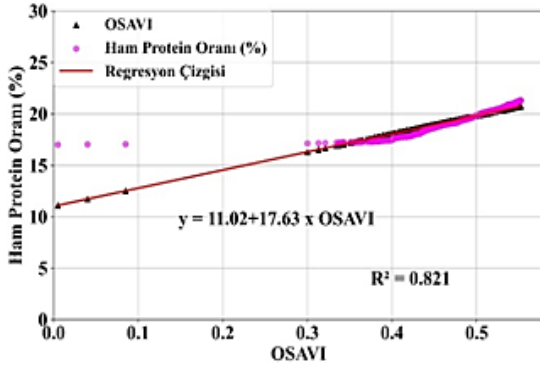
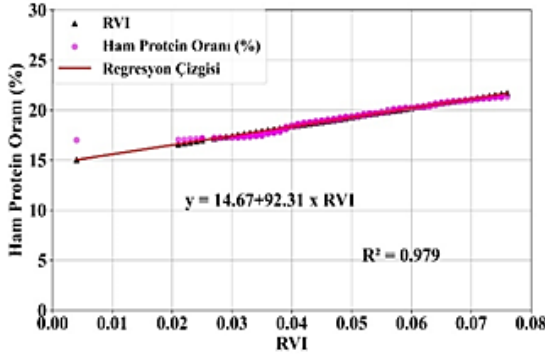
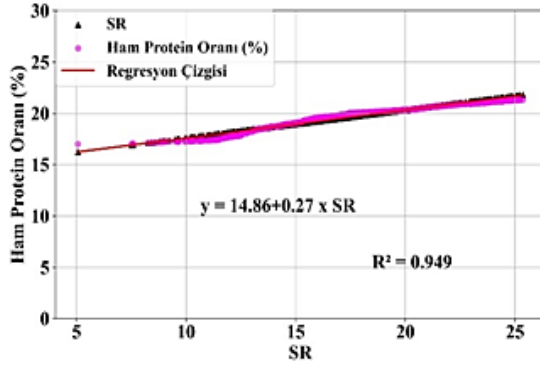
MODEL

TAHMİN


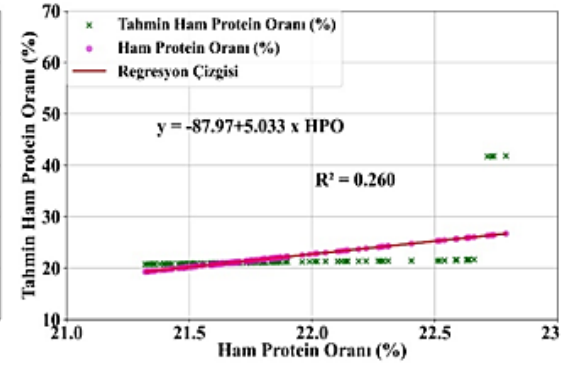




Şekil 4.14 Ham protein oranının belirlenmesinde kullanılan EVI, LCI, NDRE ve NDVI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL



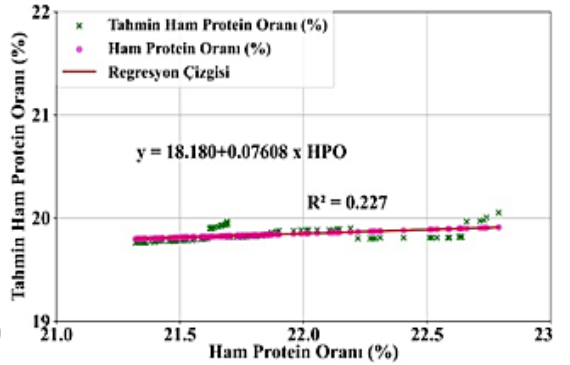
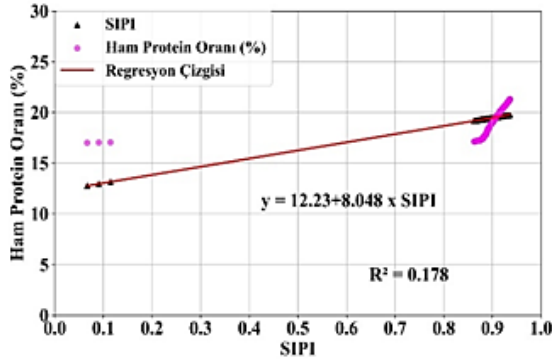

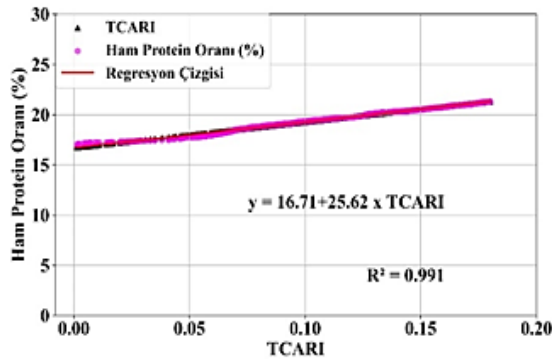

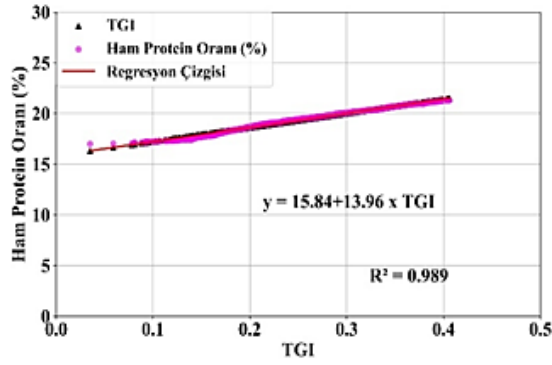
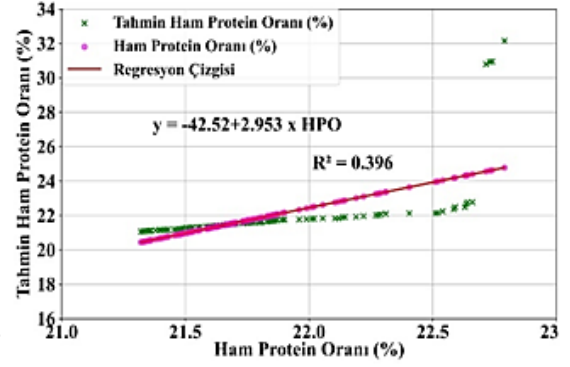
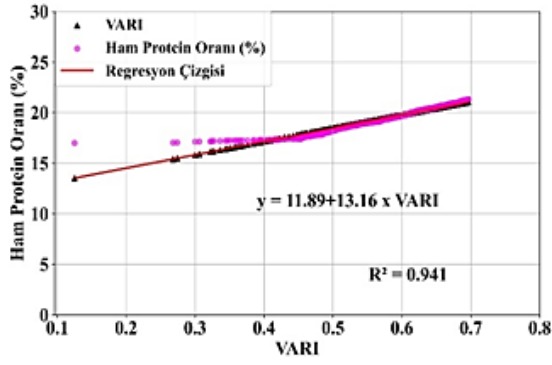
TAHMİN



Şekil 4.15 Ham protein oranının belirlenmesinde kullanılan SR, RVI, OSAVI ve MCARI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL


TAHMİN



Şekil 4.16 Ham protein oranının belirlenmesinde kullanılan VARI, TGI, TCARI ve SIPI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

TAHMİN



Şekil 4.17 Ham protein oranının belirlenmesinde geliştirilen modifiye protein normalize edilmiş kırmızı kenar (MPNDRE) bitki indeksinin model-tahmin regresyon grafikleri

4.5 NDF Oranı

Bitki indekslerinin model ve tahmin regresyon değerlerinde kullanılmak üzere araştırma sahasından alınan yonca örneklerinin Nötral Deterjan Lif (NDF) oranları biçim sayılarına göre %33.51-42.08 arasında, lokasyonlara göre ise %40.56-47.70 arasında değişmiş ve ortalama %42.75 olarak belirlenmiştir (Çizelge 4.9).

Çizelge 4.9 Lokasyon ve biçim sayısına göre yonca NDF oranı değerleri (%)

Lokasyon	Biçim				Ortalama (%)
	1. Biçim	2. Biçim	3. Biçim	4. Biçim	
Değirmenkaşı	40.56	39.36	41.05	41.29	40.56
İsahocalı	41.47	41.67	41.98	42.28	41.85
Karahıdır	42.48	42.78	43.23	43.87	43.09
Terziali	46.52	47.23	48.19	48.84	47.70
TİGEM (Malya)	39.39	40.56	41.05	41.29	40.57
Ortalama	42.08	42.32	43.10	43.51	42.75

Standart bitki indekslerinin NDF oranlarını belirlemek için kullanılan model değerleri $R^2=0.166$ ile $R^2=0.977$ arasında, tahmin modellerinin değerleri ise $R^2=0.102$ ile $R^2=0.698$

arasında değişmiştir. Tahmin modelleri arasında en yüksek R^2 değeri $CL_{REDEDGE}$ indeksinden elde edilmiş ve bu indeksin modifiye edilmesiyle elde edilen $MNCL_{REDEDGE}$ indeksinden sonra tüm modeller için en yüksek değerler $R^2=0.983$ ile tüm tahmin değerleri için ise $R^2=0.726$ olarak hesaplanmıştır. NDF oranları ile ilgili model regresyon denklemlerinin R^2 değerlerine göre en düşük öğrenmeyi SIPI indeksi, en yüksek düzeyde öğrenmeyi ise $CL_{REDEDGE}$ indeksini $CL_{REDEDGE} = \left(\frac{(NIR)}{(REDEDGE)} - 1\right)$ modifiye ederek geliştirdiğimiz $MNCL_{REDEDGE}$ indeksi $MNCL_{REDEDGE} = \left(\frac{(NIR)^2 + 1}{(CL_{REDEDGE})^2 + 1}\right)$ gerçekleştirmiştir. (Çizelge 4.10).

$CL_{REDEDGE}$ indeksi kırmızı kenar bandı ve NIR tabanlı olması avantajıyla diğer standart indekslerden daha yüksek doğrulukta NDF oranlarını tahmin etmeyi başarmıştır. Ancak $CL_{REDEDGE}$ indeksinin kullandığı NIR dalga boyu bölgesindeki hassasiyeti artırılarak ve normalize edilerek geliştirdiğimiz $MNCL_{REDEDGE}$ indeksi NDF oranının daha yüksek doğrulukta tahmini gerçekleştirmeyi başarmıştır.

Ham protein oranını tahmin etmede kabul edilebilir doğrulukta sonuç veren MCARI, LCI ve TCARI indeksleri NDF oranlarını tahmin etmede aynı başarıyı gösterememişlerdir (Çizelge 4.10 ve Şekil 4.18). Buna karşın $CL_{REDEDGE}$ indeksini modifiye ederek elde ettiğimiz $MNCL_{REDEDGE}$ indeksine ek olarak NIR ve kırmızı kenar bandını kullanarak NDF oranlarını tahmin eden GNDVI, $CL_{REDEDGE}$, EVI, NDRE ve MCARI indeksleri nispeten kabul edilebilir oranda doğru tahmin yapmayı başarmışlardır (Çizelge 4.10). NIR ve kırmızı kenar bandı kullanılarak bitki indekslerinin modifiye edilmesi NDF tahmininin hassasiyetini arttırmaktadır. Elde edilen tahmin değerinin diğer bitki indekslerinden yüksek çıkması büyük olasılıkla bitki hücre duvarı bileşimi ve lif içeriğiyle ilişkili olan kırmızı kenar bandının klorofil içeriğine olan duyarlılığından kaynaklanmaktadır (Hansen ve Schjoerring 2003; Mutanga ve Skidmore 2004; Li vd. 2014).

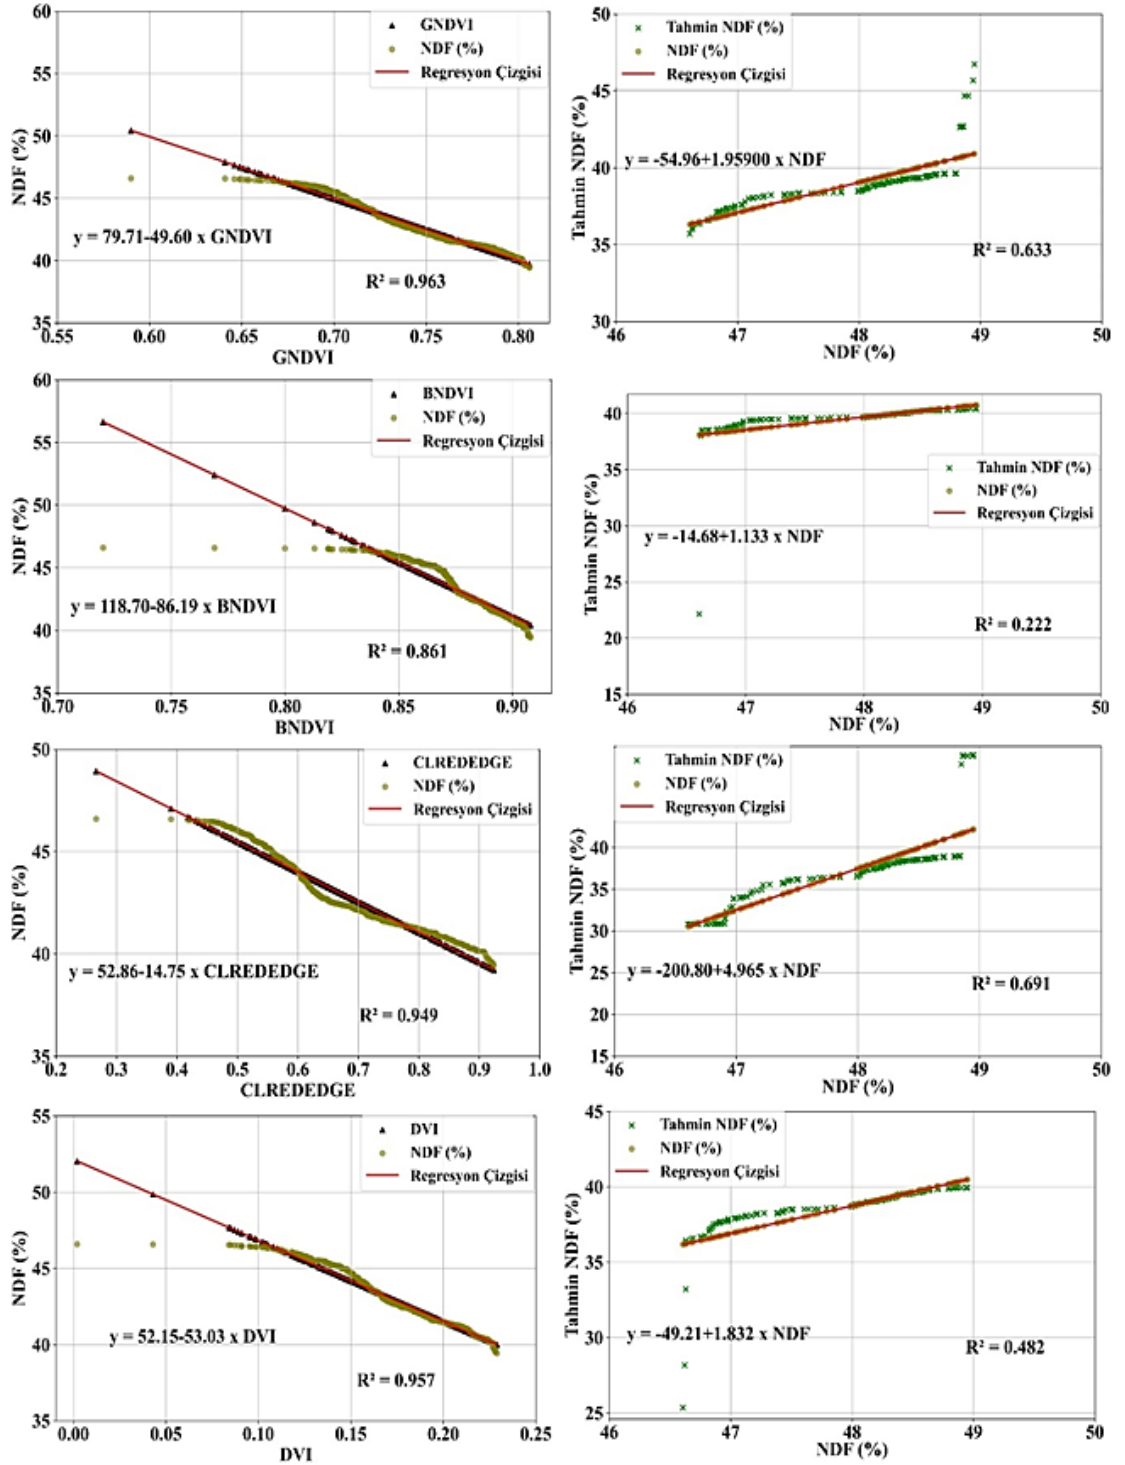
Çizelge 4.10 NDF oranının belirlenmesinde kullanılan bitki indekslerinin model-tahmin regresyon değerleri ve denklemleri

İndeks	Model		Tahmin	
	R ²	Denklem	R ²	Denklem
GNDVI	0.963	y= 79.71-49.60 x GNDVI	0.633	y= -54.96+1.959 x NDF [¥]
BNDVI	0.861	y= 118.7-86.19 x BNDVI	0.222	y= -14.68+1.133 x NDF
CL _{REDEEDGE}	0.949	y= 52.86-14.75 x CL _{REDEEDGE}	0.691	y= -200.8+4.965 x NDF
DVI	0.957	y= 52.15-53.03 x DVI	0.482	y= -49.21+1.832 x NDF
EVI	0.952	y= 53.51-28.54 x EVI	0.635	y= -21.91+1.271 x NDF
LCI	0.972	y= 59.70-45.05 x LCI	0.599	y= -92.05+2.730 x NDF
NDRE	0.970	y= 57.26-57.86 x NDRE	0.615	y= -81.07+2.487 x NDF
NDVI	0.769	y= 85.91-48.85 x NDVI	0.358	y= -7.428+0.9938 x NDF
SR	0.934	y= 50.44-0.4447 x SR	0.575	y= -128.3+3.459 x NDF
RVI	0.973	y=50.79-151.0 x RVI	0.399	y= -210.6+5.153 x NDF
OSAVI	0.796	y= 56.59-28.48 x OSAVI	0.372	y= 0.581+0.8312 x NDF
MCARI	0.903	y= 59.99-19.65 x MCARI	0.608	y= -38.18+1.499 x NDF
VARI	0.921	y= 55.24-21.35 x VARI	0.471	y= -22.14+1.289 x NDF
TGI	0.977	y= 48.87-22.76 x TGI	0.490	y= -7.226+0.9668 x NDF
TCARI	0.975	y= 47.43-41.67 x TCARI	0.574	y= -20.56+1.252 x NDF
SIPI	0.166	y= 54.41-12.75 x SIPI	0.102	y= 3.22+0.8245 x NDF
MNCL _{REDEEDGE} ^Φ	0.983	y= 61.36-25.97 x MNCL _{REDEEDGE}	0.726	y= -75.06+2.589 x NDF

MNCL_{REDEEDGE}^Φ: Modifiye edilmiş NDF klorofil kırmızı kenar indeksi, NDF[¥]: Nötr ortamda çözünebilir lif oranı

MODEL

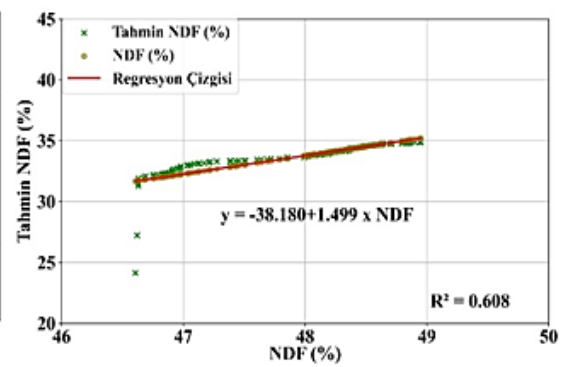

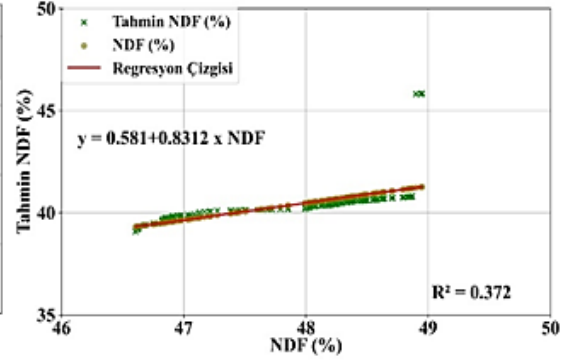
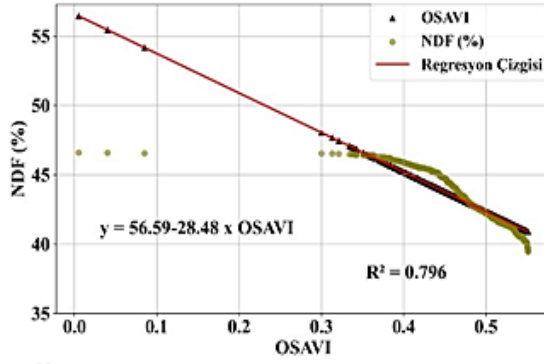
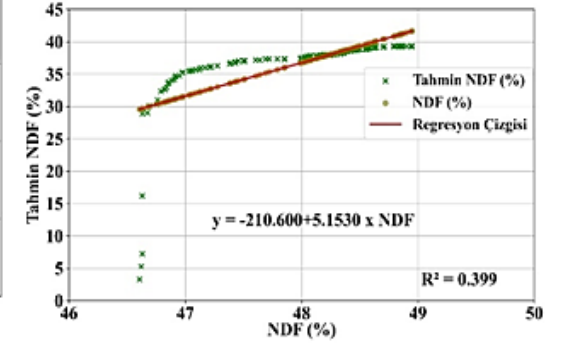
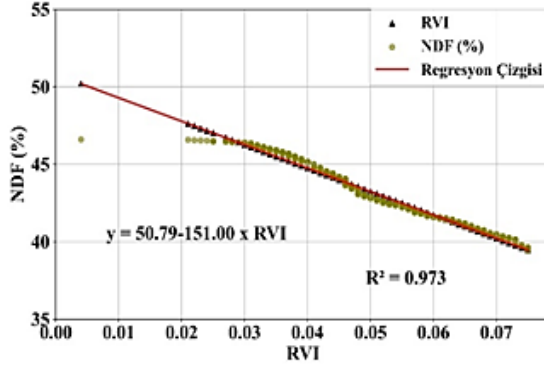
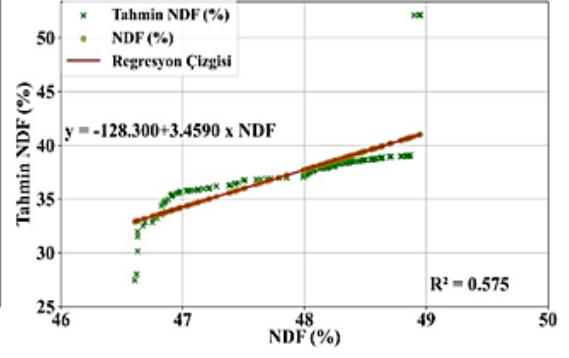
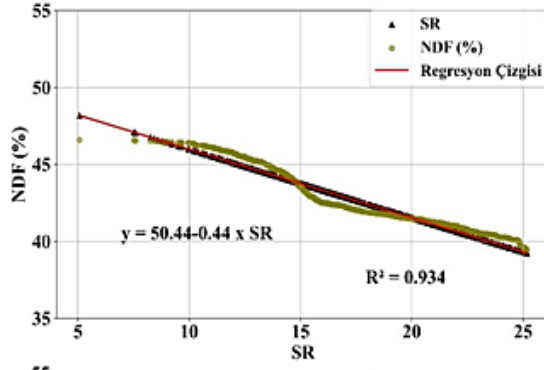
TAHMİN



