T.C
HARRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

TOPRAKTAKİ ORGANİK MADDE ANALİZİ İÇİN MOBİL VE AKILLI BİR SİSTEM TASARIMI

Yasin ASLAN

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

SANLIURFA
2019

Dr. Öğretim Üyesi Hasan GÖKTAŞ danışmanlığında Yasin ASLAN'ın hazırladığı "**Topraktaki organik madde analizi için mobil ve akıllı bir sistem tasarımı**" konulu bu çalışma 22/07/2019 tarihinde aşağıdaki jüri tarafından oy birliği ile Harran Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

İmza

Danışman : Dr. Öğr. Üys. Hasan GÖKTAŞ ……

Üye : Doç. Dr. Mehmet ÇELEBİ ……

Üye : Dr. Öğr. Üys. M. Ali ARSERİM ……

Bu Tezin Elektrik Elektronik Mühendisliği Anabilim Dalında Yapıldığını ve Enstitümüz Kurallarına Göre Düzenlendiğini Onaylarım.

Doç. Dr. İsmail HİLALİ
Enstitü Müdürü

Bu çalışma HÜBAK Tarafından Desteklenmiştir.
Proje No: 18172

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

İÇİNDEKİLER

ÖZET i
ABSTRACT ii
TEŞEKKÜR iii
ŞEKİLLER DİZİNİ iv
ÇİZELGELER DİZİNİ v
SİMGELER DİZİNİ vi
1. GİRİŞ 1
2. ÖNCEKİ ÇALIŞMALAR 3
2.1. Cihaz Geliştirme ile İlgili Çalışmalar 4
2.2. Makine Öğrenmesi Yöntemleri ile İlgili Çalışmalar 5
3. MATERYAL ve YÖNTEM 7
3.1. Ölçüm Donanımı ve Çalışma Prensibi 7
3.1.1. Plastik parçalar 10
3.1.2. Ayna mekanizması 10
3.1.3. Cosine Corrector 12
3.1.4. Spektrometre 12
3.1.5. Merkezi kontrol bilgisayarı ve diğer elektronik bileşenler 13
3.2. Kullanıcı Arayüzü ve Yazılım 15
3.3. Ölçüm ve Kalibrasyon Yöntemi 15
3.4. Toprak Örnekleri ve Ölçüm Yöntemi 17
3.5. Veri İşleme ve Makine Öğrenmesi Yöntemleri 19
3.5.1. Modellerin değerlendirme ölçütleri 21
3.5.2. Spektral verinin ön işlemlerden geçirilmesi 22
3.5.3. Temel bileşen analizi ve regresyonu (PCA, PCR) 23
3.5.4. Kısmi en küçük kareler regresyon (PLSR) 24
3.5.5. Çok değişkenli uyarlanabilir regresyon eğrileri (MARS) 25
3.5.6. Yapay sinir ağları (ANN) 26
4. ARAŞTIRMA BULGULARI ve TARTIŞMA 28
4.1. Cihazın Kullanımı ve Ölçüm Yazılımı 28
4.2. Kalibrasyon Modeli 28
4.3. Toprak Örneklerinin Spektral Ölçümleri 32
4.4. Makine Öğrenmesi Modellerinin Oluşturulması 35
5. SONUÇLAR ve ÖNERİLER 39
5.1. Sonuçlar 39
5.2. Öneriler 40
KAYNAKLAR 41
ÖZGEÇMİŞ 43
EK 1 Kod: Kalibrasyon verisinin hazırlanması ve grafiklerin çizimi 44
EK 2 Kod: Kalibrasyon modeli fonksiyonu 46
EK 3 Çizelge: Eğitilen modellerin eğitim ve test performansı sonuçları 47

ÖZET

Yüksek Lisans Tezi

TOPRAKTAKİ ORGANİK MADDE ANALİZİ İÇİN MOBİL VE AKILLI BİR SİSTEM TASARIMI

Yasin ASLAN

Harran Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üys. Hasan GÖKTAŞ
YIL: 2019, Sayfa: 48

Tarımda, toprağın verimli bir şekilde işlenmesi için öncelikle toprağın özellikleri bilinmelidir. Toprağın içerdiği organik madde miktarı bu özellikler arasında önemli bir yere sahiptir. Bu özelliklerin belirlenmesi genellikle kimyasal yöntemlerle laboratuvar koşullarında yapılır. Laboratuvarda yapılan analizlerin örnek azlığı, zaman alması ve kimyasal malzeme kullanımı gerektirmesi gibi dezavantajları bulunmaktadır. Son zamanlarda bu yöntemlere alternatif olarak yakın kızılötesi (Near InfraRed-NIR) spektrometre kullanılarak yapılan çalışmalar, toprağın organik madde miktarının uzaktan ışık yansıması ile tahmin edilebileceğini göstermiştir. Bu çalışmada NIR spektrometre yöntemiyle toprağın organik madde miktarını tahmin edebilecek taşınabilir, gerçek zamanlı bilgi veren bir cihaz geliştirme hedeflenmiştir. Tasarlanan cihaz dahili batarya, spektrometre, bilgisayar, ekran, elektronik donanım ve mekanik ayna düzeneğine sahip gömülü bir sistemdir. İçindeki bilgisayar sayesinde cihaz makine öğrenme algoritmalarını kullanarak ayna mekanizmasıyla spektrometreden aldığı verileri işlemektedir. Ölçüm sonuçlarını ise ekranda göstererek kullanıcıya bilgi vermektedir. Bu yöntem ile laboratuvar analizleri olmadan toprak organik madde miktarı hakkında bilgi alınabilir. Aynı zamanda daha fazla ölçümü gerçek zamanlı alabildiği için hassas tarım uygulamalarında kullanılabilecek potansiyele sahip bir cihaz özelliği kazanmaktadır.