Şekil 4.18 NDF oranının belirlenmesinde kullanılan GNDVI, BNDVI, CL_{REDEGE} ve DVI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

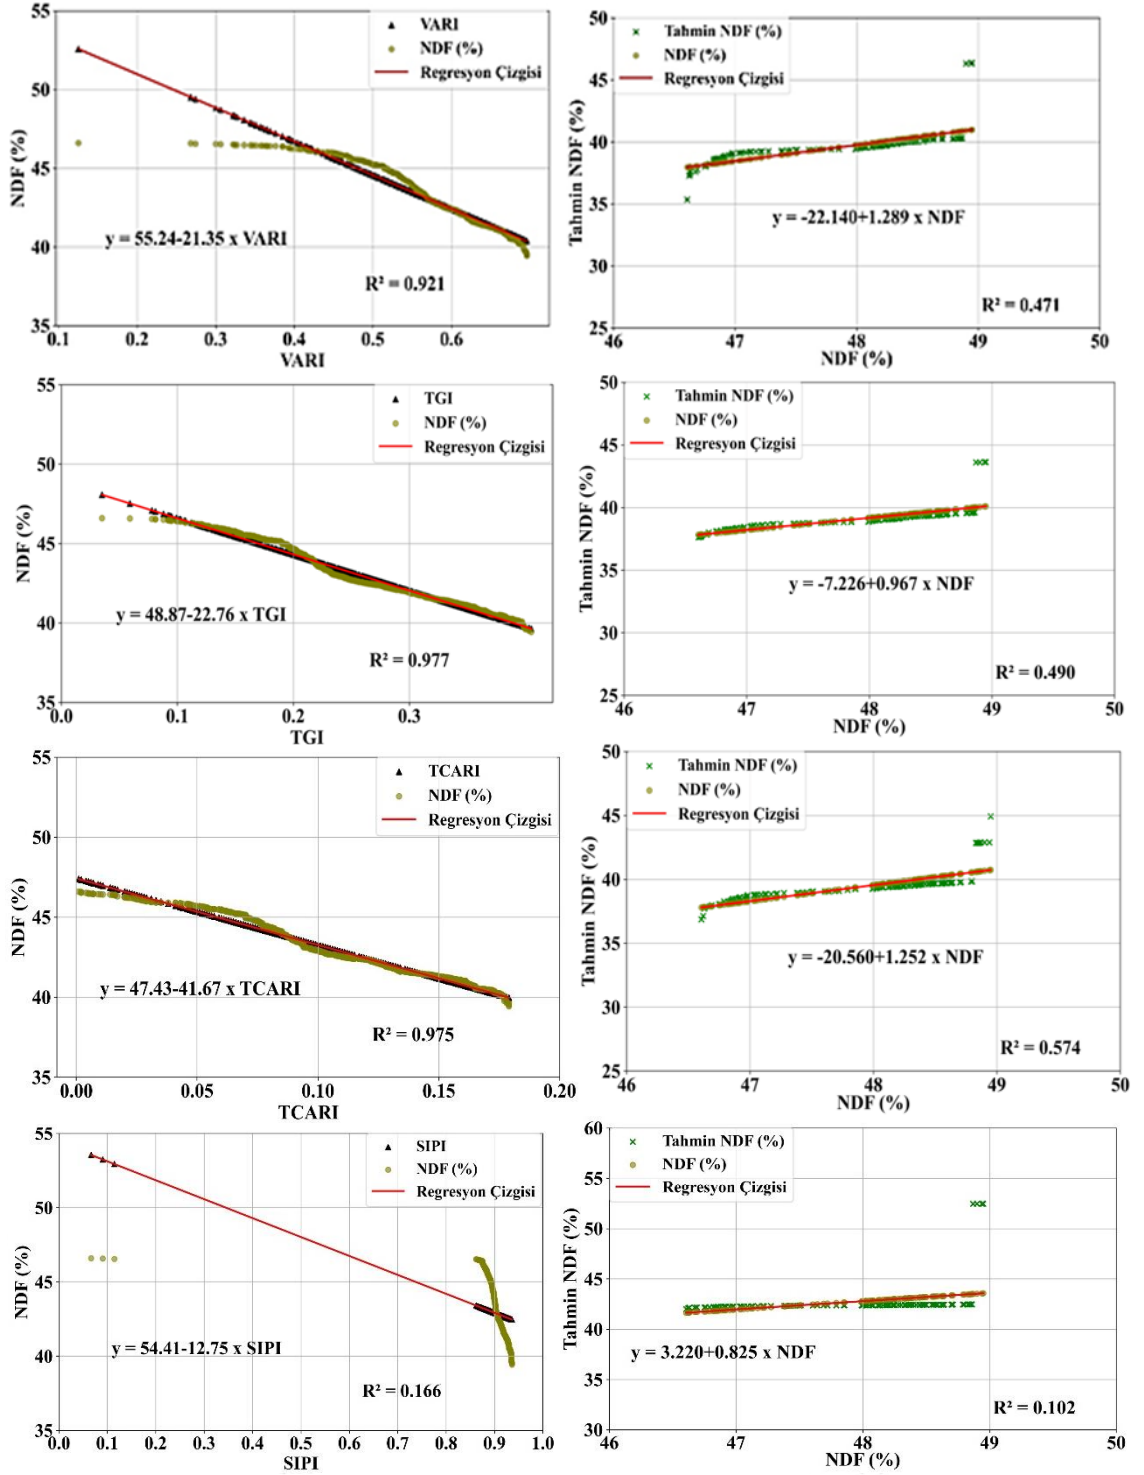
TAHMİN



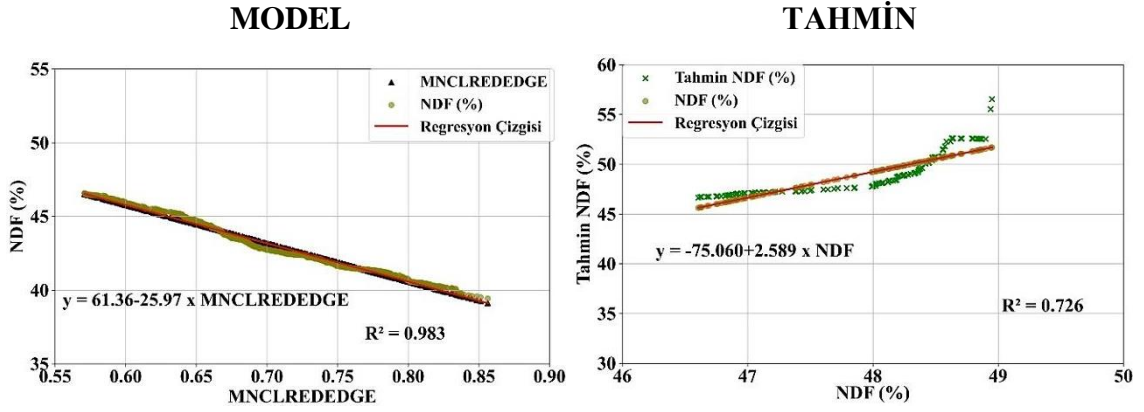
Şekil 4.20 NDF oranının belirlenmesinde kullanılan SR, RVI, OSAVI ve MCARI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

TAHMİN



Şekil 4.21 NDF oranının belirlenmesinde kullanılan VARI, TGI, TCARI ve SIPI bitki indekslerinin model-tahmin regresyon grafikleri



Şekil 4.22 NDF oranının belirlenmesinde geliştirilen modifiye NDF klorofil kırmızı kenar (MNCL_{REDEEDGE}) bitki indeksinin model-tahmin regresyon grafikleri

Bitki hücrelerinin yapısal bir bileşeni olan hücre duvarı, ışığın yansıma özelliklerini etkiler. NIR yansıması, hücre duvarı bileşimi, kalınlığı ve yoğunluğu dahil olmak üzere yapraklardaki klorofil pigmentlerinden etkilenmektedir. Bu özelliklerdeki değişiklikler, NIR ışığının yansımasını ve emilimini değiştirmekte, böylece hücre duvarı özellikleri hakkında daha net bilgi vermektedir (Jacquemoud ve Baret 1990; Hatfield vd. 2008; Soubry vd. 2017). Kırmızı bant ve NIR bölgesi arasındaki yansıma spektrumunda dik bir eğim olan kırmızı kenar, yapraktaki klorofil konsantrasyonuna bağlı olarak değişmektedir. Kırmızı kenar dönüm noktası (REIP) olarak bilinen bu kayma, klorofil içeriğindeki değişikliklere karşı oldukça hassastır (Gitelson vd. 1996; Motohka vd. 2010).

Daha yüksek klorofil içeriği kırmızı kenar dönüm noktasında daha uzun dalga boylarına doğru kırmızı bant bölgesine yaklaşan bir kaymaya neden olurken, daha düşük klorofil içeriği daha kısa dalga boylarına doğru mavi bant bölgesine yaklaşan bir kaymaya neden olmaktadır (Sims ve Gamon 2002; Herrmann vd. 2011). Dolayısıyla bu hassasiyetin ham protein, NDF ve ADF gibi kalite parametrelerinin tahmininde kırmızı kenar ve NIR bantlarını kullanan bitki indekslerini daha avantajlı kıldığını NDF tahmin modeli grafiklerinde de görmek mümkündür (Şekil 4.22).

4.6 ADF Oranı

Yonca örneklerinin ortalama Asit Deterjan Lif (ADF) oranları biçim sayılarına göre %32.78-33.92 arasında, lokasyonlara bağlı olarak ise %30.64-36.56 arasında değişirken ortalama %32.33 olarak belirlenmiştir (Çizelge 4.11).

Çizelge 4.11 Lokasyon ve biçim sayısına göre yonca ADF oranı değerleri (%)

Lokasyon	Biçim				Ortalama (%)
	1. Biçim	2. Biçim	3. Biçim	4. Biçim	
Değirmenkaşı	30.49	30.15	30.76	31.17	30.64
İsahocalı	32.83	33.12	33.36	33.60	33.23
Karahıdır	33.74	33.97	34.32	34.75	34.20
Terziali	35.38	36.21	37.07	37.60	36.56
Malya (TİGEM)	31.50	31.84	32.20	32.51	32.01
Ortalama	32.78	33.05	33.54	33.92	33.32

Araştırma materyali yoncanın ADF oranlarının bitki indeksleri aracılığıyla belirlenmesi için oluşturulan model regresyon denklemlerindeki değerler $R^2=0.168$ ile $R^2=0.993$ arasında değişmektedir. Araştırmada model regresyonları için en düşük model öğrenme oranı SIPI indeksinden, en yüksek ise NDRE indeksinden elde edilmiştir. Araştırmada kullanılan bitki indekslerinden SIPI indeksi dışındaki diğer bitki indekslerinde oldukça yüksek oranlarda öğrenme gerçekleşmiştir (Çizelge 4.12). Standart indeksler için tahmin modellerinin değerleri $R^2=0.125$ ile $R^2=0.678$ arasında belirlenirken, en düşük değer SIPI indeksinden en yüksek değer ise NDRE indeksinden elde edilmiştir. NDRE indeksi modifiye edilerek elde edilen MANDRE indeksinin $MANDRE = \frac{(NDRE+1)}{(NIR)^2 + 1}$ model değeri $R^2=0.988$ olarak, tahmin modelinin değeri ise $R^2=0.705$ olarak belirlenmiş ve bu değer tüm indeksler içinde en yüksek model öğrenme değeri olmuştur (Çizelge 4.12).

Çizelge 4.12 ADF oranının belirlenmesinde kullanılan bitki indekslerinin model-tahmin regresyon değerleri ve denklemleri


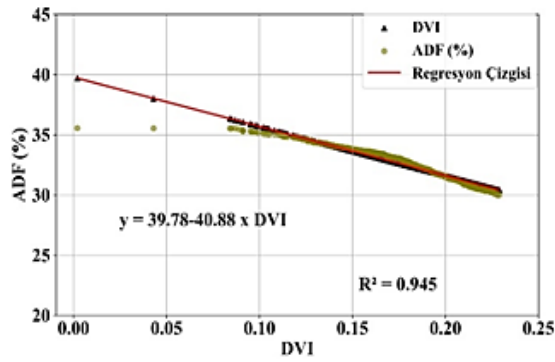
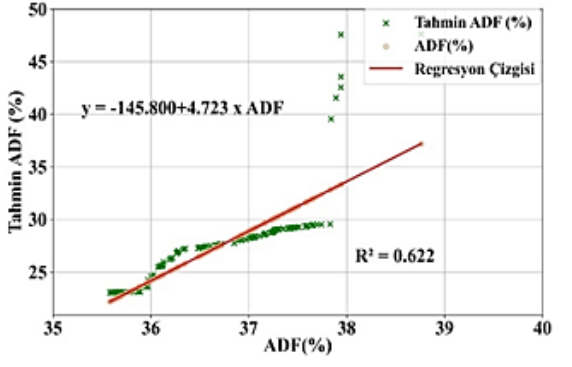
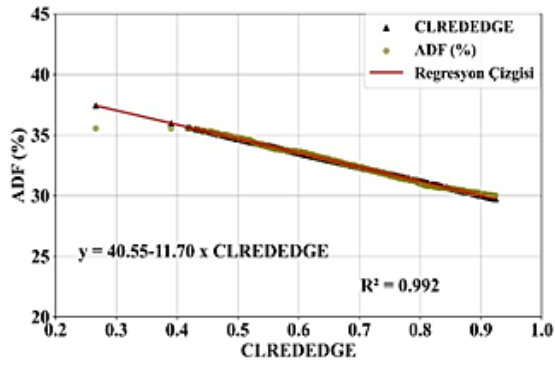
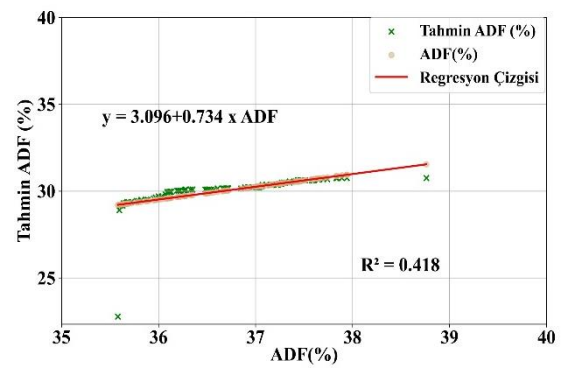

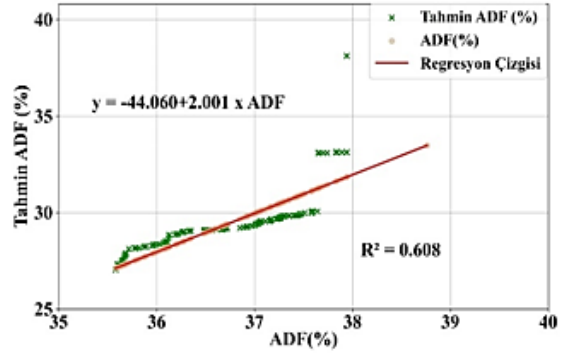

İndeks	Model		Tahmin	
	R ²	Denklem	R ²	Denklem
GNDVI	0.974	y= 61.37-38.71 x GNDVI	0.608	y= -44.06+2.001 x ADF [‡]
BNDVI	0.837	y= 90.65-65.96 x BNDVI	0.418	y= -3.096+0.7341 x ADF
CL _{REDEEDGE}	0.992	y= 40.55-11.70 x CL _{REDEEDGE}	0.622	y= -145.8+4.723 x ADF
DVI	0.945	y= 39.78-40.88 x DVI	0.474	y= -22.25+1.399 x ADF
EVI	0.935	y= 40.80-21.94 x EVI	0.534	y= -7.320+1.002 x ADF
LCI	0.985	y= 45.77-35.18 x LCI	0.587	y= -46.78+2.064 x ADF
NDRE	0.993	y= 43.92-45.42 x NDRE	0.678	y= -44.40+1.986 x ADF
NDVI	0.742	y= 65.42-37.22 x NDVI	0.351	y= 2.996+0.7482 x ADF
SR	0.992	y= 38.68-0.3556 x SR	0.512	y= -93.57+3.309 x ADF
RVI	0.977	y=38.79-117.4 x RVI	0.373	y= -120.8+4.022 x ADF
OSAVI	0.763	y= 43.05-21.64 x OSAVI	0.291	y= -7.020+1.028 x ADF
MCARI	0.879	y= 45.73-15.04 x MCARI	0.604	y= -16.37+1.138 x ADF
VARI	0.883	y= 42.02-16.22 x VARI	0.485	y= -12.03+1.145 x ADF
TGI	0.984	y= 37.30-17.22 x TGI	0.430	y= -2.681+0.8787 x ADF
TCARI	0.970	y= 36.16-32.26 x TCARI	0.513	y= 3.568+0.7104 x ADF
SIPI	0.168	y= 41.61-9.926 x SIPI	0.125	y= 3.351+0.7908 x ADF
MANDRE^φ	0.988	y= -73.66+88.20 x MANDRE	0.705	y= -4.612+1.113 x ADF

MANDRE^φ: Modifiye edilmiş ADF kırmızı kenar bandı indeksi, ADF[‡]: Asit deterjan fiber

NDF hücre duvarının her iki kısmında da bulunan selüloz, lignin ve hemiselüloz yapısal karbonhidratlarını içerirken, ADF ikincil hücre duvarında bulunan selüloz ve lignin yapısal karbonhidratlarını içermektedir (Yavuz 2005). Bu nedenle ADF oranı tahmin modellerinde kabul edilebilir belirtme katsayıları (R²) değerleri veren indekslerle NDF oranı tahmin modellerinde kabul edilebilir değerleri veren bazı indekslerin benzer olması beklenen bir durumdur. Nitekim hem NDF hem de ADF tahmin modellerinde modifiye ederek geliştirdiğimiz indeksler dışındaki GNDVI, CL_{REDEEDGE}, NDRE ve MCARI indeksleri söz konusu kalite parametrelerini kabul edilebilir doğrulukta tahmin etmişlerdir (Şekil 4. 24 ve Şekil 4.25).

MODEL

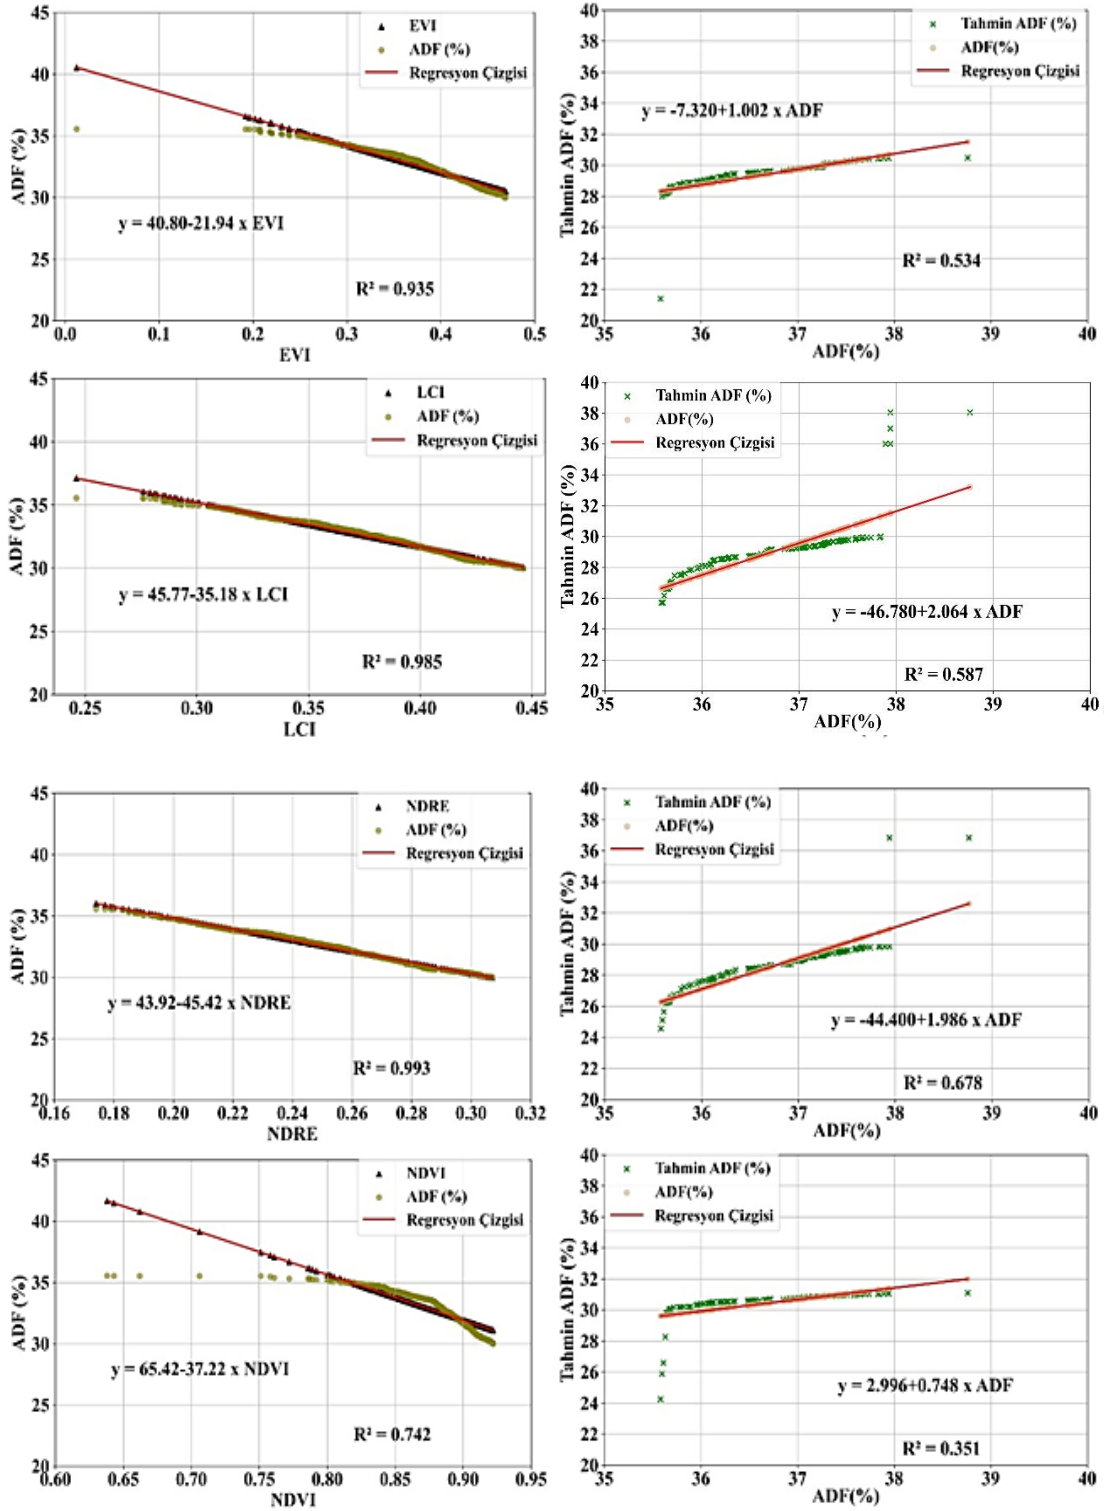
TAHMİN



Şekil 4.23 ADF oranının belirlenmesinde kullanılan GNDVI, BNDVI, CL_{REDEDGE} ve DVI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

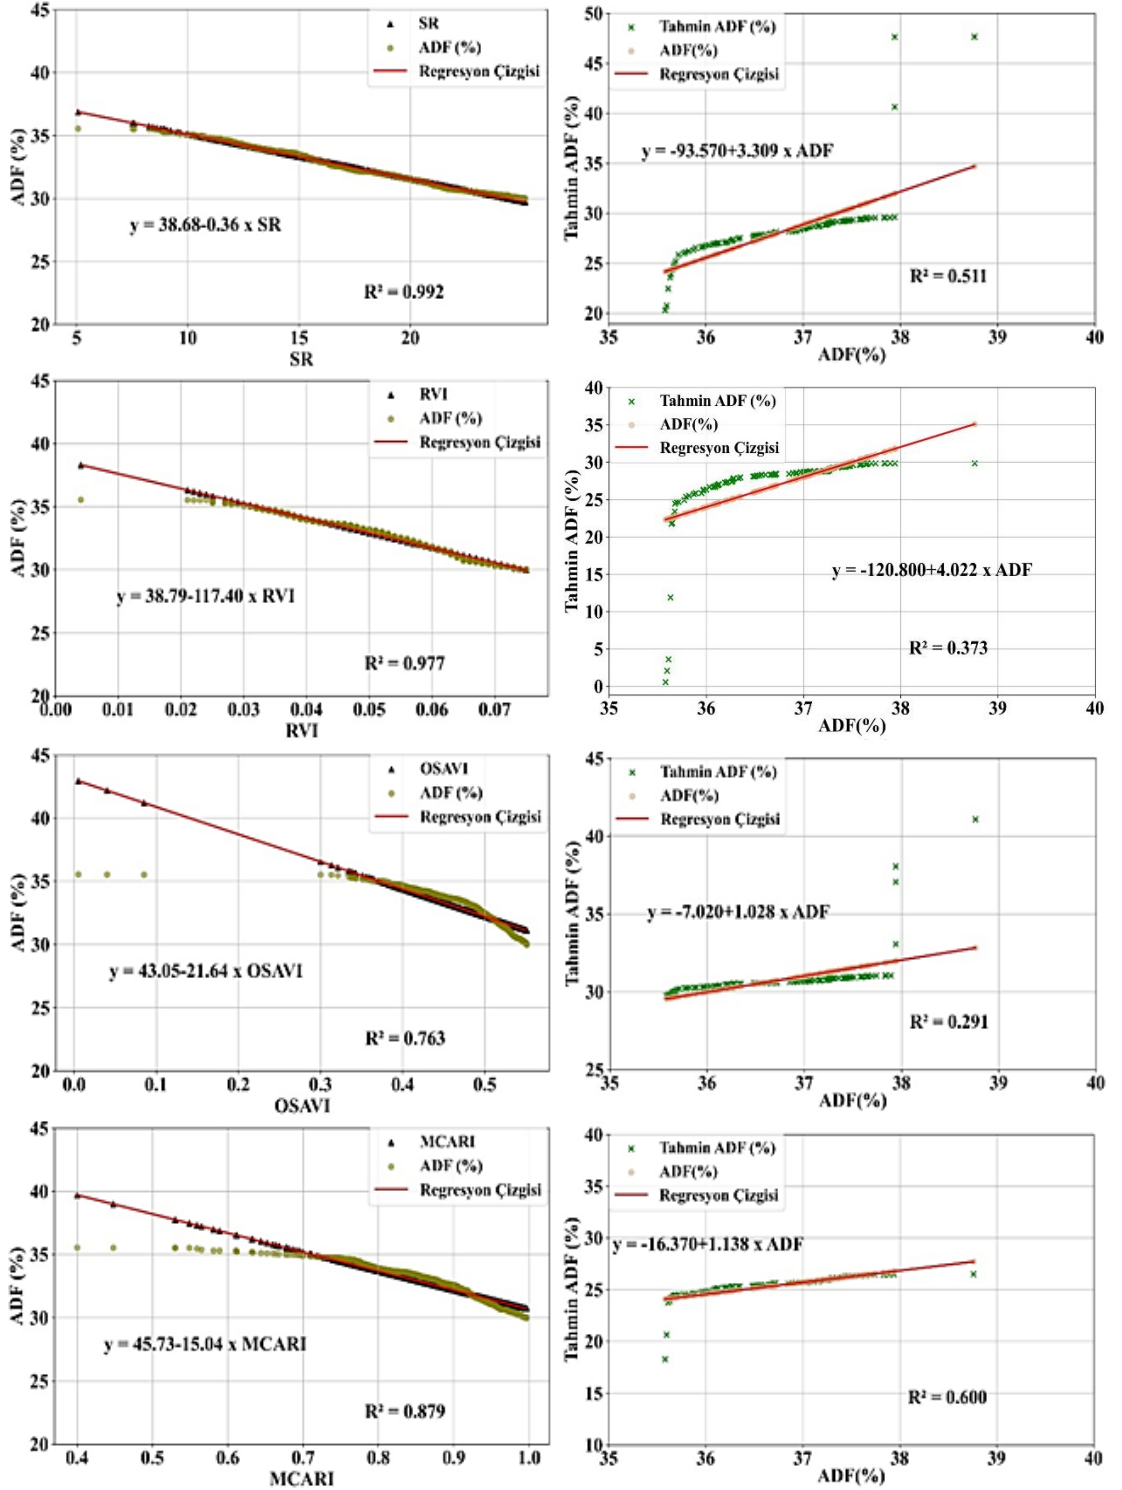
TAHMİN



Şekil 4.24 ADF oranının belirlenmesinde kullanılan EVI, LCI, NDRE ve NDVI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

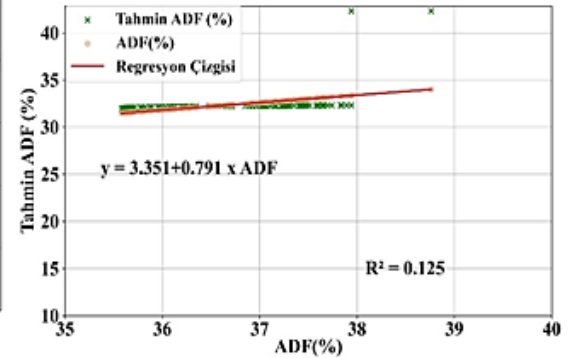
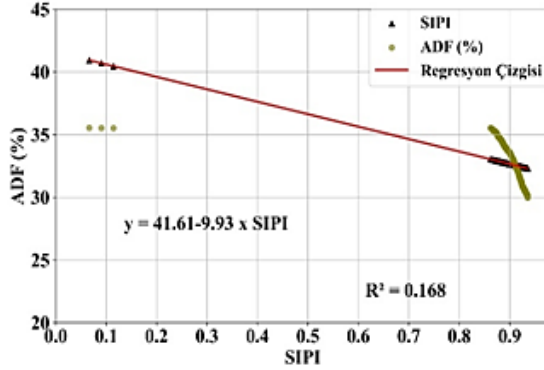


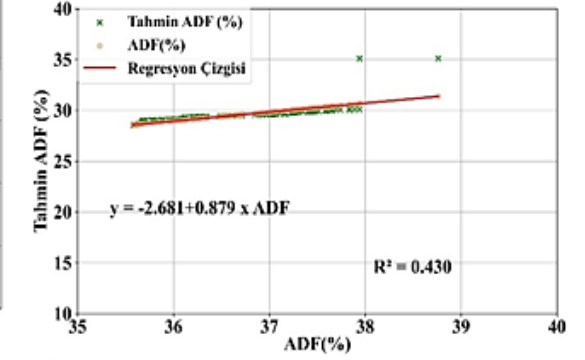
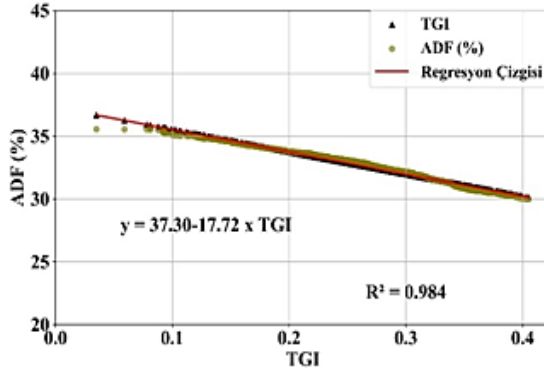


TAHMİN



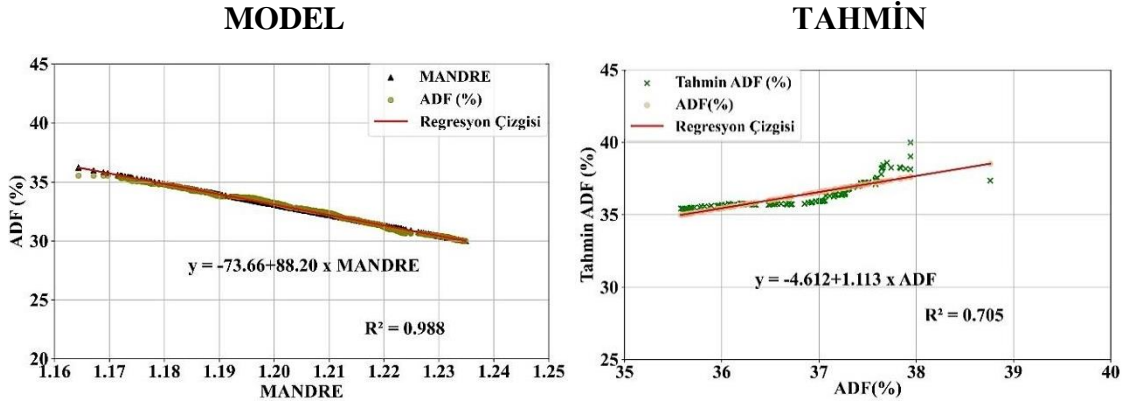
Şekil 4.25 ADF oranının belirlenmesinde kullanılan SR, RVI, OSAVI ve MCARI bitki indekslerinin model-tahmin regresyon grafikleri

MODEL

TAHMİN



Şekil 4.26 ADF oranının belirlenmesinde kullanılan VARI, TGI, TCARI ve SIPI bitki indekslerinin model-tahmin regresyon grafikleri



Şekil 4.27 ADF oranının belirlenmesinde geliştirilen modifiye ADF kırmızı kenar (MANDRE) bitki indeksinin model-tahmin regresyon grafikleri

Literatürde hücre duvarı materyallerindeki değişikliklere karşı hassas olan kırmızı kenar bandının, hücre duvarının ana bileşenleri olan lignin ve selülozun NIR bölgesinde belirgin spektral özelliklere sahip olduğu ifade edilmektedir (Curran 1989; Singh vd. 2015). Kırmızı kenar bandının dalga boyu, kırmızı bandın yerel minimum yansıtması ile NIR spektral bölgelerindeki maksimum yansıtmayı birleştiren eğim üzerindeki bükülme noktasının konumu olarak tanımlanmaktadır (Mutanga ve Skidmore 2004; Zhang vd. 2011). Bu konum fizyolojik olarak spektrumun fotosentetik olarak aktif bölgesi ile bitki hücre yapısı veya yaprak katmanlarından etkilenen NIR aralığının yüksek yansıma bölgesi arasındaki geçişi göstermektedir (Herrmann vd. 2011). Bu da aslında klorofil emiliminin nasıl gerçekleştiğini net bir şekilde ortaya koymaktadır.

Klorofil emilimi arttıkça daha uzun dalga boylarına, klorofil emilimi azaldıkça ise daha kısa dalga boylarına doğru bir kayma olduğunu literatürde de belirtilmiştir (Maas vd. 2004; Ji-Yong vd. 2012). Nitekim bu durumu elektromanyetik spektrum NIR bölgesini kullanan standart GNDVI, $CL_{REDEEDGE}$, MCARI ve NDRE indeksleriyle birlikte geliştirdiğimiz MANDRE indeksinin grafiklerinde de gözlemlemek mümkündür. Çünkü bu indekslerde elektromanyetik spektrumun NIR bölgesinin olması, model grafiklerindeki bitki indeksi skala aralıklarının diğer indekslere göre daha hassas olmasına neden olmuş ve söz konusu bu indekslerin ADF oranlarını diğer indekslere göre daha yüksek doğrulukta tahmin etmelerini sağlamıştır (Şekil 4.27).

Uzaktan algılama teknolojileriyle elde edilen verilerdeki ölçüm hataları genellikle güneş ışığı açısındaki değişikliklerinin yanı sıra yerel topografya ve diğer çevresel faktörlerdeki değişikliklerden kaynaklanmaktadır. Bu hatalar genellikle kırmızı ve yakın kızılötesi yansımalarda eşzamanlı artış veya azalışlara neden olmakta ve oransal etkileri büyük ölçüde azaltılabilmektedir (Clevers vd. 2002; Delegido vd. 2013). Bant oranlama yöntemi dışındaki matematiksel işlemleri içeren diğer tüm indeksler, hataları koruyabilecek ve hatta artırabilecektir (Chen 1996; Q. Xie vd. 2018). Elektromanyetik spektrumun NIR bölgesi (700-1400 nm), bitki hücre duvarlarındakiler de dahil olmak üzere organik bileşiklerdeki kimyasal bağlara karşı özellikle hassastır. NIR yansıması, selüloz ve ligninin moleküler titreşimlerinden etkilenmekte ve bu da onu bitki ADF oranını belirleme konusunda güvenilir bir göstergesi yapabilmektedir (Salisbury ve Milton 1988; Shi vd. 2021).

5. SONUÇLAR VE ÖNERİLER

Bu tez çalışması, yoncada bitki boyu, yaş ot ve kuru ot gibi verim parametreleri yanında ham protein oranı, NDF ve ADF gibi kalite parametrelerinin de uzaktan algılama teknolojileriyle özellikle de İHA ile belirlenmesi amacıyla yürütülmüştür. Araştırmada elde edilen sonuçlar aşağıdaki gibidir.

Araştırma sonuçlarına göre, yonca bitki boyu 73.0 cm ile 85.6 cm arasında değişiklik göstermiş ve ortalama 78.1 cm olarak belirlenmiştir. GNDVI indeksi bitki boyunu, %81.9 doğrulukta tahmin ederek etkili bir sonuç vermiştir. Bu sonuç, bitki gelişiminin izlenmesinde GNDVI indeksinin güvenilir bir araç olarak kullanılabilceğini göstermektedir. Yoncanın yaş ot verimi 1595.4- 2493.8 kg da⁻¹ arasında değişiklik gösterirken, ortalama yaş ot verimi 8181.5 kg da⁻¹ olarak hesaplanmıştır. Yaş ot verimini NDRE indeksi %93.5 doğrulukla tahmin etmiştir. Yonca kuru ot verimi 432.6-698.3 kg da⁻¹ arasında değişirken, toplam ortalama kuru ot verimi ise 2335.3 kg da⁻¹ olarak hesaplanmıştır. Kuru ot verimi tahmininde de GNDVI indeksi, %97.4 gibi yüksek bir doğruluk oranıyla etkili bir tahmin aracı olduğunu kanıtlamıştır.

Önemli kalite parametrelerinden biri olan ham protein oranı, lokasyonlara bağlı olarak %17.86 ile %21.35 arasında değişiklik göstermiş ve ortalama %19.88 olarak belirlenmiştir. Ham protein oranını tahmin etmek için kullanılan MPNDRE indeksi, %82 doğruluk oranı ile bu parametrenin güvenilir bir şekilde tahmin edilebileceğini ortaya koymuştur. NDF oranı ise %40.56 ile %47.70 arasında değişirken, ortalama %42.75 olarak belirlenmiştir. NDF oranını tahmin etmede MNCL_{REDEGE} indeksi %72.6 doğruluk oranıyla önemli bir başarı sağlamıştır. ADF oranı %30.64 ile %36.56 arasında değişiklik göstermiş ve ortalama %32.33 olarak hesaplanmıştır. MANDRE indeksi, %70.5 doğruluk oranıyla ADF oranının tahmini için kullanılan indeksler arasında en yüksek performansı sergilemiştir. Hücre duvarında bulunduğu yer nedeniyle ADF oranı, ham protein ve NDF oranlarına göre daha düşük oranda doğrulukla tahmin edilmiştir. Klasik bitki indeksleri her ne kadar tatmin edici sonuçlar verse de bitkinin farklı fizyolojik aşamaları, iklim faktörleri, toprak çeşitliği gibi parametreler dahil edilerek geliştirilen bitki indeksleri klasik indekslere göre daha yüksek doğrulukta sonuçlar vermektedir.

Modifiye edilen indeksler, yoğun emek gerektiren saha örnekleme ve laboratuvar analizlerine umut verici alternatifler sunarak, yem kalitesinin hızlı ve ekonomik bir şekilde tespit edilebileceğini göstermiştir. Kalite parametreleri açısından, modifiye edilmiş indeksler dikkate değer bir verimlilikle tahmin doğruluklarını yaklaşık olarak %5 oranında arttırmışlardır. Kırmızı, kırmızı kenar ve yakın kızılötesi dalga boyu aralıklarını kullanan bitki indekslerinde yapılan modifikasyonlar, yoncada verim ve kalite parametrelerini belirlemede önemli avantajlar sağlamaktadır. Modifiye indeksler elde edilirken NIR tabanlı bitki indekslerinin verim tahminlerinde, Kırmızı Kenar tabanlı indekslerin ise kalite tespitinde daha etkili oldukları görülmüştür.

Yoncada hem verim hem de kaliteyi belirleme aşamalarında modifiye indekslerin kullanılması hassas verilere kısa sürede ulaşılmasını sağlayarak karar verme süreçlerini olumlu yönde etkileyecektir. Dolayısıyla araştırmadan elde edilen çıktılar çiftçilerin karar alma süreçlerinde, tarımsal üretimin iyileştirilmesinde ve kaynak kullanımının optimize edilmesinde önemli bir rol oynayacaktır. Bu amaçla farklı gelişim evrelerinde hastalık veya zararlıya maruz kalan tesislerde akıllı tarım uygulamalarıyla yapılacak yeni çalışmalar bu alanda boşluğu kapatmaya katkı sağlayacaktır. Yine gübreleme, sulama gibi tekniklerin verim ve kaliteye etkisi de ilerleyen çalışmalarda göz ardı edilmemelidir.