ANAHTAR KELİMELER: Yakın kızılötesi, spektrometre, makine öğrenmesi, gömülü sistemler, toprak organik maddesi

ABSTRACT

MSc Thesis

DESIGN OF A MOBILE AND SMART SYSTEM TO ANALYSE ORGANIC MATTER OF SOIL

Yasin ASLAN

Harran University
Graduate School of Natural and Applied Sciences
Department Electrical and Electronic Engineering

Supervisor: Assist. Prof. Hasan GÖKTAŞ
Year: 2019, Page: 48

In agriculture, the characteristics of the soil should be known for the efficient processing of the soil. Organic matter contained in the soil has an important place among these properties. The determination of these properties is usually done by chemical methods in laboratory conditions. Laboratory analysis has disadvantages such as lack of sample, time consuming and chemicals. Recent studies have shown that organic matter content in the soil can be estimated by using near infrared (NIR) spectrometer as an alternative to these methods. In this study, it is aimed to develop a portable device that can estimate the amount of organic matter in soil by using NIR spectrometer method in real time. The designed device is an embedded system with internal battery, spectrometer, computer, screen, electronic hardware and mechanical mirror assembly in order to get light into spectrometer. With the computer inside, the device processes the data it receives from the spectrometer using machine learning algorithms. It shows the measurement results on the screen and informs the user. With this method, information about the soil organic matter can be obtained without laboratory analysis. At the same time, as it can take more measurements in real time, it becomes a device that has the potential by using this method in applications of precision agriculture.

KEY WORDS: Near infrared, spectrometer, machine learning, embedded systems, soil organic matter

TEŞEKKÜR

Tezin konusunun seçiminde, uygulamasında ve çalışmamda yardımlarını esirgemeyen danışmanım Dr. Öğr. Üys. Hasan GÖKTAŞ'a; toprak örneklerini elde etme, analiz etme ve teknik bilgi konusunda yardımcı olan ziraat fakültesi toprak bilimi ve bitki besleme bölümünden Doç. Dr. Ali Volkan BİLGİLİ'ye ve Emrah RAMAZANOĞLU'na; makine öğrenmesi konusunda bana yardımcı olan mühendislik fakültesi bilgisayar mühendisliği bölümünden Dr. Öğr. Üys. Nagehan İLHAN'a; çalışmamda yardımcı olan arkadaşlarım Cihan EFİL ve Duygu SAĞALTICI'ya teşekkür ederim. Ayrıca tez çalışmam boyunca bana maddi ve manevi destek veren aileme teşekkür ederim.

ŞEKİLLER DİZİNİ

Şekil 1.1 Laboratuvar ve sahada yapılan analizlerin avantajları ve dezavantajları 1
Şekil 3.1 Sistemin bilgisayar ortamında tasarlanmış görünümü 7
Şekil 3.2 Sistemin temel blok diyagramı ve bileşenler arasındaki haberleşme 8
Şekil 3.3 Cihazın kesit görünümü 9
Şekil 3.4 Plastik parçaların üretilip birleştirilmiş hali 10
Şekil 3.5 Ayna mekanizması 10
Şekil 3.6 Ayna mekanizmasının hareketleri 11
Şekil 3.7 Cosine corrector aparatnda gelme açısına göre ışık şiddetinin değişimi 12
Şekil 3.8 Cosine Corrector aparatı 12
Şekil 3.9 Spektrometrenin görünümü ve boyutları 13
Şekil 3.10 Cihazın dış görünüşü 14
Şekil 3.11 Ölçüm ekranı ve ayarlar ekranı 15
Şekil 3.12 Beyaz referans kalibrasyonu için ölçüm alınması 16
Şekil 3.13 Toprak örneklerinin organik madde miktarlarının dağılımı 18
Şekil 3.14 Işık düzeneği ve 45 derecelik açıyla yerleştirilmiş halojen lamba 18
Şekil 3.15 Toprak örneğinin reflektansının alınması 19
Şekil 3.16 İki farklı toprak örneğinin spektral yansıma ölçümleri 20
Şekil 3.17 Makine öğrenmesi modeli blok diyagramı 20
Şekil 3.18 Klasik doğrusal modelleme ve MARS modeli 25
Şekil 3.19 Yapay nöronun matematiksel modeli 26
Şekil 3.20 Yapay sinir ağı modelinin blok diyagramı 27
Şekil 4.1 Kalibrasyon için cosine corrector kullanılarak güneşten alınan ölçümler 29
Şekil 4.2 Beyaz referans için baryum sülfat kaplı tabakadan alınan ölçümler 29
Şekil 4.3 Karanlık referans için alınan ölçümler 30
Şekil 4.4 Ölçümlerin denklemde kullanılmasıyla ortaya çıkan sonuç 30
Şekil 4.5 Uzaklığa göre 632 nm dalga boyundaki yansıma oranının değişimi 31
Şekil 4.6 Toprak örneklerinin reflektans spektrumu 32
Şekil 4.7 Bir toprak örneğine ait reflektans verisi ve yumuşatma yöntemleri uygulanmış hali 33
Şekil 4.8 Normalizasyon ve şekil değiştirme işlemleri uygulanmış örnek spektrum 34
Şekil 4.9 Reflektans spektrumunun gürültülü kısmın çıkarılmış hali 35
Şekil 4.10 En iyi sonucu veren birinci ve ikinci modelin tahmin ve gerçek değer ilişkisi 36
Şekil 4.11 En iyi sonucu veren üçüncü ve dördüncü modelin tahmin ve gerçek değer ilişkisi 37
Şekil 4.12 En iyi sonucu veren beşinci ve altıncı modelin tahmin ve gerçek değer ilişkisi 37
Şekil 4.13 En iyi sonucu veren yedinci ve sekizinci modelin tahmin ve gerçek değer ilişkisi 38