Sürdürülebilirlik ve akıllı tarım uygulamalarına olan talebin artması bu alanda önemli literatür boşluğunun ortaya çıkmasına neden olmuştur. Her ne kadar dünyada akıllı tarım uygulamalarını yoğun olarak kullanan ülkelerde bazı bitki gruplarında çığır açan ön çalışmalar yapılmış olsa da Türkiye’de yoncada uzaktan algılama teknolojileriyle verim ve kaliteyi belirme konusunda yapılan bu ilk araştırmaya ek olarak literatürdeki boşluğu doldurmak için daha fazla araştırma yapılması gerektiği açıktır.

KAYNAKLAR

- Adewopo, J., Peter, H., Mohammed, I., Kamara, A., Craufurd, P. ve Vanlauwe, B. 2020. Can a combination of UAV-derived vegetation indices with biophysical variables improve yield variability assessment in smallholder farms? *Agronomy*, 10(12), 1934.
- Anonim, 2021. Web Sitesi: <https://www.ankom.com/> (Erişim Tarihi: 10 Haziran 2024).
- Anonim, 2024a. Web Sitesi: <https://www.dji.com/global/p4-multispectral> (Erişim Tarihi: 13 Haziran 2024).
- Anonim, 2024b. Web Sitesi: <https://www.dji.com/global/ground-station-pro> (Erişim Tarihi: 13 Haziran 2024).
- AOAC, 2005. Association of Official Analytical Chemists, 18th ed. Association of Official Analytical Chemists International, Maryland, USA.
- Ayyıldız, M. T. ve Meliha, Z. 2022. Türkiye’de Yem Bitkisi Desteklemeleri ile Ekim Alanı Arasındaki Nedensellik İlişkisi, International Conference on Global Practice of Multidisciplinary Scientific Studies-III, November 15-17, Turkish Republic of Northern Cyprus.
- Baldocchi, D. D., Ryu, Y., Dechant, B., Eichelmann, E., Hemes, K., Ma, S., Sanchez, C. R., Shortt, R., Szutu, D. ve Valach, A. 2020. Outgoing near-infrared radiation from vegetation scales with canopy photosynthesis across a spectrum of function, structure, physiological capacity, and weather. *Journal of Geophysical Research: Biogeosciences*, 125(7), e2019JG005534.
- Bannari, A., Morin, D., Bonn, F. ve Huete, A. 1995. A review of vegetation indices. *Remote Sensing Reviews*, 13(1-2), 95-120.
- Bao, L., Li, X., Yu, J., Li, G., Chang, X., Yu, L. ve Li, Y. 2024. Forecasting spring maize yield using vegetation indices and crop phenology metrics from UAV observations. *Food and Energy Security*, 13(1), e505.
- Beck, P., Jönsson, P., Høgda, K. A., Karlsen, S., Eklundh, L. ve Skidmore, A. 2007. A ground-validated NDVI dataset for monitoring vegetation dynamics and mapping phenology in Fennoscandia and the Kola peninsula. *International Journal of Remote Sensing*, 28(19), 4311-4330.
- Biewer, S., Fricke, T., Wachendorf, M. ve Wachendorf, M. 2009. Development of canopy reflectance models to predict forage quality of legume–grass mixtures. *Crop Science*, 49(5), 1917-1926.
- Casadesús, J., Kaya, Y., Bort, J., Nachit, M., Araus, J., Amor, S., Ferrazzano, G., Maalouf, F., Maccaferri, M. ve Martos, V. 2007. Using vegetation indices derived

from conventional digital cameras as selection criteria for wheat breeding in water-limited environments. *Annals of applied biology*, 150(2), 227-236.

- Cazenave, A. B., Shah, K., Trammell, T., Komp, M., Hoffman, J., Motes, C. M. ve Monteros, M. J. 2019. High-throughput approaches for phenotyping alfalfa germplasm under abiotic stress in the field. *The Plant Phenome Journal*, 2(1), 1-13.
- Chen, J. M. 1996. Evaluation of vegetation indices and a modified simple ratio for boreal applications. *Canadian Journal of Remote Sensing*, 22(3), 229-242.
- Cho, M., Skidmore, A., Atzberger, C. ve Atzberger, C. 2008. Towards red-edge positions less sensitive to canopy biophysical parameters for leaf chlorophyll estimation using properties optiques spectrales des feuilles (PROSPECT) and scattering by arbitrarily inclined leaves (SAILH) simulated data. *International Journal of Remote Sensing*, 29(8), 2241-2255.
- Clay, D., Kim, K. I., Chang, J., Clay, S. ve Dalsted, K. 2006. Characterizing water and nitrogen stress in corn using remote sensing. *Agronomy journal*, 98(3), 579-587.
- Clevers, J., De Jong, S., Epema, G., Van Der Meer, F., Bakker, W., Skidmore, A. ve Scholte, K. 2002. Derivation of the red edge index using the MERIS standard band setting. *International Journal of Remote Sensing*, 23(16), 3169-3184.
- Clevers, J. ve Gitelson, A. A. 2013. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and -3. *International Journal of Applied Earth Observation and Geoinformation*, 23, 344-351.
- Clevers, J. ve Kooistra, L. 2011. Using hyperspectral remote sensing data for retrieving canopy chlorophyll and nitrogen content. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2), 574-583.
- Curran, P. J. 1989. Remote sensing of foliar chemistry. *Remote sensing of environment*, 30(3), 271-278.
- Curran, P. J., Dungan, J. L., Gholz, H. L. ve Gholz, H. L. 1990. Exploring the relationship between reflectance red edge and chlorophyll content in slash pine. *Tree physiology*, 7(1-2-3-4), 33-48.
- Daughtry, C. S., Walthall, C., Kim, M., De Colstoun, E. B. ve McMurtrey Iii, J. 2000. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote sensing of environment*, 74(2), 229-239.
- Debats, S. R., Luo, D., Estes, L. D., Fuchs, T. J. ve Caylor, K. K. 2016. A generalized computer vision approach to mapping crop fields in heterogeneous agricultural landscapes. *Remote sensing of environment*, 179, 210-221.

- Delegido, J., Verrelst, J., Meza, C., Rivera, J., Alonso, L. ve Moreno, J. 2013. A red-edge spectral index for remote sensing estimation of green LAI over agroecosystems. *European Journal of Agronomy*, 46, 42-52.
- Drusch, M., Gascon, F., Berger, M. ve Berger, M. (2010). GMES Sentinel-2 mission requirements document. In *Earth*.
- Duchemin, B., Fieuzal, R., Rivera, M. A., Ezzahar, J., Jarlan, L., Rodriguez, J. C., Hagolle, O. ve Watts, C. 2015. Impact of sowing date on yield and water use efficiency of wheat analyzed through spatial modeling and FORMOSAT-2 images. *Remote Sensing*, 7(5), 5951-5979.
- Dvorak, J. S., Pampolini, L. F., Jackson, J. J., Seyyedhasani, H., Sama, M. P. ve Goff, B. 2021. Predicting Quality and Yield of Growing Alfalfa from a UAV. *Transactions of the ASABE*, 64(1), 63-72.
- Dymond, J. R. ve Shepherd, J. D. 2004. The spatial distribution of indigenous forest and its composition in the Wellington region, New Zealand, from ETM+ satellite imagery. *Remote sensing of environment*, 90(1), 116-125.
- Eitel, J., Long, D., Gessler, P., Hunt Jr, E. ve Brown, D. 2009. Sensitivity of ground-based remote sensing estimates of wheat chlorophyll content to variation in soil reflectance. *Soil Science Society of America Journal*, 73(5), 1715-1723.
- Elfanssi, S., Ouazzani, N., Mandi, L. ve Mandi, L. 2018. Soil properties and agro-physiological responses of alfalfa (*Medicago sativa* L.) irrigated by treated domestic wastewater. *Agricultural Water Management*, 202, 231-240.
- Feng, L., Zhang, Z., Ma, Y., Du, Q., Williams, P., Drewry, J. ve Luck, B. 2020. Alfalfa Yield Prediction Using UAV-Based Hyperspectral Imagery and Ensemble Learning. *Remote Sensing*, 12(12).
- Feng, L., Zhang, Z., Ma, Y., Sun, Y., Du, Q., Williams, P., Drewry, J. ve Luck, B. 2022. Multitask Learning of Alfalfa Nutritive Value From UAV-Based Hyperspectral Images. *IEEE Geoscience and Remote Sensing Letters*, 19, 1-5.
- Floreano, D. ve Wood, R. J. 2015. Science, technology and the future of small autonomous drones. *nature*, 521(7553), 460-466.
- Fricke, T. ve Wachendorf, M. 2013. Combining ultrasonic sward height and spectral signatures to assess the biomass of legume–grass swards. *Computers and Electronics in Agriculture*, 99, 236-247.
- Galvão, L. S., Roberts, D. A., Formaggio, A. R., Numata, I. ve Breunig, F. M. 2009. View angle effects on the discrimination of soybean varieties and on the relationships between vegetation indices and yield using off-nadir Hyperion data. *Remote sensing of environment*, 113(4), 846-856.

- Gámez, A. L., Vatter, T., Santesteban, L. G., Araus, J. L. ve Aranjuelo, I. 2024. Onfield estimation of quality parameters in alfalfa through hyperspectral spectrometer data. *Computers and Electronics in Agriculture*, 216.
- Gao, B.-C. 1996. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote sensing of environment*, 58(3), 257-266.
- Gitelson, A. A. 2004. Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. *Journal of Plant Physiology*, 161(2), 165-173.
- Gitelson, A. A., Kaufman, Y. J. ve Merzlyak, M. N. 1996. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote sensing of environment*, 58(3), 289-298.
- Gitelson, A. A. ve Merzlyak, M. N. 1994. Spectral reflectance changes associated with autumn senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. leaves. Spectral features and relation to chlorophyll estimation. *Journal of Plant Physiology*, 143(3), 286-292.
- Gitelson, A. A. ve Merzlyak, M. N. 1996. Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll. *Journal of Plant Physiology*, 148(3-4), 494-500.
- Gitelson, A. A. ve Merzlyak, M. N. 1998. Remote sensing of chlorophyll concentration in higher plant leaves. *Advances in space research*, 22(5), 689-692.
- Gitelson, A. A., Merzlyak, M. N., Chivkunova, O. B. ve Chivkunova, O. B. 2001. Optical properties and nondestructive estimation of anthocyanin content in plant leaves. *Photochemistry and photobiology*, 74(1), 38-45.
- Gitelson, A. A., Merzlyak, M. N., Lichtenthaler, H. K. ve Lichtenthaler, H. K. 1996. Detection of red edge position and chlorophyll content by reflectance measurements near 700 nm. *Journal of Plant Physiology*, 148(3-4), 501-508.
- Gitelson, A. A., Stark, R., Grits, U., Rundquist, D., Kaufman, Y. ve Derry, D. 2002. Vegetation and soil lines in visible spectral space: A concept and technique for remote estimation of vegetation fraction. *International Journal of Remote Sensing*, 23(13), 2537-2562.
- Gitelson, A. A., Viña, A., Ciganda, V., Rundquist, D. C. ve Arkebauer, T. J. 2005. Remote estimation of canopy chlorophyll content in crops. *Geophysical research letters*, 32(8).
- Gitelson, A. A., Zur, Chivkunova, O. B. ve Merzlyak, M. N. 2002. Assessing carotenoid content in plant leaves with reflectance spectroscopy. *Photochemistry and photobiology*, 75(3), 272-281.

- Guyot, G. 1989. Signatures spectrales des surfaces naturelles. Télédétection satellitaire, 5. Paradigme, Caen.
- Haboudane, D., Miller, J. R., Pattey, E., Zarco-Tejada, P. J. ve Strachan, I. B. 2004. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote sensing of environment*, 90(3), 337-352.
- Haboudane, D., Miller, J. R., Tremblay, N., Zarco-Tejada, P. J. ve Dextraze, L. 2002. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote sensing of environment*, 81(2-3), 416-426.
- Hancock, D. W. ve Dougherty, C. T. 2007. Relationships between blue-and red-based vegetation indices and leaf area and yield of alfalfa. *Crop Science*, 47(6), 2547-2556.
- Hansen, P. ve Schjoerring, J. 2003. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. *Remote sensing of environment*, 86(4), 542-553.
- Hatfield, J. L., Gitelson, A. A., Schepers, J. S. ve Walthall, C. L. 2008. Application of spectral remote sensing for agronomic decisions. *Agronomy journal*, 100, S-117-S-131.
- Hatfield, J. L. ve Prueger, J. H. 2010. Value of using different vegetative indices to quantify agricultural crop characteristics at different growth stages under varying management practices. *Remote Sensing*, 2(2), 562-578.
- Hernandez, A., Jensen, K., Larson, S., Larsen, R., Rigby, C., Johnson, B., Spickermann, C. ve Sinton, S. 2024. Using Unmanned Aerial Vehicles and Multispectral Sensors to Model Forage Yield for Grasses of Semiarid Landscapes. *Grasses*, 3(2), 84-109.
- Herrmann, I., Pimstein, A., Karnieli, A., Cohen, Y., Alchanatis, V. ve Bonfil, D. 2011. LAI assessment of wheat and potato crops by VEN μ S and Sentinel-2 bands. *Remote sensing of environment*, 115(8), 2141-2151.
- Hill, M. J. 2004. Grazing agriculture—managed pasture, grassland and rangeland. (Vol. 4). In *Manual of Remote Sensing, Remote Sensing for Natural Resource Management and Environmental Monitoring*; Ustin, S.L., Ed.; Wiley International: New York, NY, USA.
- Holben, B. ve Justice, C. 1981. An examination of spectral band ratioing to reduce the topographic effect on remotely sensed data. *International Journal of Remote Sensing*, 2(2), 115-133.

- Horler, D., Dockray, M., Barber, J. ve Barber, J. 1983. The red edge of plant leaf reflectance. *International Journal of Remote Sensing*, 4(2), 273-288.
- Houborg, R., Anderson, M., Daughtry, C. ve Daughtry, C. 2009. Utility of an image-based canopy reflectance modeling tool for remote estimation of LAI and leaf chlorophyll content at the field scale. *Remote sensing of environment*, 113(1), 259-274.
- Hrbáčková, M., Dvořák, P., Takáč, T., Tichá, M., Luptovčíak, I., Šamajová, O., Ovečka, M. ve Šamaj, J. 2020. Biotechnological perspectives of omics and genetic engineering methods in alfalfa. *Frontiers in plant science*, 11, 592.
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X. ve Ferreira, L. G. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote sensing of environment*, 83(1-2), 195-213.
- Huete, A., Liu, H., Batchily, K. ve Van Leeuwen, W. 1997. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote sensing of environment*, 59(3), 440-451.
- Hunt, E. R., Daughtry, C., Eitel, J. U. ve Long, D. S. 2011. Remote sensing leaf chlorophyll content using a visible band index. *Agronomy journal*, 103(4), 1090-1099.
- Hunt, E. R., Doraiswamy, P. C., McMurtrey, J. E., Daughtry, C. S., Perry, E. M. ve Akhmedov, B. 2013. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. *International Journal of Applied Earth Observation and Geoinformation*, 21, 103-112.
- İleri, O. (2020). Bozdağ mera bitki örtüsünün durumu, elverişli yem üretimi ve kalitesinin mevsimsel değişiminin uzaktan algılama tekniği ile izlenmesi. Doktora Tezi, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü.
- İleri, O. ve Koç, A. 2022. Monitoring the available forage using Sentinel 2-derived NDVI data for sustainable rangeland management. *Journal of Arid Environments*, 200, 104727.
- Jackson, R. D. ve Huete, A. R. 1991. Interpreting vegetation indices. *Preventive veterinary medicine*, 11(3-4), 185-200.
- Jacquemoud, S. ve Baret, F. 1990. PROSPECT: A model of leaf optical properties spectra. *Remote sensing of environment*, 34(2), 75-91.
- Jacquemoud, S., Verhoef, W., Baret, F., Bacour, C., Zarco-Tejada, P. J., Asner, G. P., François, C. ve Ustin, S. L. 2009. PROSPECT+ SAIL models: A review of use for vegetation characterization. *Remote sensing of environment*, 113, S56-S66.

- Jelínek, Z., Starý, K., Kumhálová, J., Lukáš, J. ve Mašek, J. 2020. Winter wheat, winter rape and poppy crop growth evaluation with the help of remote and proximal sensing measurements.
- Jha, P. K., Athanasiadis, P., Gualdi, S., Trabucco, A., Mereu, V., Shelia, V. ve Hoogenboom, G. 2019. Using daily data from seasonal forecasts in dynamic crop models for yield prediction: A case study for rice in Nepal's Terai. *Agricultural and forest meteorology*, 265, 349-358.
- Ji-Yong, S., Xiao-Bo, Z., Jie-Wen, Z., Kai-Liang, W., Zheng-Wei, C., Xiao-Wei, H., De-Tao, Z. ve Holmes, M. 2012. Nondestructive diagnostics of nitrogen deficiency by cucumber leaf chlorophyll distribution map based on near infrared hyperspectral imaging. *Scientia Horticulturae*, 138, 190-197.
- Jiang, Z., Huete, A. R., Didan, K. ve Miura, T. 2008. Development of a two-band enhanced vegetation index without a blue band. *Remote sensing of environment*, 112(10), 3833-3845.
- Jin, X., Li, Z., Feng, H., Ren, Z. ve Li, S. 2020. Deep neural network algorithm for estimating maize biomass based on simulated Sentinel 2A vegetation indices and leaf area index. *The Crop Journal*, 8(1), 87-97.
- Jordan, C. F. 1969. Derivation of leaf-area index from quality of light on the forest floor. *Ecology*, 50(4), 663-666.
- Jorge, J., Vallbé, M., Soler, J. A. ve Soler, J. A. 2019. Detection of irrigation inhomogeneities in an olive grove using the NDRE vegetation index obtained from UAV images. *European Journal of Remote Sensing*, 52(1), 169-177.
- Kanke, Y., Tubaña, B., Dalen, M. ve Harrell, D. 2016. Evaluation of red and red-edge reflectance-based vegetation indices for rice biomass and grain yield prediction models in paddy fields. *Precision Agriculture*, 17(5), 507-530.
- Kayad, A. G., Al-Gaadi, K. A., Tola, E., Madugundu, R., Zeyada, A. M. ve Kalaitzidis, C. 2016. Assessing the Spatial Variability of Alfalfa Yield Using Satellite Imagery and Ground-Based Data. *PLoS One*, 11(6), e0157166.
- Leprieur, C., Verstraete, M. M., Pinty, B. ve Pinty, B. 1994. Evaluation of the performance of various vegetation indices to retrieve vegetation cover from AVHRR data. *Remote Sensing Reviews*, 10(4), 265-284.
- Li, Cheng, T., Zhou, K., Zheng, H., Yao, X., Tian, Y., Zhu, Y. ve Cao, W. 2017. WREP: A wavelet-based technique for extracting the red edge position from reflectance spectra for estimating leaf and canopy chlorophyll contents of cereal crops. *ISPRS Journal of Photogrammetry and Remote Sensing*, 129, 103-117.
- Li, Mistele, B., Hu, Y., Chen, X. ve Schmidhalter, U. 2014. Reflectance estimation of canopy nitrogen content in winter wheat using optimised hyperspectral spectral

- indices and partial least squares regression. *European Journal of Agronomy*, 52, 198-209.
- Li, Wang, R., Zhang, M., Wang, X., Yan, Y., Sun, X. ve Xu, D. 2023. A Method for Estimating Alfalfa (*Medicago sativa* L.) Forage Yield Based on Remote Sensing Data. *Agronomy*, 13(10).
- Li, F., Miao, Y., Feng, G., Yuan, F., Yue, S., Gao, X., Liu, Y., Liu, B., Ustin, S. L. ve Chen, X. 2014. Improving estimation of summer maize nitrogen status with red edge-based spectral vegetation indices. *Field Crops Research*, 157, 111-123.
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S. ve Bochtis, D. 2018. Machine learning in agriculture: A review. *Sensors*, 18(8), 2674.
- Liu, H. Q. ve Huete, A. 1995. A feedback based modification of the NDVI to minimize canopy background and atmospheric noise. *IEEE Transactions on Geoscience and Remote Sensing*, 33(2), 457-465.
- Liu, H. Q. ve Mason, P. J. 2013. *Essential image processing and GIS for remote sensing*. John Wiley & Sons.
- Loudjani, P. 2014. Precision Agriculture: An Opportunity for EU-Farmers–Potential Support with the CAP 2014-2020.
- Maas, S. J., Vanderbilt, V. C., Barnes, E. M., Miller, S. N. ve Clarke, T. R. 2004. Application of image-based remote sensing to irrigated agriculture. In: *Remote Sensing for Natural Resources Management and Environmental Monitoring: Manual of Remote Sensing*; Susan, U., Ed. 617-676.
- Maccioni, A., Agati, G., Mazzinghi, P. ve Mazzinghi, P. 2001. New vegetation indices for remote measurement of chlorophylls based on leaf directional reflectance spectra. *Journal of Photochemistry and Photobiology B: Biology*, 61(1-2), 52-61.
- Marino, S., Aria, M., Basso, B., Leone, A. ve Alvino, A. 2014. Use of soil and vegetation spectroradiometry to investigate crop water use efficiency of a drip irrigated tomato. *European Journal of Agronomy*, 59, 67-77.
- Marino, S., Basso, B., Leone, A. ve Alvino, A. 2013. Agronomic traits and vegetation indices of two onion hybrids. *Scientia Horticulturae*, 155, 56-64.
- Marshall, M. ve Thenkabail, P. 2015. Developing in situ non-destructive estimates of crop biomass to address issues of scale in remote sensing. *Remote Sensing*, 7(1), 808-835.
- McBratney, A., Whelan, B., Ancev, T. ve Bouma, J. 2005. Future directions of precision agriculture. *Precision Agriculture*, 6, 7-23.

- Motohka, T., Nasahara, K. N., Oguma, H. ve Tsuchida, S. 2010. Applicability of green-red vegetation index for remote sensing of vegetation phenology. *Remote Sensing*, 2(10), 2369-2387.
- Moulin, S. 1999. Impacts of model parameter uncertainties on crop reflectance estimates: a regional case study on wheat. *International Journal of Remote Sensing*, 20(1), 213-218.
- Moyo, S., Swanepoel, F., Stroebel, A. ve Stroebel, A. 2010. The role of livestock in developing communities: Enhancing multifunctionality. UJ Press.
- Mutanga, O. ve Skidmore, A. K. 2004. Narrow band vegetation indices overcome the saturation problem in biomass estimation. *International Journal of Remote Sensing*, 25(19), 3999-4014.
- Myneni, R. B., Hall, F. G., Sellers, P. J. ve Marshak, A. L. 1995. The interpretation of spectral vegetation indexes. *IEEE Transactions on Geoscience and Remote Sensing*, 33(2), 481-486.
- Noland, R. L., Wells, M. S., Coulter, J. A., Tiede, T., Baker, J. M., Martinson, K. L. ve Sheaffer, C. C. 2018. Estimating alfalfa yield and nutritive value using remote sensing and air temperature. *Field Crops Research*, 222, 189-196.
- Ollinger, S. V. 2011. Sources of variability in canopy reflectance and the convergent properties of plants. *New Phytologist*, 189(2), 375-394.
- Peñuelas, J., Filella, I., Gamon, J. A. ve Gamon, J. A. 1995. Assessment of photosynthetic radiation-use efficiency with spectral reflectance. *New Phytologist*, 131(3), 291-296.
- Piekkielek, W. ve Fox, R. 1992. Use of a chlorophyll meter to predict sidedress nitrogen requirements for maize. *Agronomy journal*, 84(1), 59-65.
- Pilon, R., Klumpp, K., Carrère, P. ve Picon-Cochard, C. 2010. Determination of aboveground net primary productivity and plant traits in grasslands with near-infrared reflectance spectroscopy. *Ecosystems*, 13(6), 851-859.
- Pinter Jr, P. J., Hatfield, J. L., Schepers, J. S., Barnes, E. M., Moran, M. S., Daughtry, C. S. ve Upchurch, D. R. 2003. Remote sensing for crop management. *Photogrammetric Engineering & Remote Sensing*, 69(6), 647-664.
- Poudyal, C., Sandhu, H., Ampatzidis, Y., Odero, D. C., Arbelo, O. C., Cherry, R. H. ve Costa, L. F. 2023. Prediction of morpho-physiological traits in sugarcane using aerial imagery and machine learning. *Smart Agricultural Technology*, 3, 100104.
- Prestes, C. D. P., Guimarães, A. M., Zampier, D. P., Gabardo, G., Caires, E. F. ve Asato, B. R. 2020. Avaliação de metodologia de estimativa de produtividade de soja por meio de aeronave não tripulada e técnica de aprendizado de máquina baseada em

- regressão. *Revista Mundi Engenharia, Tecnologia e Gestão* (ISSN: 2525-4782), 5(3).
- Prudnikova, E., Savin, I., Vindeker, G., Grubina, P., Shishkonakova, E. ve Sharychev, D. 2019. Influence of soil background on spectral reflectance of winter wheat crop canopy. *Remote Sensing*, 11(16), 1932.
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H. ve Sorooshian, S. 1994. A modified soil adjusted vegetation index. *Remote sensing of environment*, 48(2), 119-126.
- Quan, Z., Xianfeng, Z., Miao, J. ve Miao, J. 2011. Eco-environment variable estimation from remote sensed data and eco-environment assessment: models and system. *Acta Botanica Sinica*, 47, 1073-1080.
- Radović, J., Sokolović, D., Marković, J. ve Radović, J. 2009. Alfalfa-most important perennial forage legume in animal husbandry. *Biotechnology in Animal Husbandry*, 25(5-6-1), 465-475.
- Richardson, A. J. ve Wiegand, C. 1977. Distinguishing vegetation from soil background information. *Photogrammetric engineering and remote sensing*, 43(12), 1541-1552.
- Roman, A. ve Ursu, T. 2016. Multispectral satellite imagery and airborne laser scanning techniques for the detection of archaeological vegetation marks. 141-152.
- Rondeaux, G., Steven, M., Baret, F. ve Baret, F. 1996. Optimization of soil-adjusted vegetation indices. *Remote sensing of environment*, 55(2), 95-107.
- Roujean, J.-L. ve Breon, F.-M. 1995. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote sensing of environment*, 51(3), 375-384.
- Rouse, J. W., Haas, R. H., Schell, J. A. ve Deering, D. W. 1974. Monitoring vegetation systems in the Great Plains with ERTS. *NASA Spec. Publ*, 351(1), 309.
- Safari, H., Fricke, T., Reddersen, B., Möckel, T. ve Wachendorf, M. 2016. Comparing mobile and static assessment of biomass in heterogeneous grassland with a multi-sensor system. *Journal of Sensors and Sensor Systems*, 5(2), 301-312.
- Salisbury, J. ve Milton, N. 1988. Thermal infrared (2.5-to 13.5- μm) directional hemispherical reflectance of leaves.
- Sanches, G. M., Duft, D. G., Kölln, O. T., Luciano, A. C. d. S., De Castro, S. G. Q., Okuno, F. M. ve Franco, H. C. J. 2018. The potential for RGB images obtained using unmanned aerial vehicle to assess and predict yield in sugarcane fields. *International Journal of Remote Sensing*, 39(15-16), 5402-5414.

- Sanjerehei, M. M. 2014. Assessment of spectral vegetation indices for estimating vegetation cover in arid and semiarid shrublands. *Range Management and Agroforestry*, 35(1), 91-100.
- Santos, M. P., Heinemann, A. B., Stone, L. F., da Matta, D. H., de Castro, J. R. ve dos Santos, A. B. 2021. Nitrogen determination in irrigated rice using spectral reflectance. *Agronomy journal*, 113(6), 5087-5101.
- Sapkota, A., Haghverdi, A., Montazar, A. ve Montazar, A. 2023. Estimating fall-harvested alfalfa (*Medicago sativa* L.) yield using unmanned aerial vehicle–based multispectral and thermal images in southern California. *Agrosystems, Geosciences & Environment*, 6(2).
- Sasidhar, T. T., Sreelakshmi, K., Vyshnav, M., Sowmya, V. ve Soman, K. 2019. Land cover satellite image classification using ndvi and simplecnn, 2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT), IEEE, 1-5.
- Schirrmann, M., Giebel, A., Gleiniger, F., Pflanz, M., Lentschke, J. ve Dammer, K.-H. 2016. Monitoring agronomic parameters of winter wheat crops with low-cost UAV imagery. *Remote Sensing*, 8(9), 706.
- Sellers, P. J. 1985. Canopy reflectance, photosynthesis and transpiration. *International Journal of Remote Sensing*, 6(8), 1335-1372.
- Shi, Nan, L., Smith, K. F. ve Smith, K. F. 2017. The current status, problems, and prospects of alfalfa (*Medicago sativa* L.) breeding in China. *Agronomy*, 7(1), 1.
- Shi, Wang, Y., Li, Z., Huang, X., Shen, T. ve Zou, X. 2021. Simultaneous and nondestructive diagnostics of nitrogen/magnesium/potassium-deficient cucumber leaf based on chlorophyll density distribution features. *Biosystems Engineering*, 212, 458-467.
- Sims, D. A. ve Gamon, J. A. 2002. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote sensing of environment*, 81(2-3), 337-354.
- Singh, A., Serbin, S. P., McNeil, B. E., Kingdon, C. C. ve Townsend, P. A. 2015. Imaging spectroscopy algorithms for mapping canopy foliar chemical and morphological traits and their uncertainties. *Ecological Applications*, 25(8), 2180-2197.
- Sleugh, B., Moore, K. J., George, J. R. ve Brummer, E. C. 2000. Binary legume–grass mixtures improve forage yield, quality, and seasonal distribution. *Agronomy journal*, 92(1), 24-29.
- Soubry, I., Patias, P., Tsioukas, V. ve Tsioukas, V. 2017. Monitoring vineyards with UAV and multi-sensors for the assessment of water stress and grape maturity. *Journal of Unmanned Vehicle Systems*, 5(2), 37-50.

- Szypuła, B. 2024. Accuracy of UAV-based DEMs without ground control points. *GeoInformatica*, 28(1), 1-28.
- Tang, Z., Parajuli, A., Chen, C. J., Hu, Y., Revolinski, S., Medina, C. A., Lin, S., Zhang, Z. ve Yu, L. X. 2021. Validation of UAV-based alfalfa biomass predictability using photogrammetry with fully automatic plot segmentation. *Sci Rep*, 11(1), 3336.
- Tedesco, D., Nieto, L., Hernández, C., Rybecky, J. F., Min, D., Sharda, A., Hamilton, K. J. ve Ciampitti, I. A. 2022. Remote Sensing on Alfalfa as an Approach to Optimize Production Outcomes: A Review of Evidence and Directions for Future Assessments. *Remote Sensing*, 14(19).
- Trotter, T. F., Frazier, P., Trotter, M. G. ve Lamb, D. W. 2008. Objective biomass assessment using an active plant sensor (Crop Circle), preliminary experiences on a variety of agricultural landscapes, 9th International Conference on Precision Agriculture. Colorado State University, Fort Collins, Colorado.
- Tucker, C. J. 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of environment*, 8(2), 127-150.
- Undersander, D., Vassalotti, P., Cosgrove, D. ve Cosgrove, D. 1997. Alfalfa germination & growth. (Vol. 3681). University of Wisconsin--Extension, Cooperative Extension.
- Vescovo, L., Wohlfahrt, G., Balzarolo, M., Pilloni, S., Sottocornola, M., Rodeghiero, M. ve Gianelle, D. 2012. New spectral vegetation indices based on the near-infrared shoulder wavelengths for remote detection of grassland phytomass. *International Journal of Remote Sensing*, 33(7), 2178-2195.
- Wang, Huang, J.-f., Tang, Y.-l. ve Wang, X.-z. 2007. New vegetation index and its application in estimating leaf area index of rice. *Rice Science*, 14(3), 195-203.
- Wang, Singh, K., Poudel, H., Ravichandran, P., Natarajan, M. ve Eisenreich, B. 2023. Estimation of Crop Height and Digital Biomass from UAV-Based Multispectral Imagery, 2023 13th Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing (WHISPERS), IEEE, 1-4.
- Wang, S., Guo, K., Ameen, A., Fang, D., Li, X., Liu, X. ve Han, L. 2022. Evaluation of different shallow groundwater tables and alfalfa cultivars for forage yield and nutritional value in coastal saline soil of north China. *Life*, 12(2), 217.
- Wijesingha, J., Astor, T., Schulze-Brüninghoff, D., Wengert, M. ve Wachendorf, M. 2020. Predicting forage quality of grasslands using UAV-borne imaging spectroscopy. *Remote Sensing*, 12(1), 126.

- Wu, C., Niu, Z., Tang, Q. ve Huang, W. 2008. Estimating chlorophyll content from hyperspectral vegetation indices: Modeling and validation. *Agricultural and forest meteorology*, 148(8-9), 1230-1241.
- Xie, Dash, J., Huang, W., Peng, D., Qin, Q., Mortimer, H., Casa, R., Pignatti, S., Laneve, G. ve Pascucci, S. 2018. Vegetation indices combining the red and red-edge spectral information for leaf area index retrieval. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(5), 1482-1493.
- Xie, Q., Dash, J., Huang, W., Peng, D., Qin, Q., Mortimer, H., Casa, R., Pignatti, S., Laneve, G., Pascucci, S., Ye, H. 2018. Vegetation Indices Combining the Red and Red-Edge Spectral Information for Leaf Area Index Retrieval. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(5), 1482-1493.
- Xue, J. ve Su, B. 2017. Significant remote sensing vegetation indices: A review of developments and applications. *Journal of sensors*, 2017(1), 1353691.
- Yavuz, M. 2005. Bazı ruminant yemlerinin nispi yem değeri ve in vitro sindirim değerlerinin belirlenmesi. *Journal of Agricultural Faculty of Gaziosmanpaşa University (JAFAG)*, 2005(1).
- Yegül, U. (2016). Azot sensörü kullanarak bitki yansıma indeksi ile buğdayın verim ve kalite parametrelerinin modellenmesi. *Doktora Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü*.
- Yuan, H., Yang, G., Li, C., Wang, Y., Liu, J., Yu, H., Feng, H., Xu, B., Zhao, X. ve Yang, X. 2017. Retrieving soybean leaf area index from unmanned aerial vehicle hyperspectral remote sensing: Analysis of RF, ANN, and SVM regression models. *Remote Sensing*, 9(4), 309.
- Zhang, Liao, Q., Huang, L., Zhao, J., Du, S. ve Ma, Z. 2011. Studying on red edge characteristics of maize leaf using visible/near-infrared imaging hyperspectra, *International Symposium on Photoelectronic Detection and Imaging 2011: Advances in Imaging Detectors and Applications, SPIE*, 8194, 884-891.
- Zhang, Wang, X., Ma, W. ve Zhao, C. 2012. Research vertical distribution of chlorophyll content of wheat leaves using imaging hyperspectra. *Intelligent Automation & Soft Computing*, 18(8), 1111-1120.
- Zhang, Zhang, F., Yuan, Z.-Q. ve Li, F.-M. 2024. Alfalfa-livestock system promotes the accumulation of soil organic carbon in a semi-arid marginal land. *Agriculture, Ecosystems & Environment*, 375, 109200.
- Zhang, F., Sun, T., Li, Z., Peng, Y., Sheng, T., Du, M. ve Wu, Q. 2023. Alfalfa stand age at termination influences soil properties, root characteristics, and subsequent maize yield. *European Journal of Agronomy*, 148, 126879.

- Zhao, Ma, F., Yu, H. ve Li, Z. 2023. Inversion Model of Salt Content in Alfalfa-Covered Soil Based on a Combination of UAV Spectral and Texture Information. *Agriculture*, 13(8).
- Zhao, D., Reddy, K. R., Kakani, V. G. ve Reddy, V. 2005. Nitrogen deficiency effects on plant growth, leaf photosynthesis, and hyperspectral reflectance properties of sorghum. *European Journal of Agronomy*, 22(4), 391-403.

EKLER

EK 1 Deęirmenkaşı Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları

EK 2 Deęirmenkaşı Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları

EK 3 İshocalı Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları

EK 4 İshocalı Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları

EK 5 Karahıdır Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları

EK 6 Karahıdır Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları

EK 7 Terziali Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları

EK 8 Terziali Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları

EK 9 Malya (TİGEM) Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları

EK 10 Malya (TİGEM) Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları

EK 11 Deęirmenkaşı lokasyonu modifiye bitki indeks haritaları

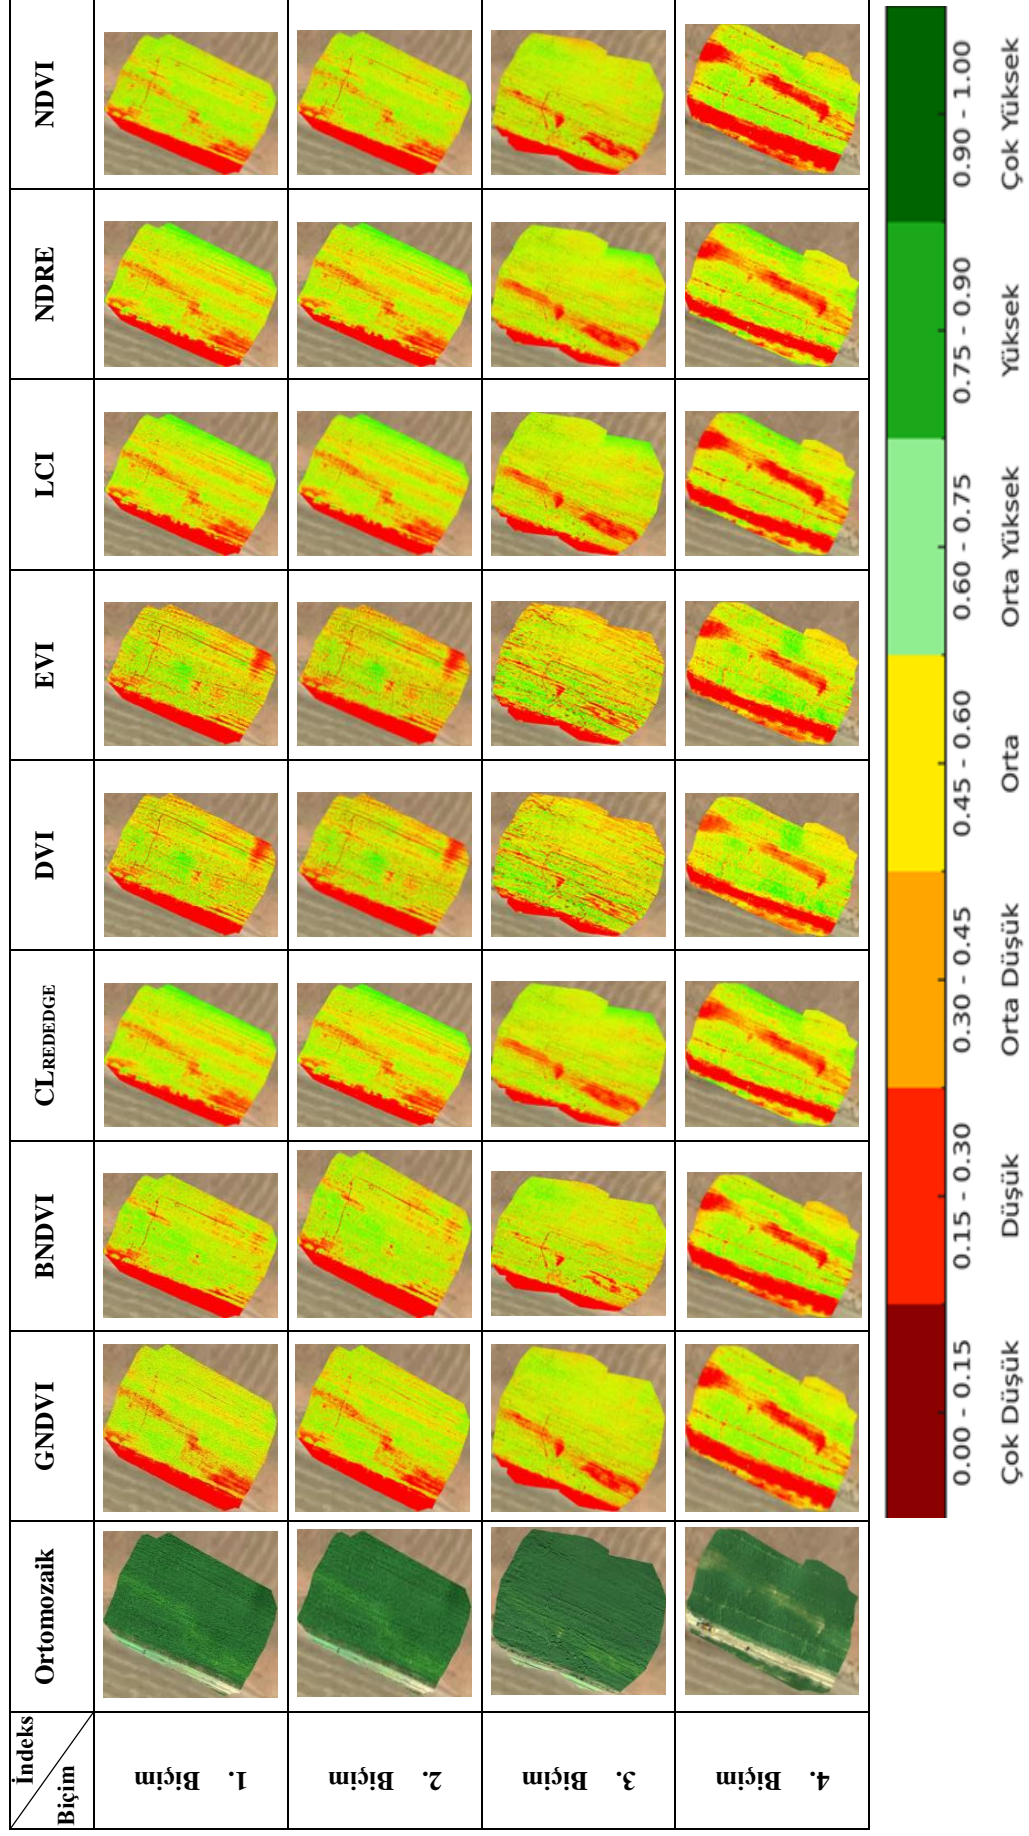
EK 12 İshocalı lokasyonu modifiye bitki indeks haritaları