ÇİZELGELER DİZİNİ

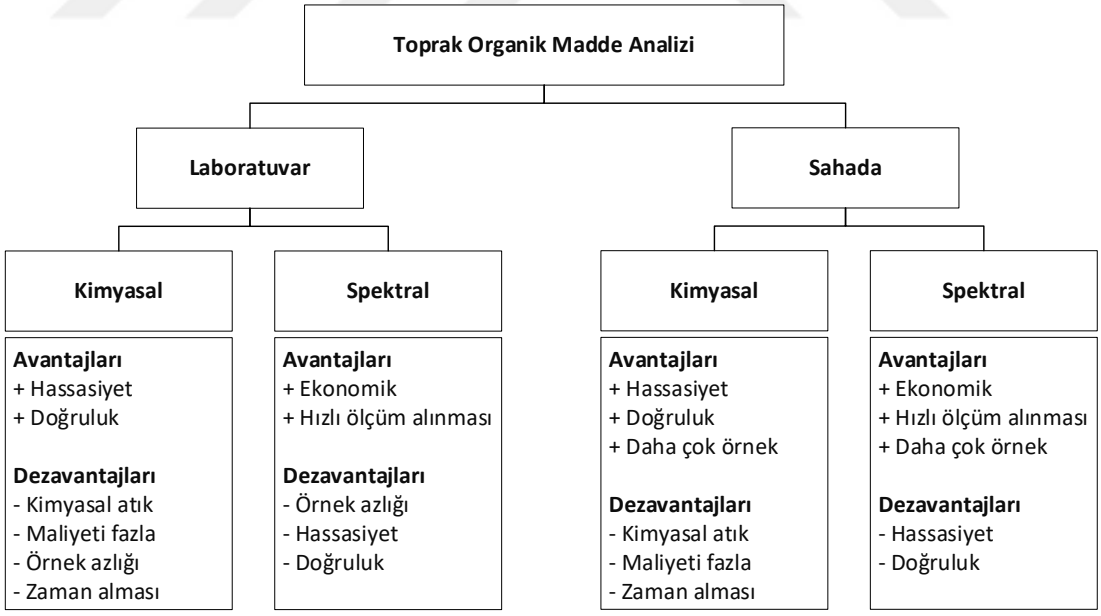
Çizelge 3.1 Cihazın kesit görünümünde belirtilen bileşenlerin isimleri 9
Çizelge 3.2 Sistemin bileşenlerinin maksimum güç tüketimi 14
Çizelge 4.1 Spektral veriye yapılan ön işlemler ve işlem sonrası değişken sayısı 33
Çizelge 4.2 R^2 ölçütüne göre en iyi 12 eğitim modelinin performans ölçütleri 36
Çizelge 5.1 En iyi sonucu veren 8 adet modelin performansları 39

SİMGELER DİZİNİ

NIR	Near Infrared (Yakın Kızılötesi)
GPIO	General Purpose Input-Output (Genel Amaçlı Giriş-Çıkış)
SPI	Serial Peripheral Interface (Seri Çevre Arayüzü)
USB	Universal Serial Bus (Evrensel Seri Veriyolu)
LCD	Liquid Crsytal Display (Sıvı Kristal Ekran)
PLA	Polilaktik Asit
UART	Universal Asynchronous Receiver Transmitter (Evrensel Asenkron Alıcı Verici)
OM	Organik Madde
PCA	Principal Component Analysis
PCR	Principal Component Regression
PLSR	Partial Least Squares Regression
MARS	Multivariate Adaptive Regression Spline
ANN	Artificial Neural Networks
SARSA	State-Action-Reward-State-Action
OLS	Ordinary Least Squares
RMSE	Root Mean Square Error (Kök Ortalama Kare Hata)
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
R^2 veya R^2	Belirleme katsayısı (Coefficient of determination)
Mv	Moving average (Hareketli ortalama)
Bn	Binning-Resampling (Yeniden örnekleme)
Sg	Savitzky-Golay filtresi
Diff	Türev alma yöntemi
SgDiff	Savitzky-Golay Gap-Segment türev alma yöntemi
Snv	Standard Normal Variate (Standart Normal Değişkenlik)
SnvDe	Snv Detrend (SNV yöntemi ile eğilimi kaldırmak)

1. GİRİŞ

Tarımda verimlilik, toprak kalitesi ve toprak erozyonuna bağlı karbon salınımı konularında topraktaki organik madde ve organik karbon önemli bir rolü vardır. Organik madde miktarı bitkiler için besin maddesi anlamına gelmektedir. Yapılan tarımın ne kadar verimli olacağı hakkında bilgi verir. Ayrıca toprak erozyonuyla doğaya salınan karbonun takibi açısından da organik madde miktarı önemli bir parametredir. Organik madde çoğunlukla ölü bitkiler, hayvanlar, mikroorganizmalar ve bunların atıklarından oluşmaktadır. Toprak organik maddesi için kimyasal analiz veya uzaktan ölçüm yöntemleri geliştirilmiştir (Nelson and Sommers, 1982), (Ben-Dor and Banin, 2010). Bu ölçümler laboratuvar ortamında veya sahada gerçekleştirilmektedir. Her ikisinde de topraktan örnekler alınarak kimyasal veya spektral yöntemlerle analizi yapılır. Fakat hassasiyet açısından avantajlı olmasına rağmen örnek azlığı, kimyasal kullanımı, zaman ve maliyet açısından dezavantajlıdır (Şekil 1.1). Diğer taraftan uzaktan ölçüm tekniği olarak spektral analiz ile daha hızlı ve fazla örnek alınabilir.