EK 13 Karahıdır lokasyonu modifiye bitki indeks haritaları

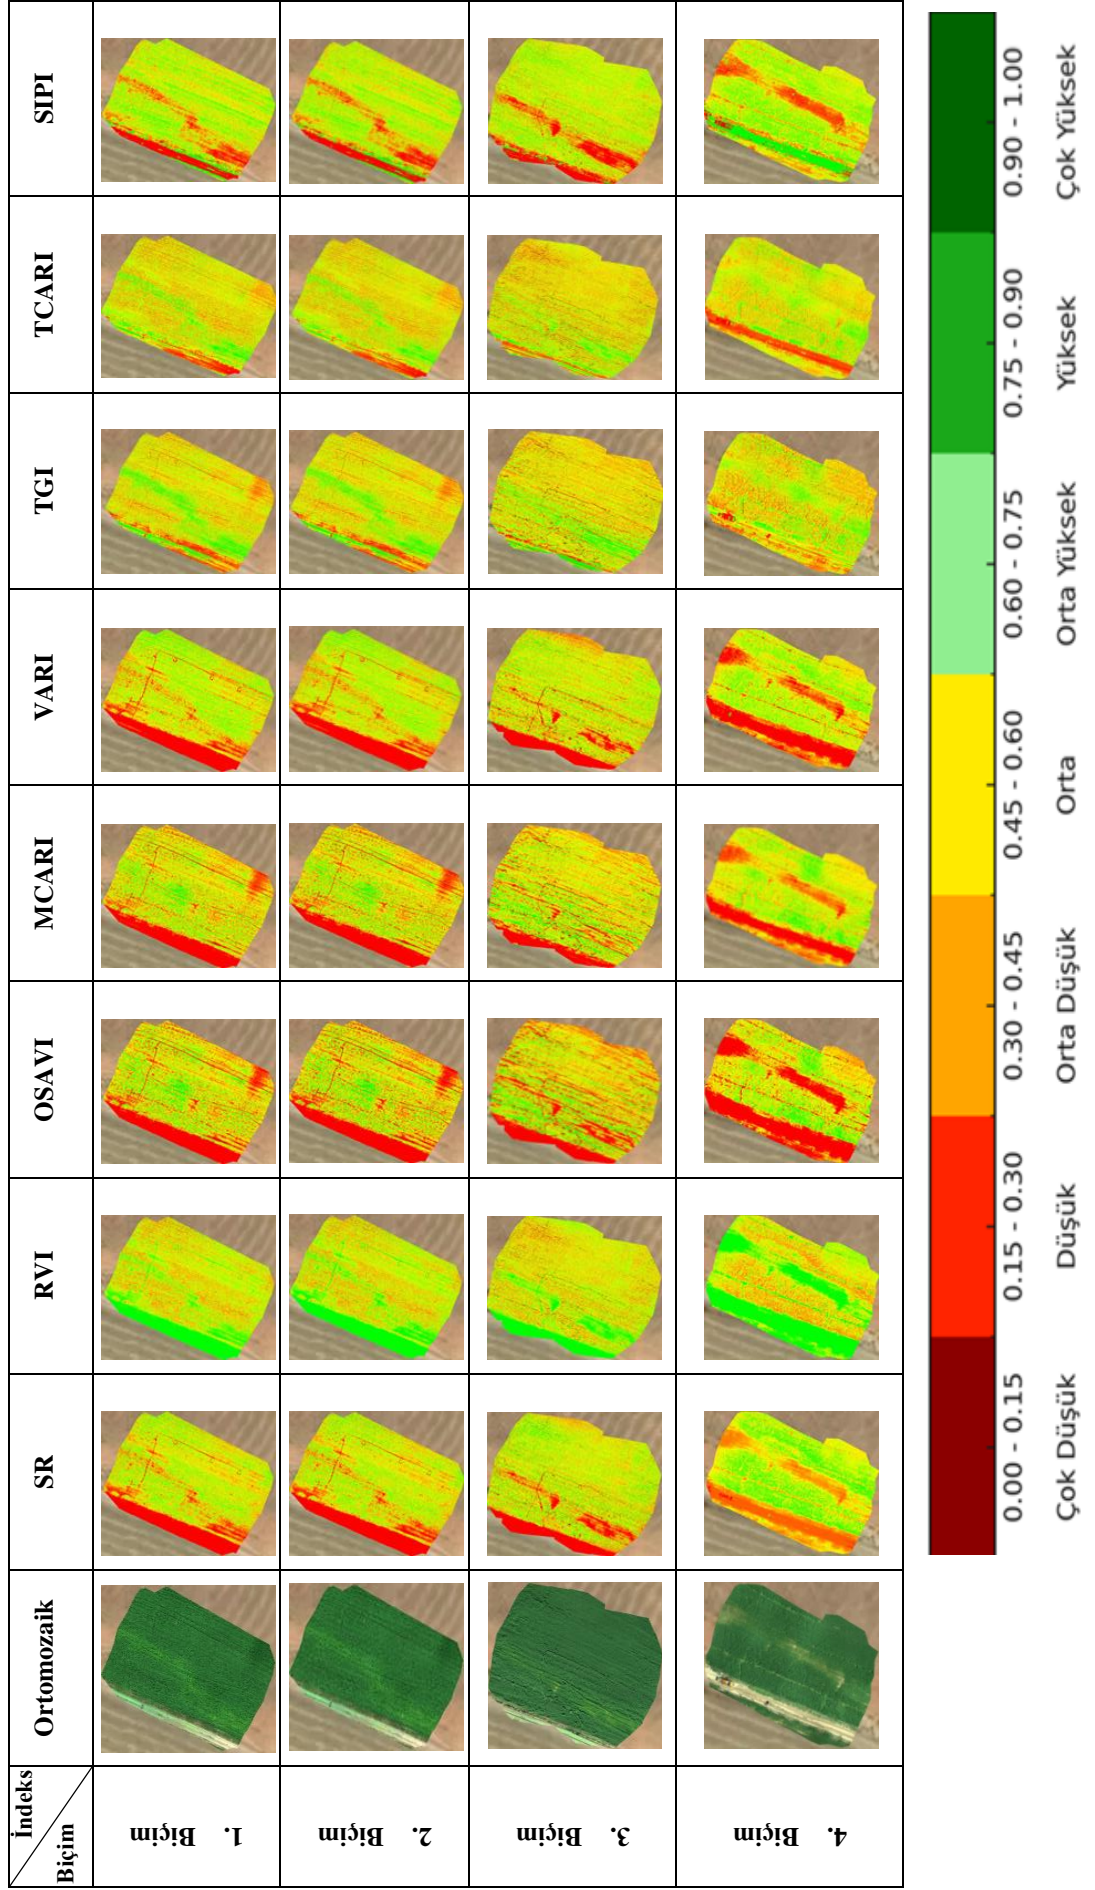
EK 14 Terziali lokasyonu modifiye bitki indeks haritaları

EK 15 MALYA (TİGEM) lokasyonu modifiye bitki indeks haritaları

EK 1 Değirmenkaşı Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları




EK 2 Değirmenkaşı Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları

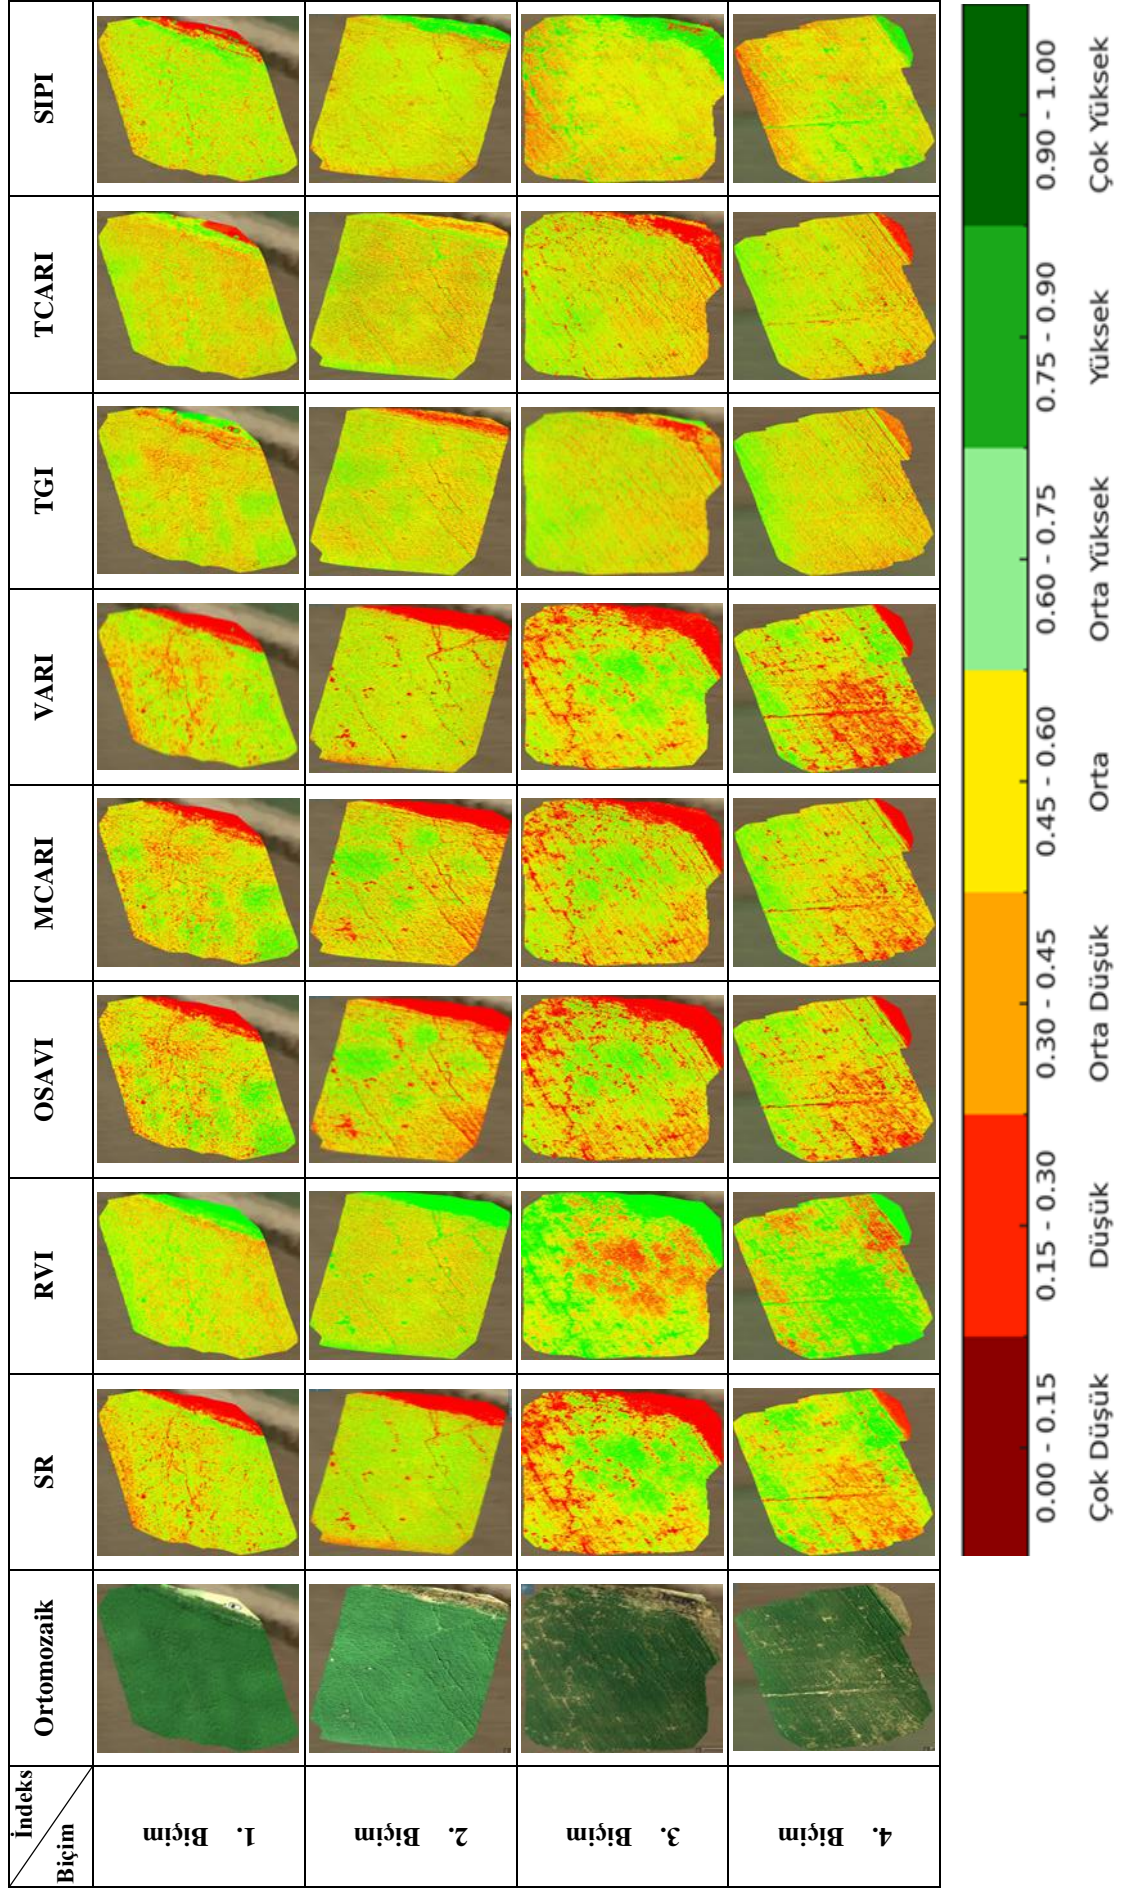


EK 3 İshacalı Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları

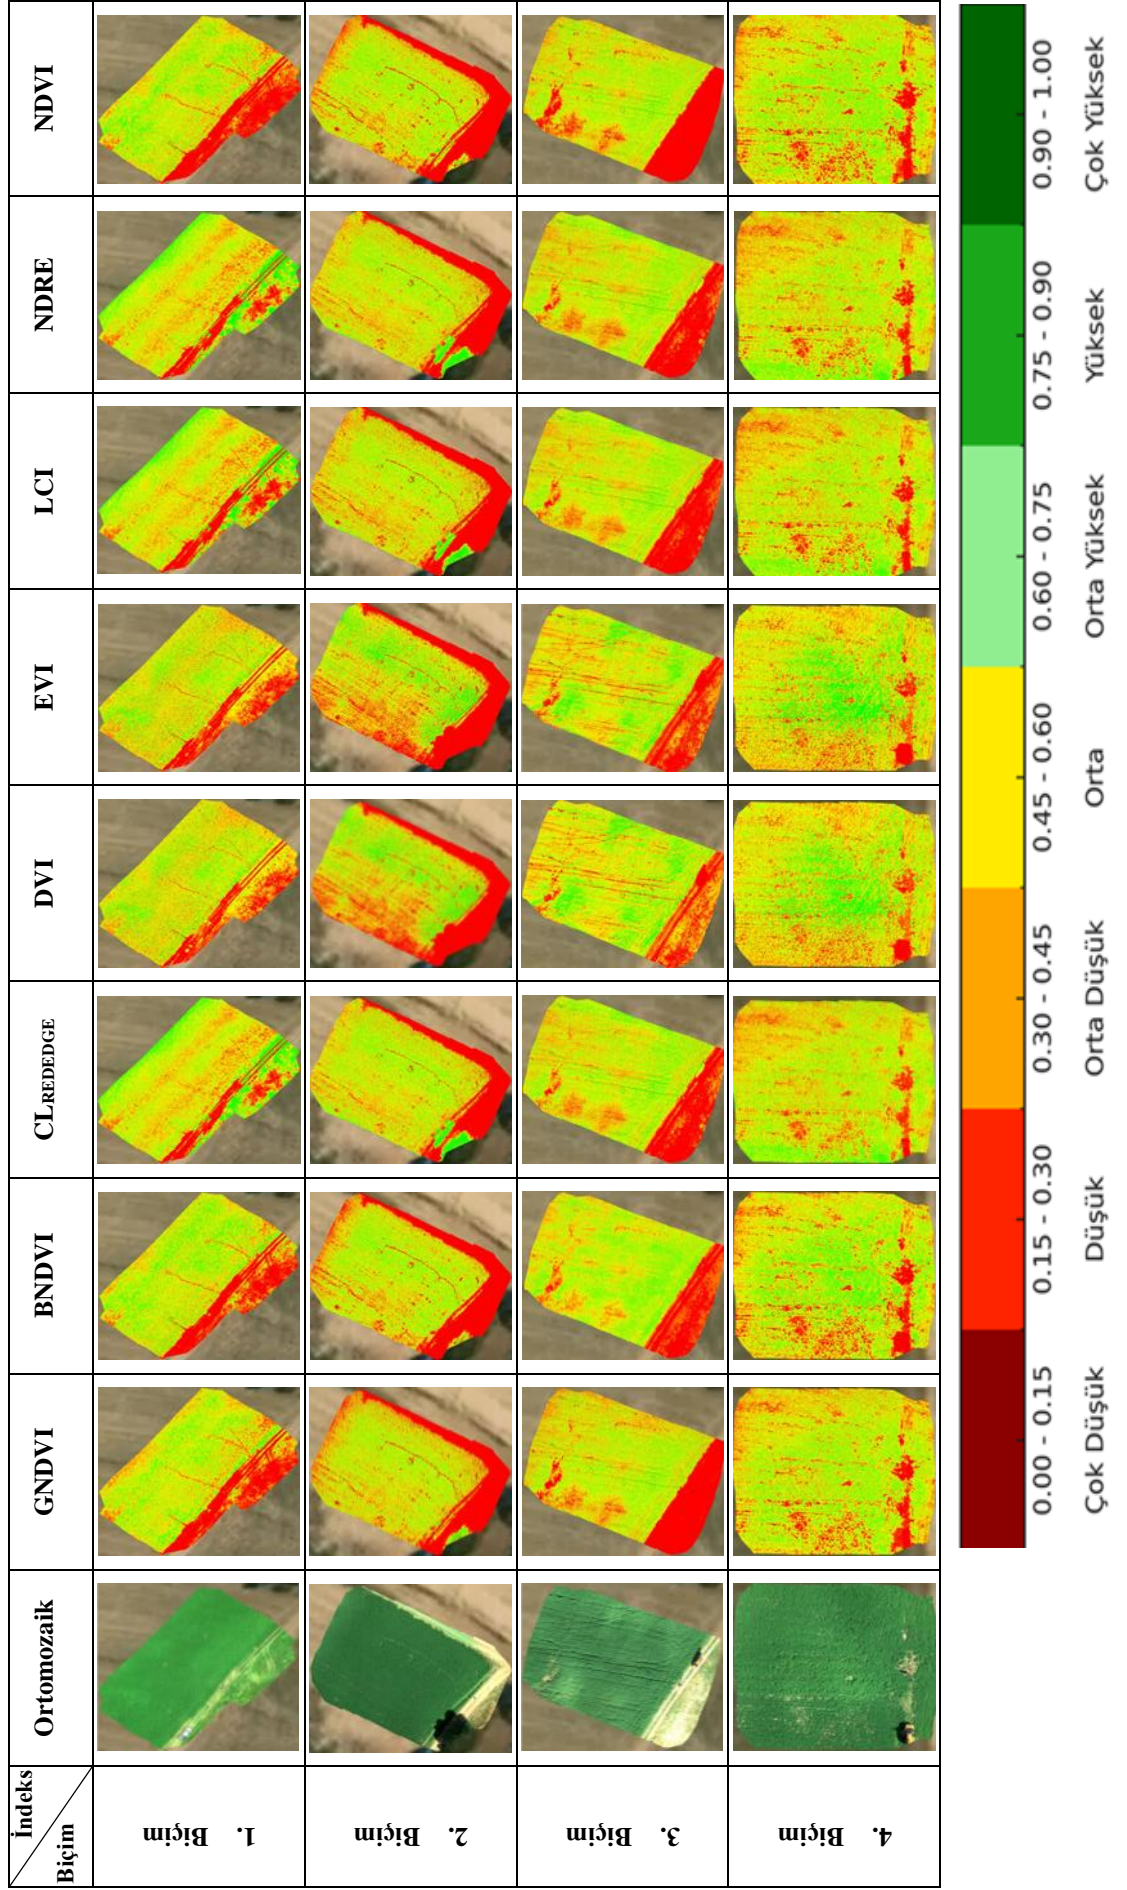
İndeks Biçim	Ortomozaik	GNDVI	BNDVI	CL _{REDEGE}	DVI	EVI	LCI	NDRE	NDVI
1. Biçim									
2. Biçim									
3. Biçim									
4. Biçim									