Şekil 1.1 Laboratuvar ve sahada yapılan analizlerin avantajları ve dezavantajları

Uzaktan algılama teknikleri (Yakın Kızılötesi Spektrometre, Termal Görüntüleme vb.), sahada toprak organik maddesinin dolaylı yoldan tahmin edilmesini sağlamaktadır. Çok sayıda örneği hızlı analiz edilebilmesi bu tekniği cazip kılmaktadır. Bu avantajları sayesinde büyük alanlar organik madde bakımından haritalandırılabilir ve bu işlem periyodik olarak gerçekleştirilebilir. Uzaktan algılama dışında sahada ölçüm alabilmek için kimyasal yöntemler de geliştirilmiştir (Lobsey, Rossel, and McBratney, 2010). Ancak yavaş olması, kimyasal atık bırakması ve maliyet gibi dezavantajları bulunmaktadır.

Topraktaki organik madde, temelde C-H, O-H, N-O bağlarının topraktaki oranının ölçümü ile belirlenir. Her bir bağ yapısının veya elementin topraktaki ışığı yansıtma, absorbe etme ve geçirme oranları birbirinden farklıdır. Çalışmada ışığı yansıtma özelliğinden yararlanarak topraktaki organik madde miktarını ölçebilecek bir cihaz geliştirmek hedeflenmektedir. Bu yöntem halen geliştirmeye açıktır ve tarımdaki önemi göz önüne alındığında böyle bir ihtiyaç ortaya çıkmaktadır.

Hızlı ve daha çok örnek ölçümü yapılmak istendiğinden çalışmanın ölçüm yöntemi olarak NIR (near infrared, yakın kızılötesi) spektroskopisi, en uygun ve ekonomik olmuştur. Yukarıda belirtilen özelliklerinden dolayı bu sistemin ve yöntemin daha ileri bir seviyede geliştirilip hassas tarımda da kullanılması beklenmektedir.

2. ÖNCEKİ ÇALIŞMALAR

Tarım, eski çağlardan günümüze kadar ulaşmış ve her geçen gün gelişmekte olan bir alandır. Tarımsal faaliyetleri geliştirmek adına birçok çalışma yapılmaktadır.

Toprakta organik maddenin önemli bir nitelik taşıması nedeniyle bu verilere ulaşmak için çeşitli yöntemler geliştirilmiştir. Laboratuvar çalışmalarının yanı sıra yerinde ölçüm kolaylığı sağlayan ve topraktan gelen yansımaları veriye dönüştüren spektrometre, son yıllarda gelişimde kolaylık sağlamıştır. Bu konuda büyük ölçüde araştırmalar yapılmıştır. Çalışmalardan bazıları ölçüm alabilmek için cihaz geliştirmeye; bazıları da spektroskopi ile alınan ölçümlerin daha iyi analizini yapabilmeye odaklanmıştır.

Önceki çalışmalarda eğitilen modellerin başarı oranını ölçümlemek için birkaç ölçüt kullanılmıştır. R^2 (belirleme katsayısı), RMSE (kök ortalama kare hata), MAE (ortalama mutlak hata) ve RPD (atık tahmin sapması) gibi ölçütler ile modellerinin başarılı olup olmadığını göstermişlerdir. R^2 katsayısı sıfır ile bir arasında değişmekte ve bire yaklaştıkça tahmin edilen ve gerçek değerin birbirine olan ilişkisi artmaktadır. RPD birden küçük ise model başarısız, 2.5'ten büyük ise modelin çok iyi olduğu anlamına gelmektedir. RMSE tahmin edilen ve gerçek değer arasındaki hataların kareleri ortalamasının karekökü alınarak bulunur. RMSE sıfıra ne kadar yakın olursa o kadar iyi model oluşturulmuş olur. MAE tahmin edilen ve gerçek değer arasındaki hatanın mutlak değerlerinin ortalaması alınarak hesaplanır. MAE'nin sıfıra yakın olması istenir. RMSE MAE'den büyük veya eşit çıkmaktadır. MAE hatadaki küçük değişimleri doğrusal olarak yansıtmaktadır. RMSE ise küçük hata değişimlerini daha fazla yansıtır ve bu yüzden model seçimlerinde RMSE ölçütü tercih edilir. Bunların yanında R^2 ise gerçek değerler ve tahmin edilen değerler arasındaki doğrusallığın bir ölçütüdür. RMSE ve R^2 birlikte kullanılarak modelin ne derecede iyi olduğu tespit edilebilir.

2.1. Cihaz Geliştirme ile İlgili Çalışmalar

K. A. Sudduth ve J. W. Hummel 1993 yılındaki çalışmalarında NIR spektrofotometre kullanarak topraktan veri almış ve elde ettikleri verileri laboratuvar sonuçları ile karşılaştırmışlardır. Sonuç olarak 1640-2640 nm arasındaki dalga boyu kullanılarak yaptıkları çalışmalarda R^2=0.89 belirleme katsayısına ulaşmışlardır. Organik madde tahmininde ise %40 gibi bir hata oranı tespit etmişlerdir (Kim, Sudduth, and Hummel, 2009).

Craig Lobsey, R. V. Rossel ve A. McBratney (2010) toprağın azot (N), potasyum (K) ve sodyum (Na) miktarını ölçmeye yönelik bir çalışma yapmışlardır. Bu çalışmada İyon Seçici Elektrotlar (ISE) kullanılmış ve multi-iyon ölçüm sisteminin (MIMS) deneysel gelişimine değinilmiştir. Toprağın besin değerlerini 30 saniye gibi kısa bir sürede analiz eden bir prototip geliştirmişlerdir. Kullandıkları yöntem sonucunda nitrat tahmini için 0.92, potasyum ve azot için ise 0.99 R^2 korelasyon değerine ulaşmışlardır (Lobsey et al., 2010).

Boyan Kuang ve Abdul M. Mouazen (2013) topraktaki organik karbonun ve azotun değerlerini tahmin etmek için vis-NIR spektrometre ile hem arazide hem de laboratuvar ortamında ölçüm alıp karşılaştırma yapmışlardır. Çalışmalarında ayrıca nem içeriği ve fiziksel görünümn ölçüme etkisini gözlemlemişlerdir. Bunun sonucunda organik karbon tahmini için 2.66-3.39 RPD (residual prediction deviation) ve toplam azot için 2.85-3.45 RPD değerlerine ulaşmışlardır. Ek olarak toprak nem içeriğinin ve toprağın taze olmasının ölçümde önemli birer etken olduğunu; kil, kum, silt ve nem değerinin vis-NIR spektrometre ölçümlerini önemli derecede etkilediğini gözlemlemişlerdir (Kuang and Mouazen, 2013).

W. Aimrun, A. Gholizadeh, J. N. A. Asminda ve M. S. M. Amin (2014) RGB (red green blue) kamera ile toprak organik maddesini tespit etme amaçlı bir çalışma yapmışlardır. Topraktaki organik maddesini gerçek zamanlı ölçümü için SOMSENSE (soil organic matter sence) adını verdikleri bir sistem geliştirmişlerdir. Bu çalışmayı kamera ve GPS (global positioning system) ile MATLAB yazılımını birleştirerek yapmışlardır. Traktöre entegre edilen bu sistem dahili çapası ile toprağı açıp arkasındaki kamera ile toprağın görüntüsü alınmaktadır. Sonuç olarak organik madde

tahmininde $R^2 = 0.2183$ değerini elde etmişlerdir (Aimrun, Gholizadeh, Asminda, and Amin, 2014).

P. P. Ruwanpathirana, B. M. S. Jinendra, K. M. T. S. Bandara 2016'da yayımlanmış olan çalışmalarında 588-1100 nm dalga boyu aralığına sahip olan FQA-NIR Gun adlı portatif NIR spektrometresini kullanarak toprak değerlerini ölçmüşlerdir. Organik karbon içeriğinin tespitinde kimyasal analiz olarak Walkley-Black yöntemini, topraktaki organik madde miktarının modellenmesi için de PLSR algoritmasını kullanmışlardır. Kuru ve ıslak toprak örneklerinde organik madde tahmini için sırasıyla 0.95 R^2 ve 0.91 R^2 değerlerine ulaşmışlardır (Ruwanpathirana, Jinendra, and Bandara, 2016).

Jing Yu, Jiangmei Mao, Tao Pan, Pimao Chen ve Lijun Yao (2017) deniz tortularındaki organik karbon değerini ölçmek için portatif ve 950-1650 nm dalga boyu aralığına sahip olan MicroNIR spektrometresini kullanmışlardır. Kısmi en küçük kareler regresyonu ve Savitzky-Golay yumuşatmayı kullanarak organik karbon değeri için RMSE (root mean square errors) % 0.075 ve korelasyon katsayısını 0.883 elde etmişlerdir (Yu, Mao, Pan, Chen, and Yao, 2017).

2.2. Makine Öğrenmesi Yöntemleri ile İlgili Çalışmalar

He Yong, Song Hai-Yan, A. G. Pereira Ve A. H. Gomez (2005) topraktaki organik madde miktarı ve azotu ölçmek amacıyla ASD FieldSpec Pro FR (350~ 2500 nm)/A110070 spektrometresini kullanmışlardır. Toplamda 125 toprak örneğinin ölçümlerini kalibrasyon için 95 doğrulama için 30 olarak ayırarak PCA (principal component analysis) ve En küçük kareler regresyon yöntemlerini (PLSR) uygulamışlardır. Sonuç olarak tahmin edilen ile ölçülen değerler arasındaki korelasyonu azot için 0.92 organik madde için ise 0.93 olarak bulmuşlardır (He, Song, Pereira, and Gomez, 2005).

P. K. Mutuo, D. Shepherd ve arkadaşları (2006) çalışmalarında 350-2500 nm dalga boyuna sahip bir spektrometre kullanarak kumlu ve killi topraklarda organik karbon ve azot tahmini için ölçüm yapmışlardır. Laboratuvar referans değerleri ile sonuçları karşılaştırmış ve organik karbon tahmininde R^2=0.84, azot için ise R^2=0.87 sonucuna ulaşmışlardır. Elde ettikleri diğer bir sonuç ise kumlu ve killi topraklarda

spektrometre ile organik madde ölçümünün zor olması ve sonuçları olumsuz etkilemesidir (Mutuo, Shepherd, Albrecht, and Cadisch, 2006).

Cécile Gomez, R. A. V. Rossel ve A. B. McBratney (2008) topraktaki organik maddeyi tahmin ederken kullanılan vis-NIR (görünür ışık ve yakın kızılötesi) hiperspektrometre ile uydu spektrometresi verilerini karşılaştırmışlardır. Bunun için 350-2500 nm dalga boyu aralığına sahip AgriSpec portatif spektrometre ve 400-2500 nm dalga boyu aralığındaki Hyperion adlı uyduyu kullanmışlardır. Bunun sonucunda organik madde tahmininde AgriSpec spektrometresinden elde edilen verilerin daha yüksek doğruluk sunduğunu ancak iki yöntemin de beraber kullanılma potansiyelinin olduğunu gözlemlemişlerdir (Gomez, Viscarra Rossel, and McBratney, 2008).