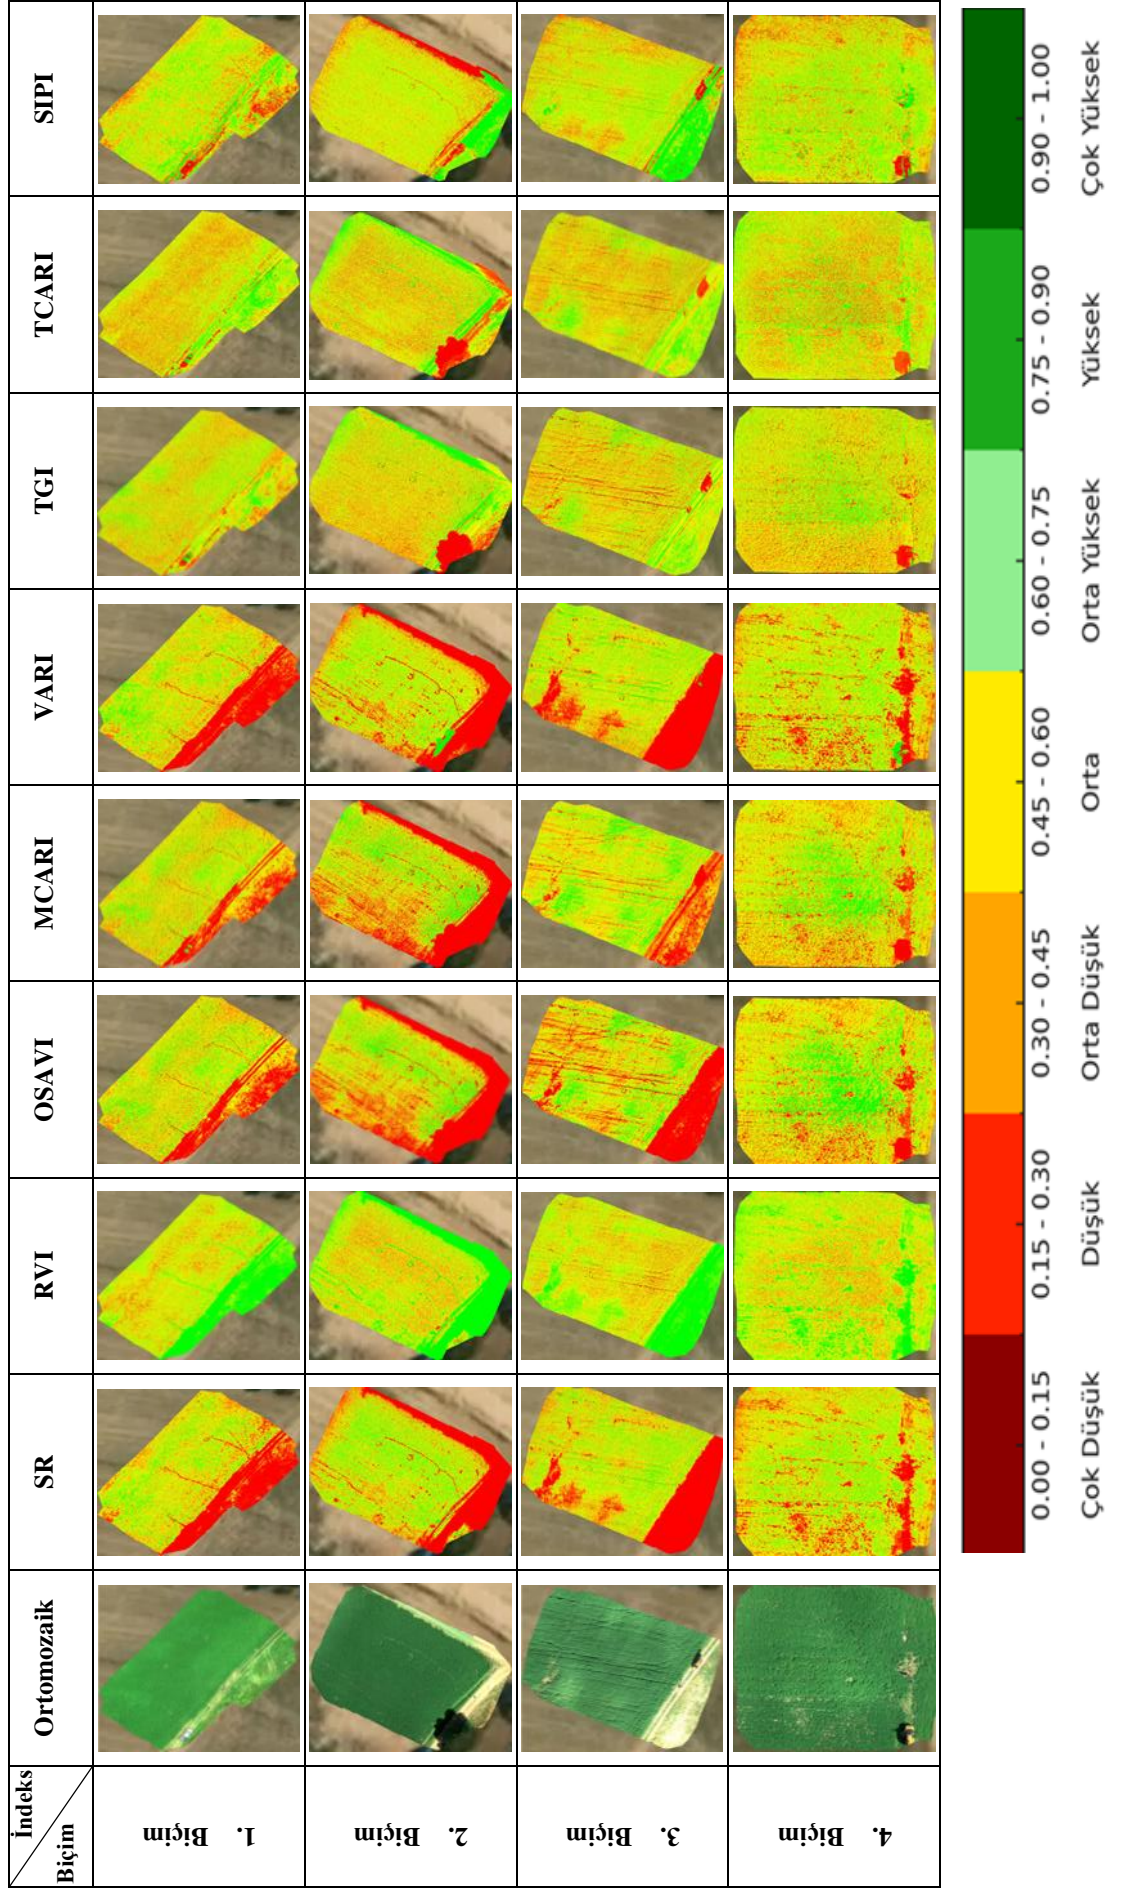
EK 4 İshahocah Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları



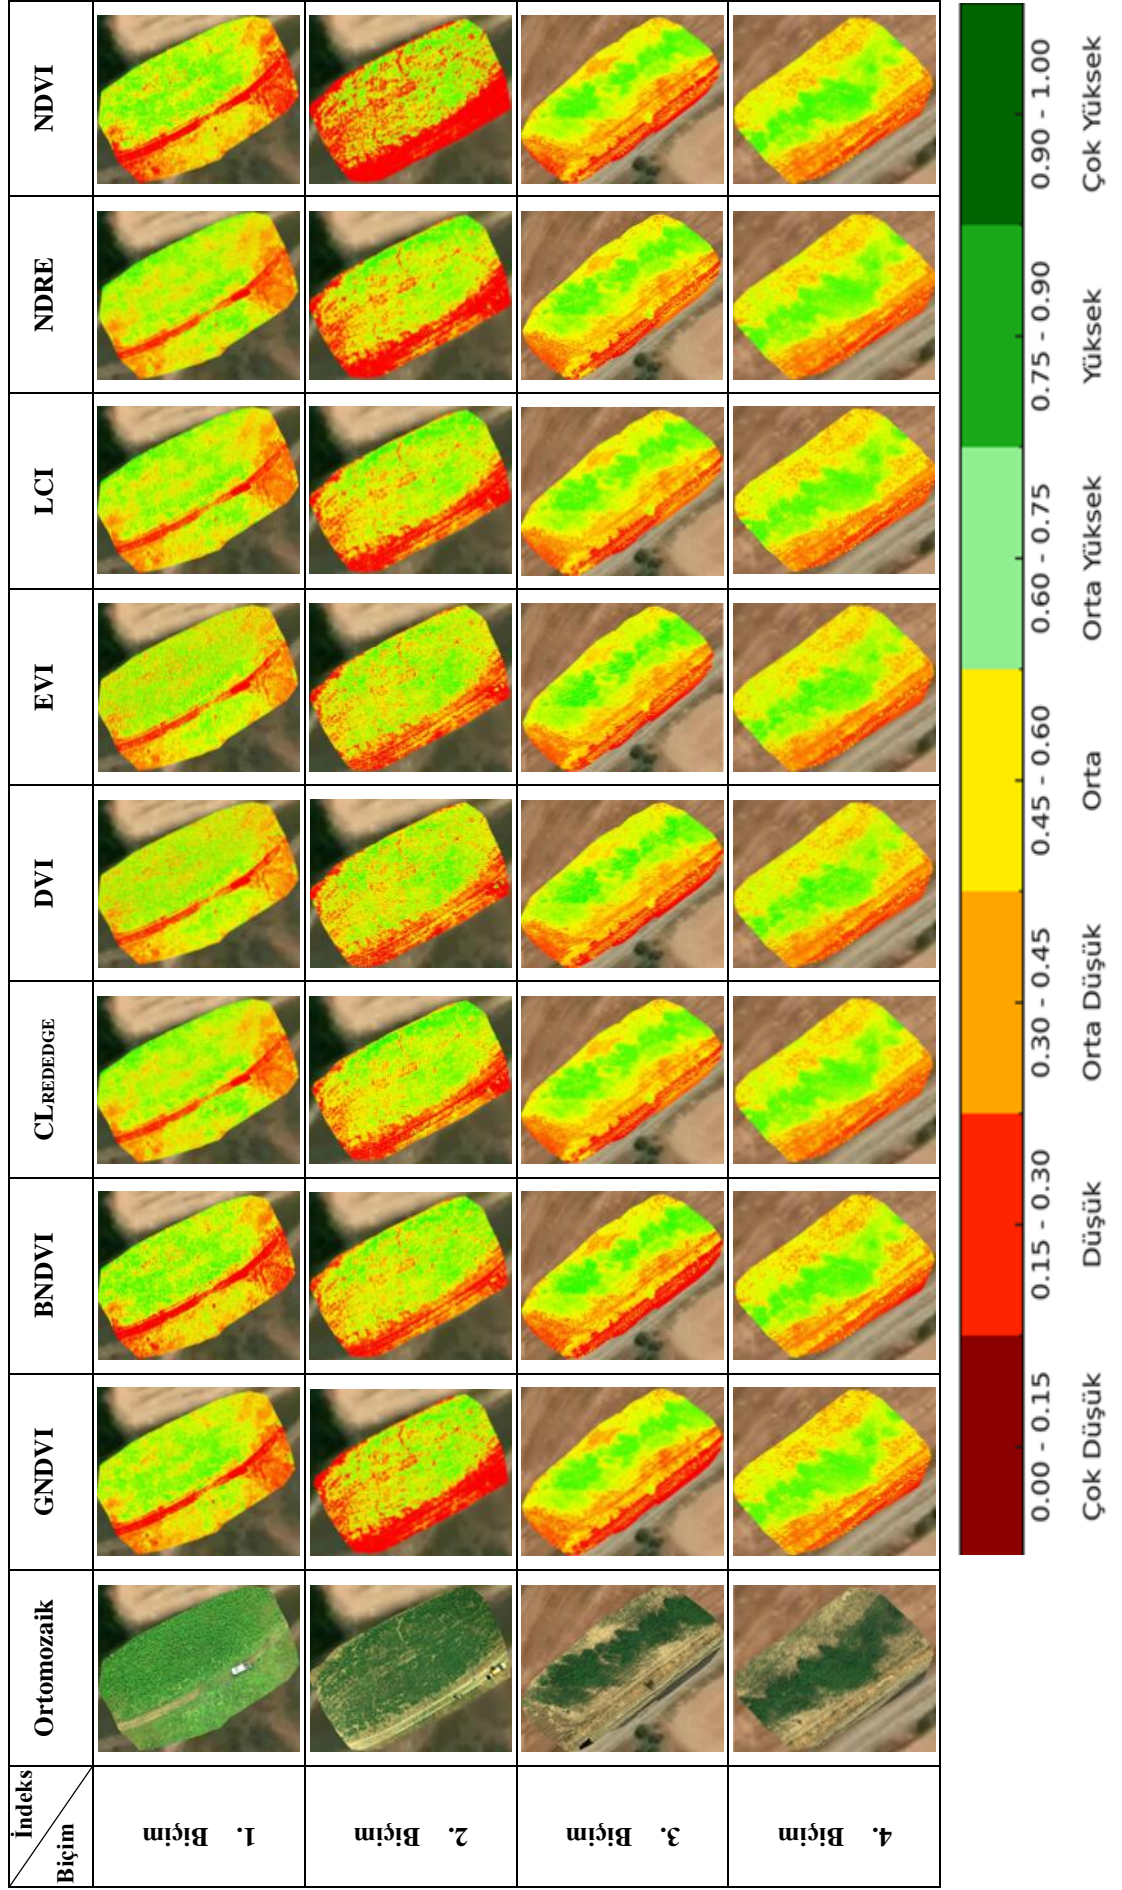
EK 5 Karahdır Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları



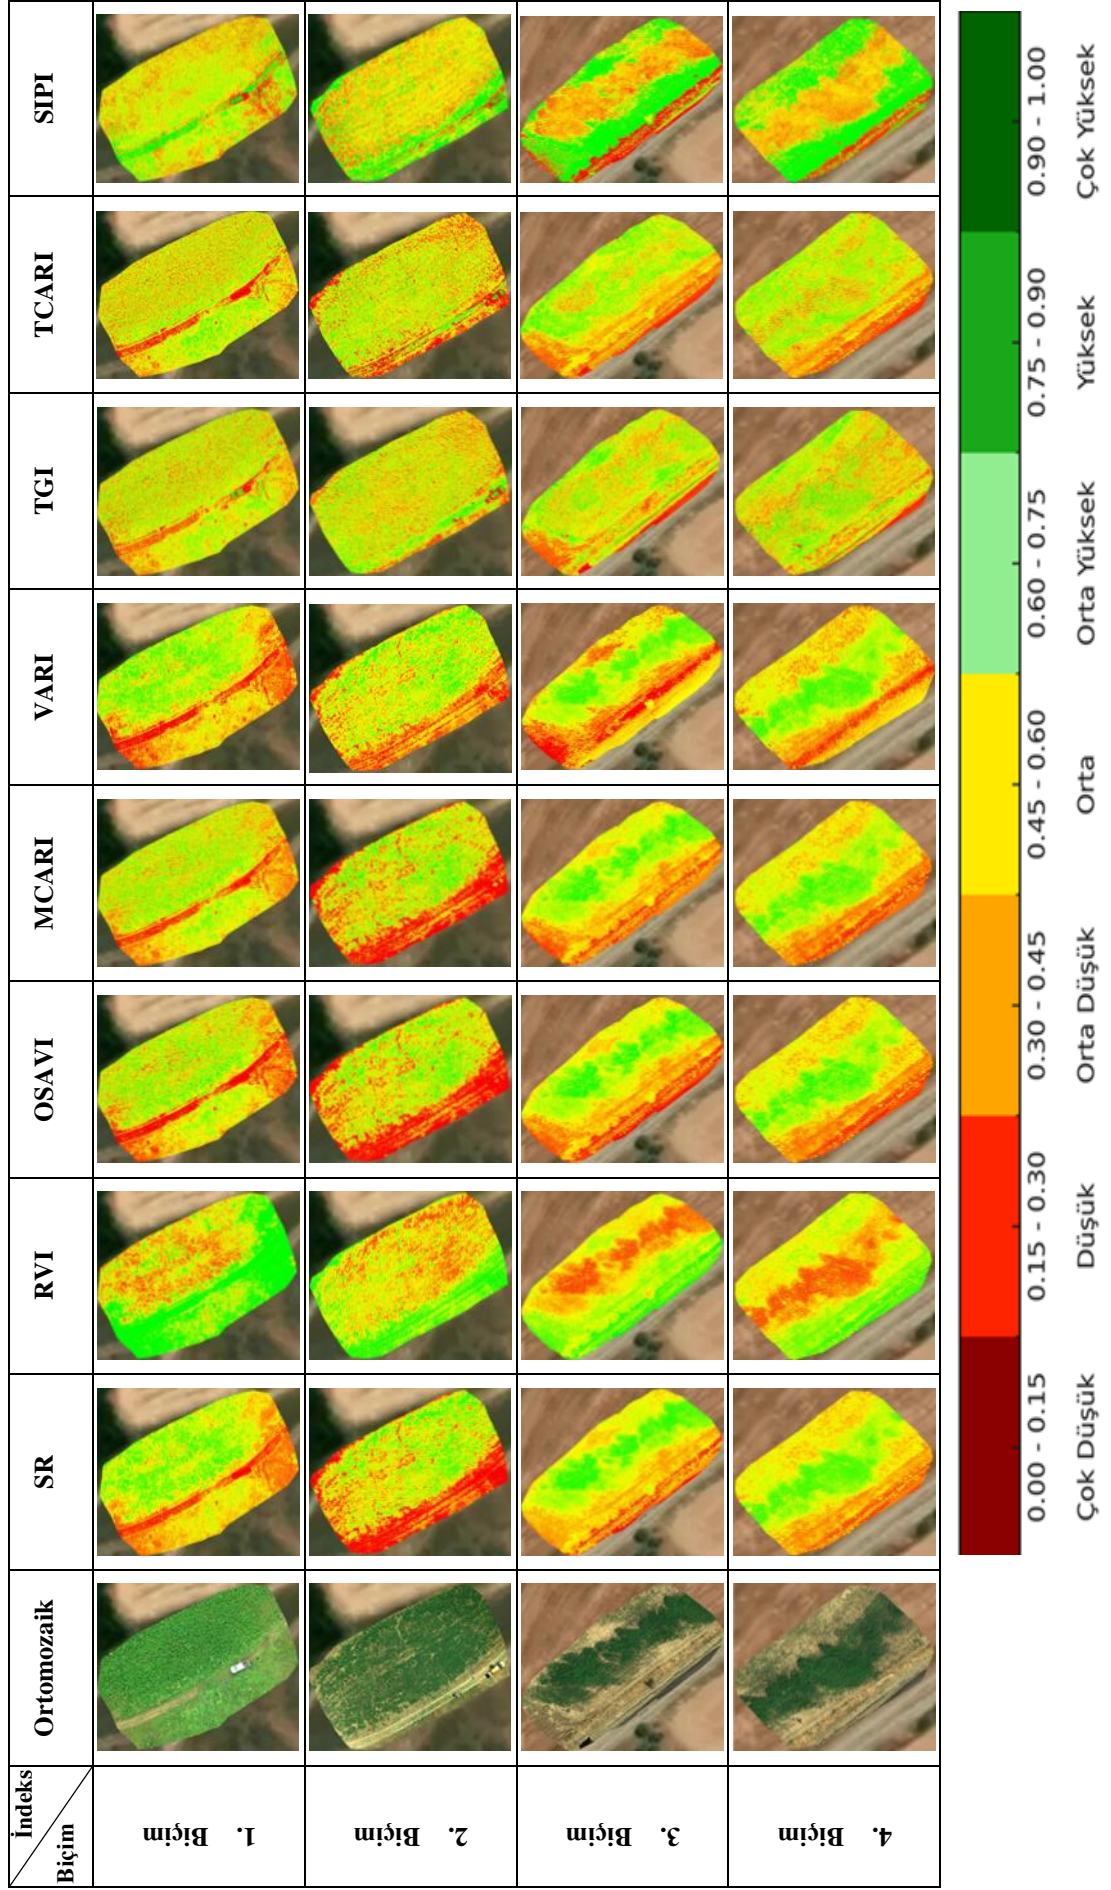
EK 6 Karahdır Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları



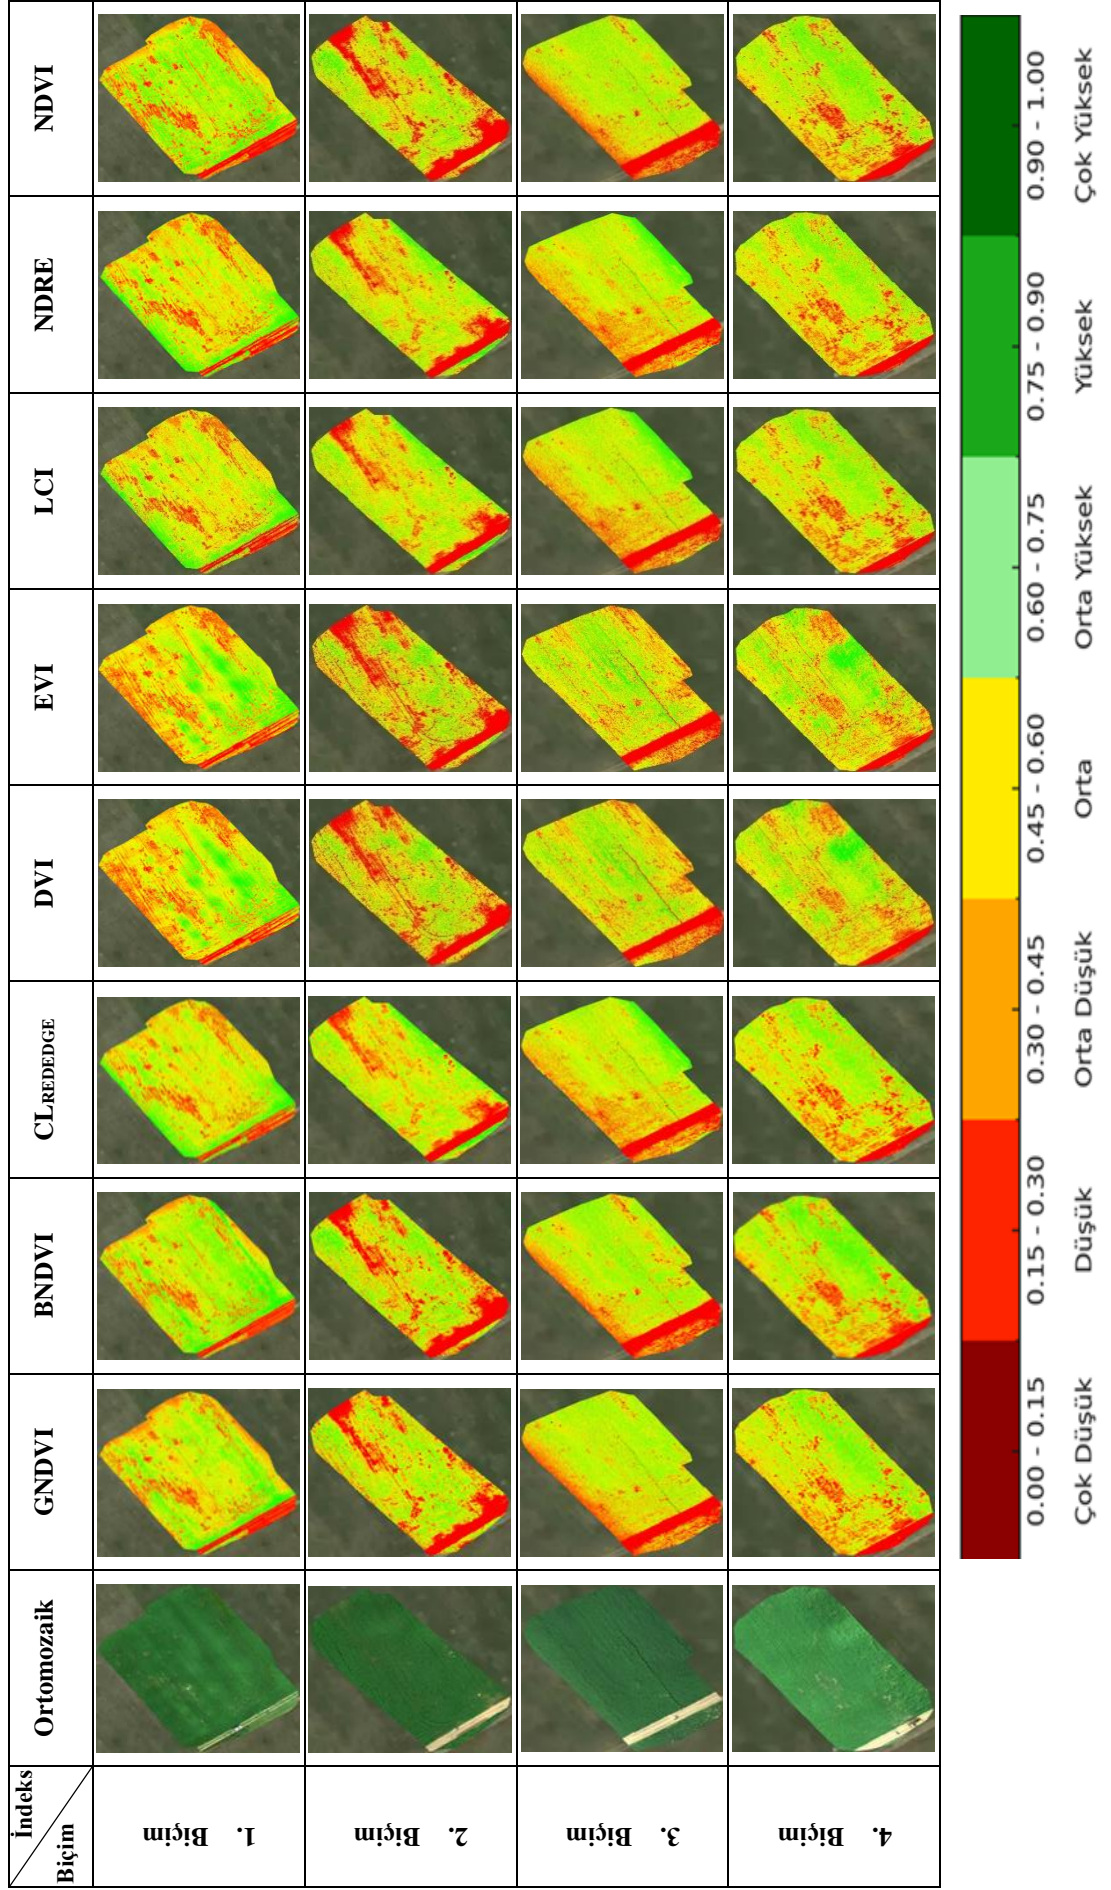
EK 7 Terziali Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları



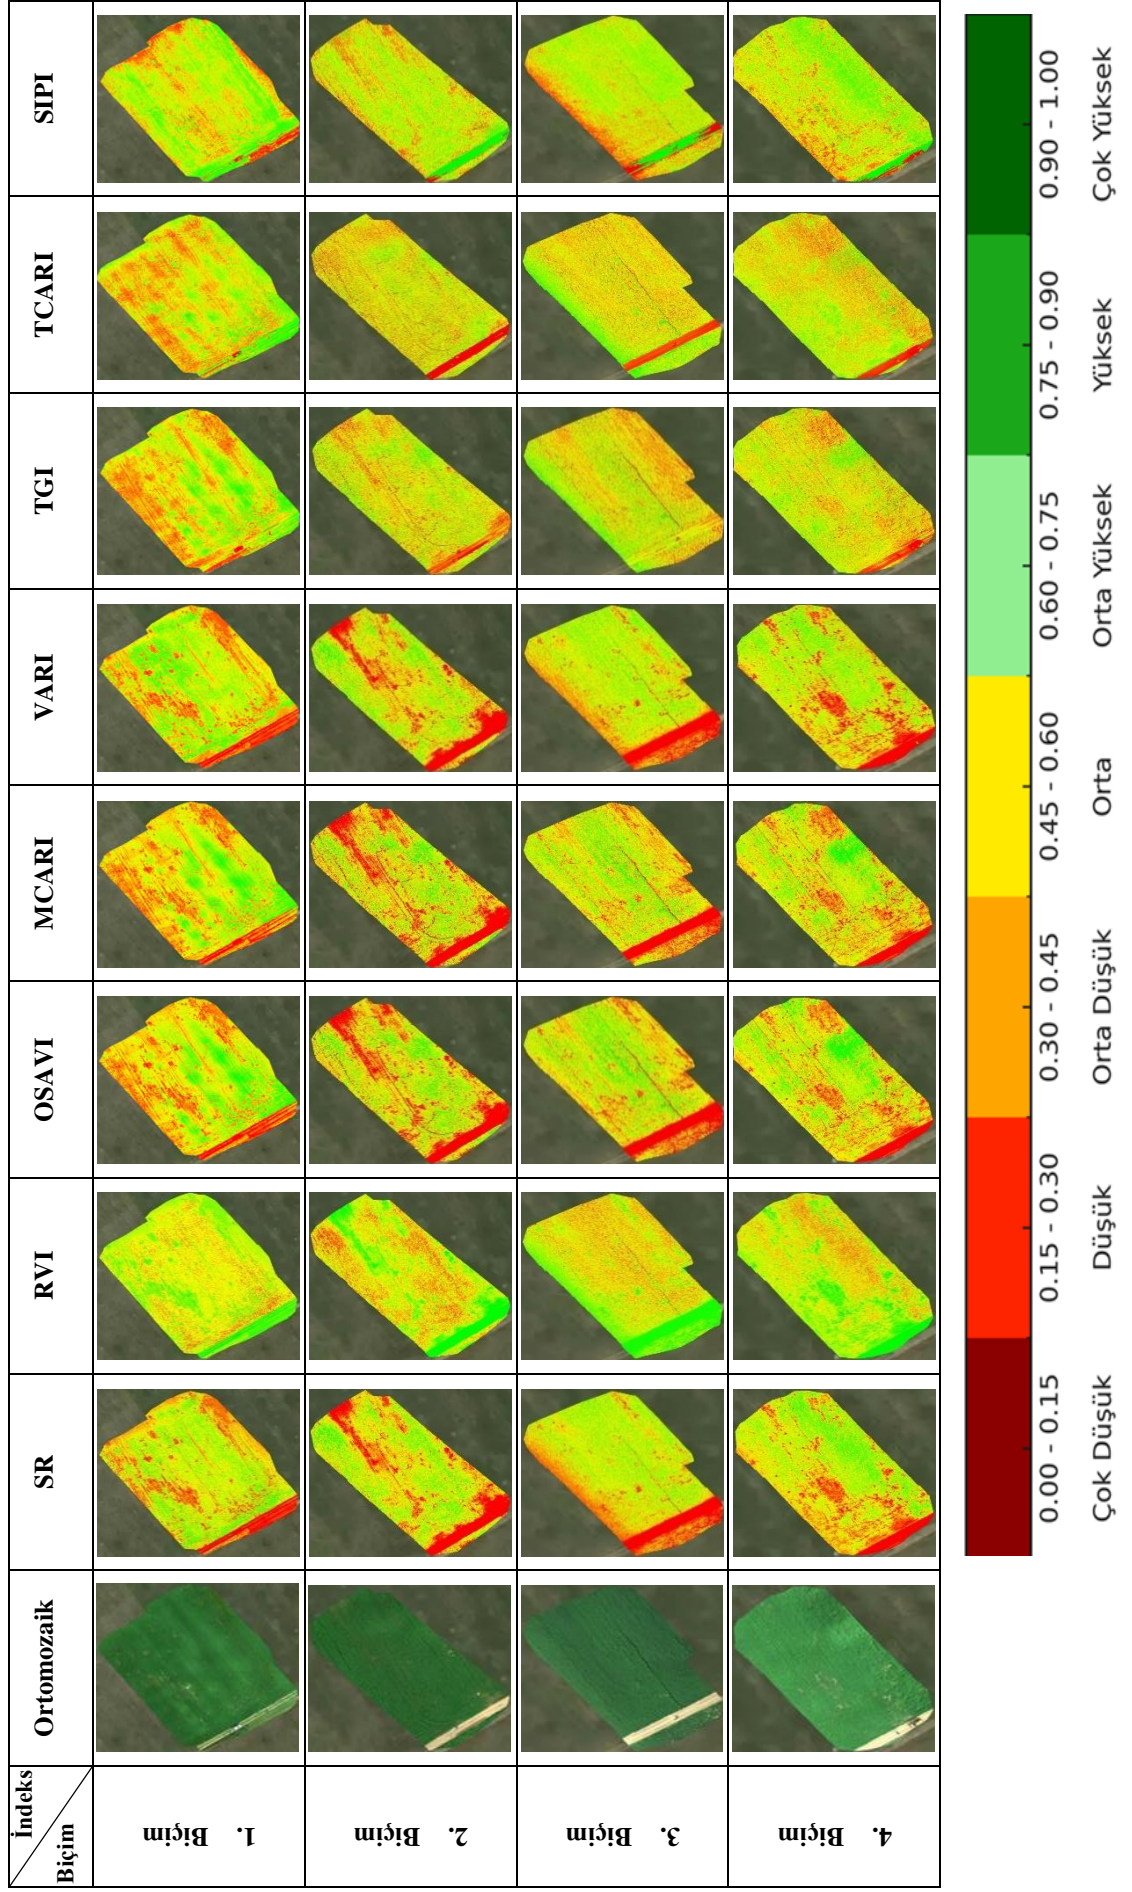
EK 8 Terziali Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları



EK 9 Malya (TIGEM) Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları




EK 10 Malya (TIGEM) Lokasyonunun Biçim Sayılarına Göre Bitki İndeks Haritaları

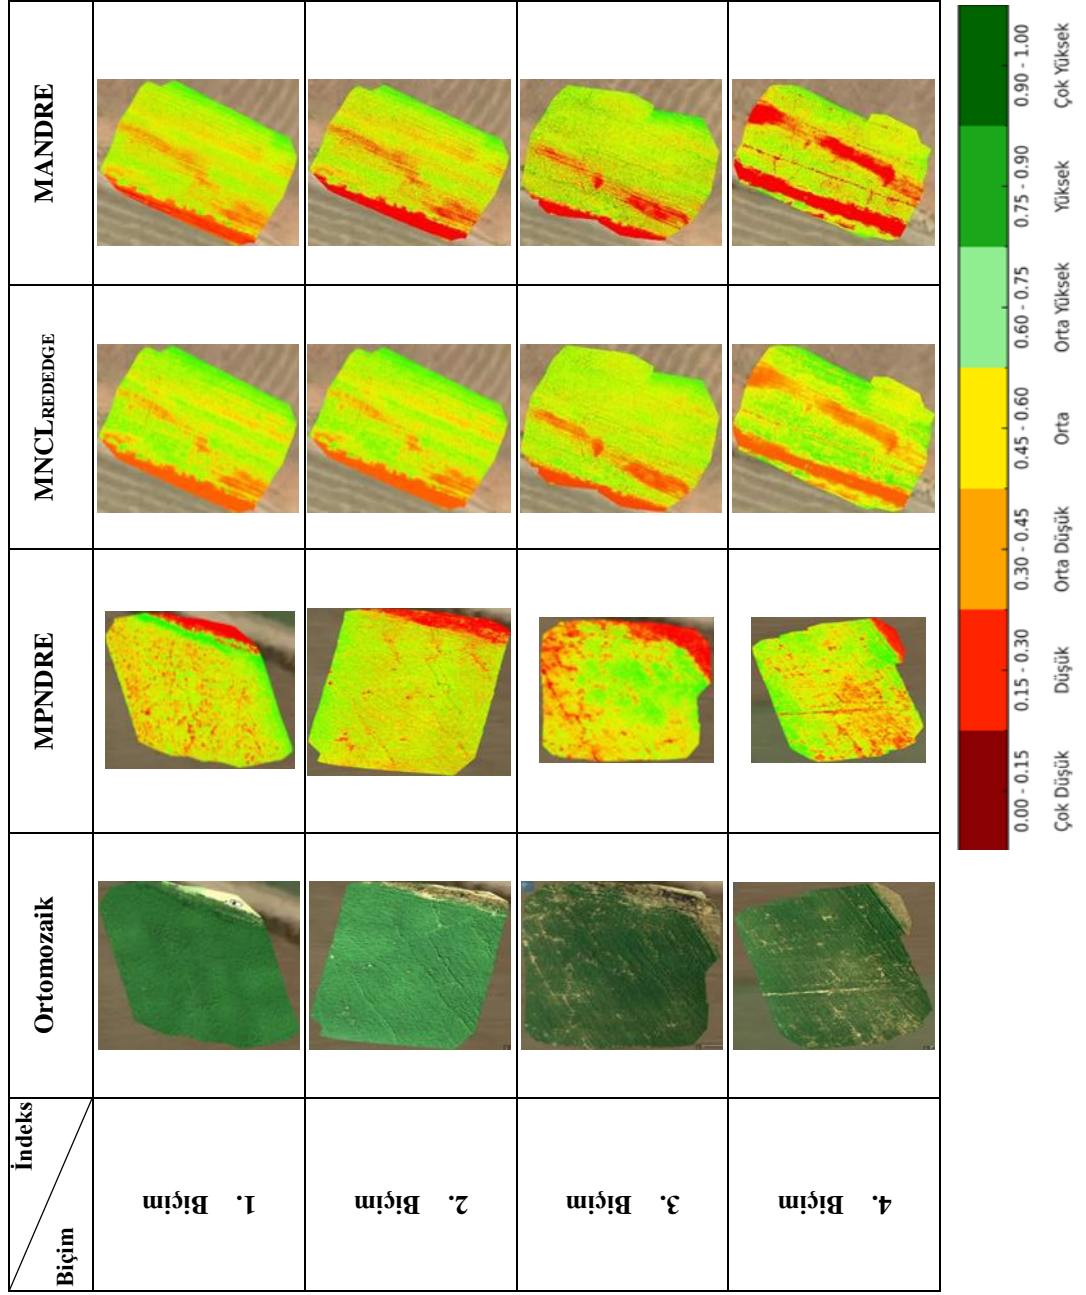


EK 11 Değirmenkaşı lokasyonu modifiye bitki indeks haritaları

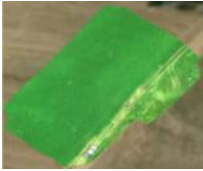
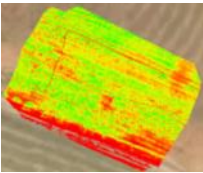
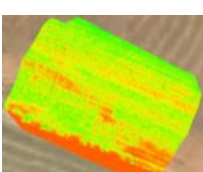
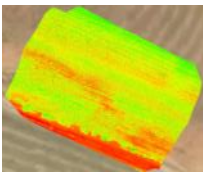

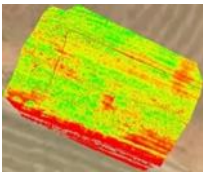
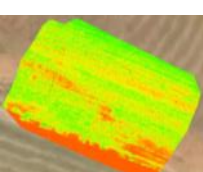
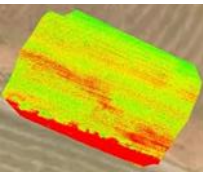
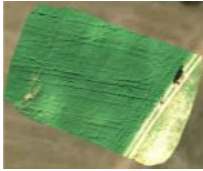
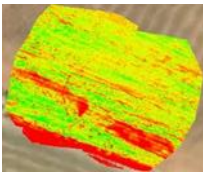
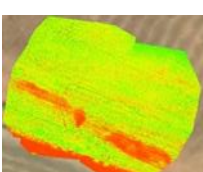
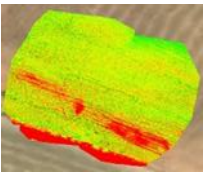

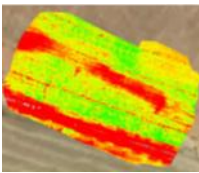
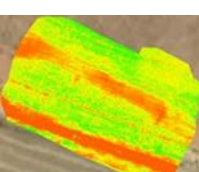
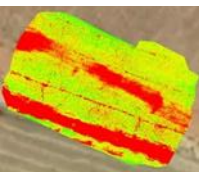
Biçim	İndeks	Ortomozaik				MPNDRE	MNCL _{REDEGE}	MANDRE
		Ortomozaik				MPNDRE	MNCL _{REDEGE}	MANDRE
1. Biçim								
2. Biçim								
3. Biçim								
4. Biçim								




EK 12 İshocacı lokasyonu modifiye bitki indeks haritaları


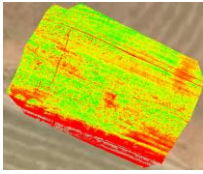
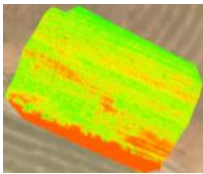
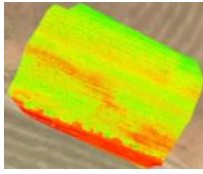

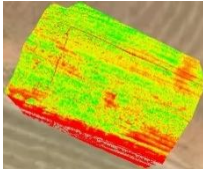
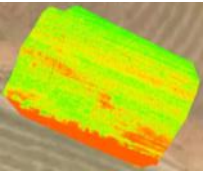
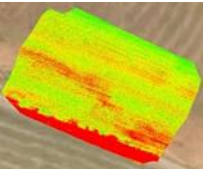
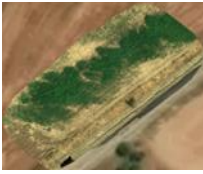
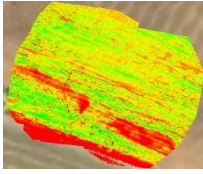
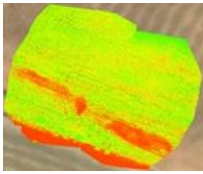
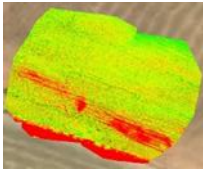
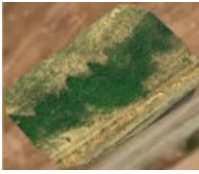
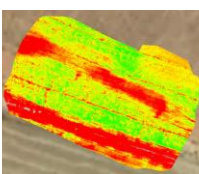
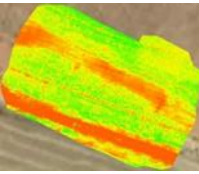
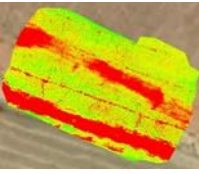



EK 13 Karahıdır lokasyonu modifiye bitki indeks haritaları

İndeks Biçim	Ortomozaik	MPNDRE	MNCL_REDEGE	MANDRE
5. Biçim				
6. Biçim				
7. Biçim				
8. Biçim				

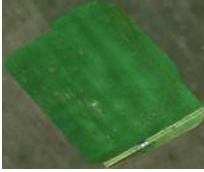
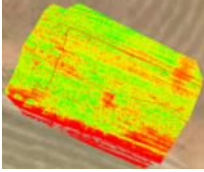
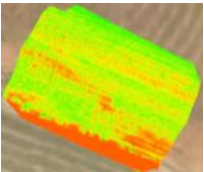
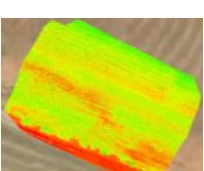
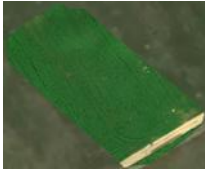
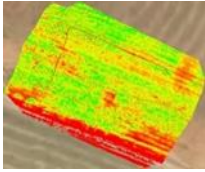
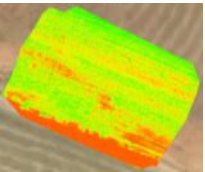
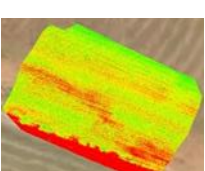
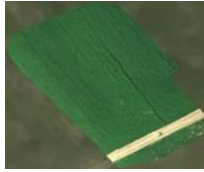
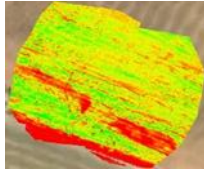
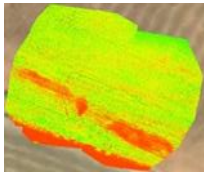
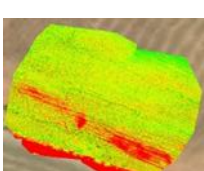


EK 14 Terziali lokasyonu modifiye bitki indeks haritaları

Biçim	İndeks	Ortomozaik	MPNDRE	MNCL_REDEGE	MANDRE
9. Biçim					
10. Biçim					
11. Biçim					
12. Biçim					



EK 15 MALYA (TİGEM) lokasyonu modifiye bitki indeks haritaları

İndeks Biçim	Ortomozaik	MPNDRE	MNCL _{REEDGE}	MANDRE
13. Biçim				
14. Biçim				
15. Biçim				
16. Biçim	