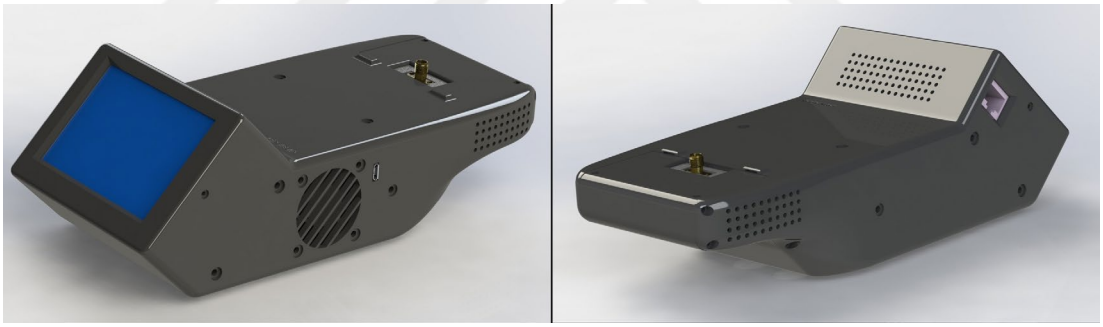
Sandro Teixeira, Alaine M. Guimarães ve çalışma arkadaşları (2014) toprak organik madde miktarı ve kil oranını arasındaki en iyi korelasyonu bulmak amacıyla görünür-kızılötesi (vis-NIR) spektrometre kullanmışlardır. Elde edilen verileri Weka yazılımındaki tüm sınıflandırma algoritmalarını uygulayarak analiz etmişlerdir. 400-2500 nm dalga boyu aralığında kullandıkları spektrometre aracılığı ile topraktaki kilin hem görünür hem de NIR spektrum ile yüksek korelasyon olduğunu göstermiştir. Organik madde tahmininde 0.7'den büyük doğruluk elde etmiş ve en iyi sonucu Lazy Kstar algoritmasının verdiğini görmüşlerdir (Teixeira, Guimarães, Proença, Rocha, and Fávero, 2014).

Massimo Conforti, Giorgio Matteucci ve Gabriele Buttafuoco 2017 yılındaki çalışmalarında 267 toprak örneği ile laboratuvar ortamında kimyasal analiz yapmışlardır. Daha sonra ASD FieldSpec IV adlı 350-2500 nm dalga boyu aralığına sahip spektroradiometre kullanarak ölçüm almışlardır. Kalibrasyon modeli için en küçük kareler regresyonu kullanılmış ve veri setlerini %70 eğitim %30 test olarak ayırmışlardır. Sonuç olarak toprak organik karbonu için 0.88 R^2 değerine ulaşmışlardır (Conforti, Matteucci, and Buttafuoco, 2018).

3. MATERYAL ve YÖNTEM

Çalışma toprak örnekleri ve ölçüm yapacak cihaz olmak üzere iki temel materyalden oluşmaktadır. Toprak örnekleri üniversitenin ziraat fakültesi yardımıyla elde edilmiştir. Bunlar 127 adet Şanlıurfa'nın Siverek ilçesinden alınmış farklı organik madde miktarlarına sahip bazalt tabanlı örneklerdir. Ölçüm yapacak cihaz, yakın kızılötesi (NIR) reflektans tekniğiyle çalışan, içinde spektrometre barındıran taşınabilir bir elektronik sistemden oluşmaktadır (Şekil 3.1).

Bu çalışmanın yöntemini cihazın tasarımı, sonuç verebilmesi için gereken kalibrasyonlar, testler ve makine öğrenmesi algoritmaları oluşturmaktadır. Cihazın ölçüm yöntemi organik karbonun algılanmasına bağlı olarak organik maddeyi tahmin etmektir. Bunu, içinde bulunan spektrometre ile topraktan yansıyan ışığı ölçüp bu ışığı yorumlayarak yapmaktadır. Daha sonra sonucu ekrana yazdırarak kullanıcıyı bilgilendirmektedir.



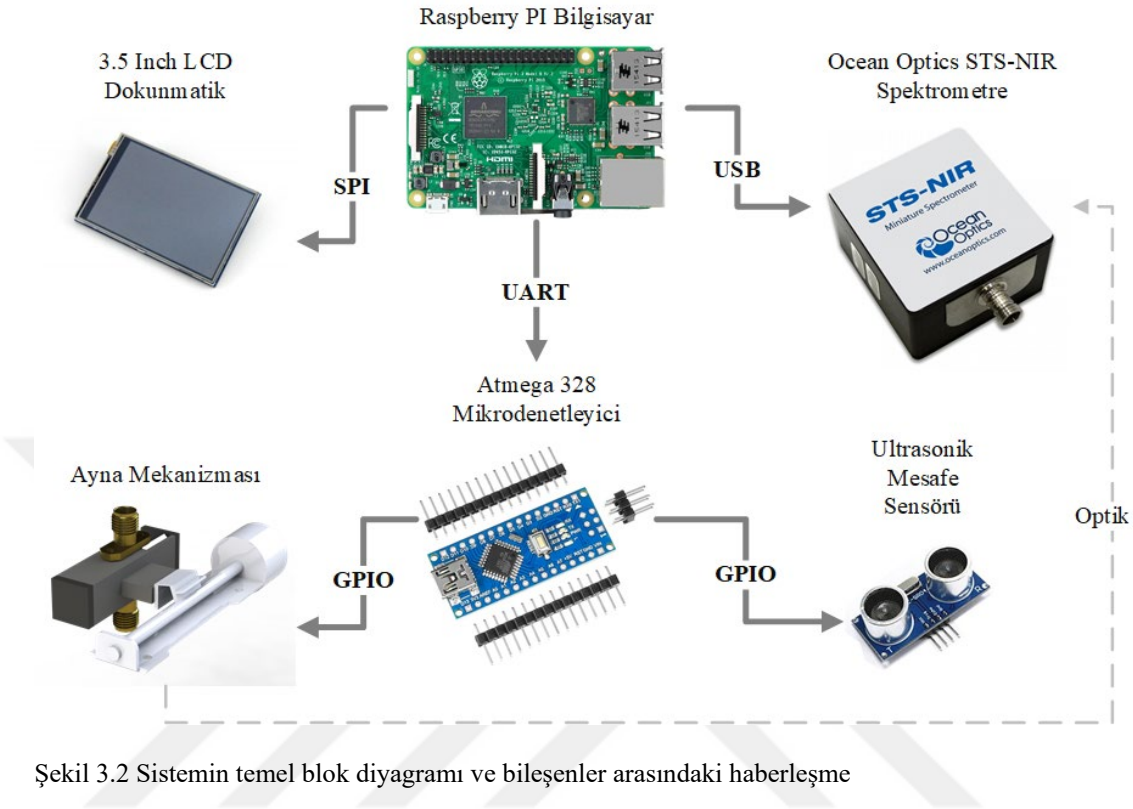
Şekil 3.1 Sistemin bilgisayar ortamında tasarlanmış görünümü

3.1. Ölçüm Donanımı ve Çalışma Prensibi

Sistem toprak üzerinde uzaktan ölçüm alabilmek için güneş ışığından faydalanmaktadır. Temel çalışma prensibi olarak; güneşten toprağa gelen ışığı referans alarak topraktan yansıyan ışığa göre sonucu tahmin etmektedir. Bulduğu sonucu dâhili ekranında göstererek kullanıcıyı bilgilendirir. Sistemin blok diyagramı ve aralarındaki haberleşme protokolleri Şekil 3.2'de verilmiştir.

Sistemin temel bileşenlerinden biri olan spektrometre olarak Ocean Optics firmasının STS-NIR modeli kullanılmıştır. Bu model organik karbonun ayırt

edilebildiği 600-1100nm dalga boyu aralığında çalışmaktadır. Ayrıca küçük yapısı nedeniyle de tercih sebebi olmuştur.



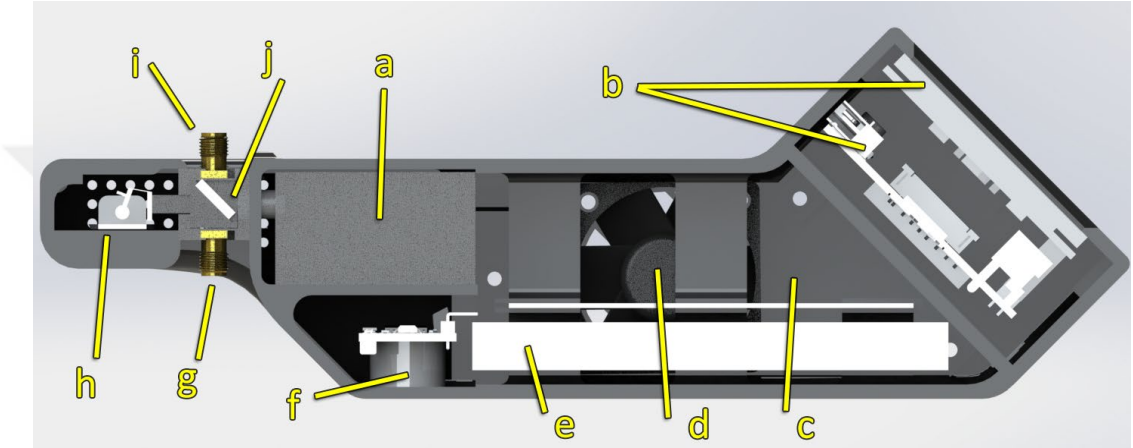
Şekil 3.2 Sistemin temel blok diyagramı ve bileşenler arasındaki haberleşme

Spektrometrenin sürekli değişen ışık koşullarına göre kalibre edilebilmesi için hem güneşten hem de topraktan gelen ışığı almalıdır. Bunun için ışığı her iki yönden de alabilecek hareketli bir ayna mekanizması tasarlanmıştır. Böylece ışığın yansıma oranını belirlemek için referans alınabilir ve yerden yansıyan ışık bu referansa göre ölçülebilir. Ek olarak ayna düzeneğinde toprağa bakan optik açıklık ile toprak arasındaki mesafe değişebileceğinden açıklığın görüş alanı da değişebilir. Görüş alanının değişmesi referans ışığından bağımsız olarak gelen ışığın az veya çok olmasıyla sonuçlanır. Işığın alınan referanstan bağımsız olarak değişmesi sonucun cihazın toprak ile arasındaki mesafeye bağlı olması anlamına gelmektedir. Oluşan sorunu cihaz ile toprak arasındaki mesafenin değişiminin kalibre edilmesi ile giderilebilir. Bu nedenle ultrasonik mesafe sensörü kullanılarak cihaz ile toprak arasındaki mesafe ölçülüp, görüş alanı kalibre edilebilir hale getirilmiştir.

Düşünülmesi gereken bir diğer husus ise güneş ışınlarının cihaza hangi açıyla geldiğidir. Güneş ışınlarının açısı gün içerisinde sürekli değiştiğinden bunun da kalibre

edilebilir olması gerekmektedir. Bu sorun daha sonraki başlıklarda tanımı yapılan Cosine Corrector aparatıyla giderilmiştir. Böylece güneş ışınları her yönden alınarak spektrometreye aktarılmaktadır. Toprağa gelen ışınlar bu şekilde simüle edilebilir ve bağıl yansıma oranı alınabilir.

Topraktan 600-1100nm dalga boyu aralığındaki yansıma miktarları alındıktan sonra bu veriler dâhili bilgisayarda analiz edilerek, tahmin sonucu ekranda gösterilmektedir.



Şekil 3.3 Cihazın kesit görünümü

Şekil 3.3'te cihazın kesit görünümü verilmiş ve harflerle gösterilen bileşenlerin isimleri Çizelge 3.1'de listelenmiştir.

Çizelge 3.1 Cihazın kesit görünümünde belirtilen bileşenlerin isimleri

a	Spektrometre
b	Raspberry Pi ve LCD
c	Mikro denetleyici, motor sürücü ve batarya şarj devresi için boş bırakılan alan
d	Soğutma fanı
e	Lityum iyon batarya (3.7V,8000mAh)
f	Ultrasonik sensör
g	Topraktan yansıyan ışınların alındığı optik açıklık
h	Step motor
i	Güneş ışınlarının alındığı optik açıklık
j	Aynalar ve aynaları tutan plastik parçaları

3.1.1. Plastik parçalar

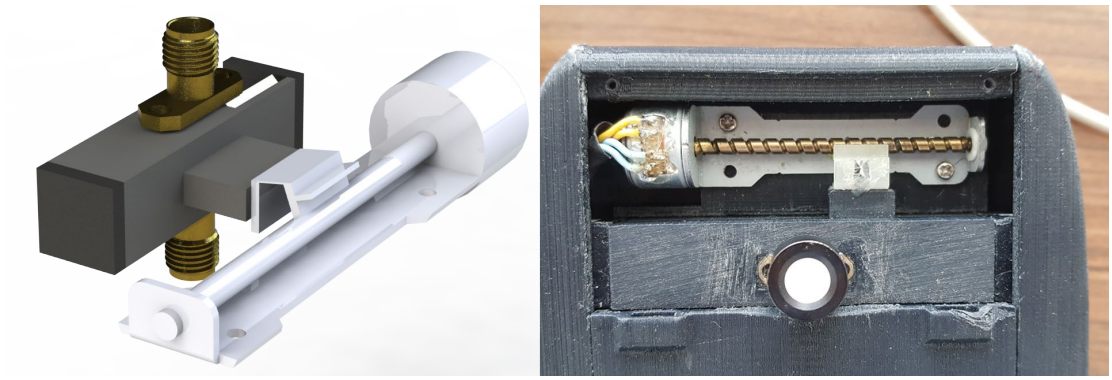
Cihazın elektronik ve mekanik parçalarını bir arada tutmak için plastik şase kullanılmıştır. Bilgisayar ortamında üç boyutlu olarak tasarlandıktan sonra 3D yazıcı ile plastik parçalar PLA plastik türüyle üretilmiştir. Üretilen bu parçaların birleştirilmiş hali Şekil 3.4'te gösterilmiştir. Bu parçalar metrik 3 metal somun ve vidalar ile tutturulmuştur.



Şekil 3.4 Plastik parçaların üretilip birleştirilmiş hali

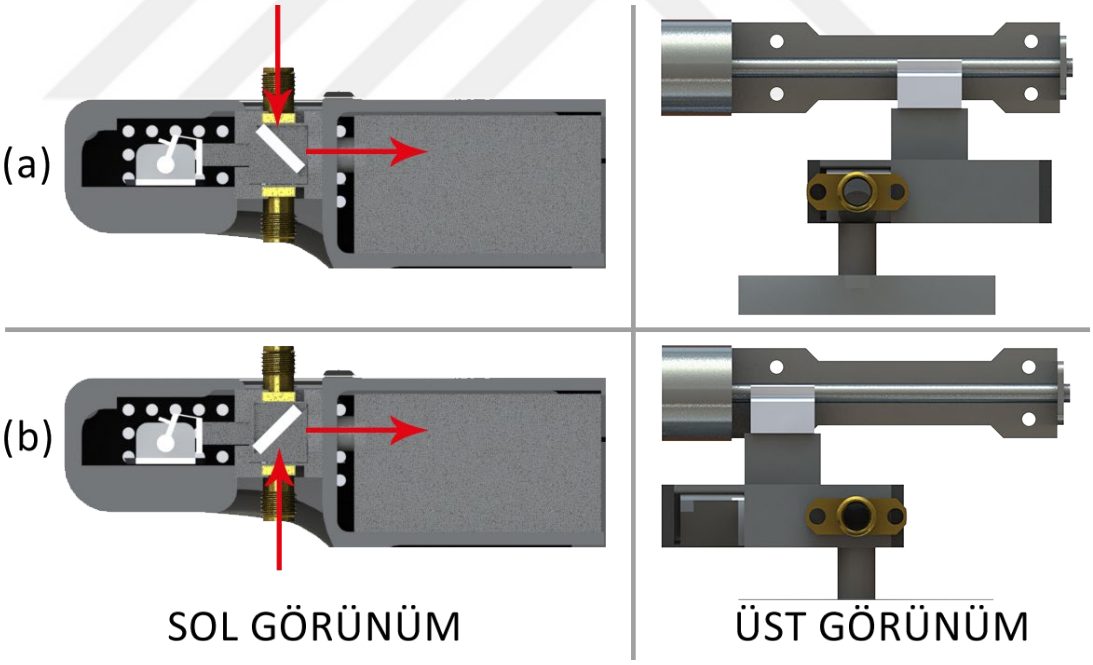
3.1.2. Ayna mekanizması

Spektrometreye ışığın hangi yönden gelmesi gerektiğini ayarlamak için tasarlanmıştır (Şekil 3.5). Güneş ışığını veya topraktan yansıyan ışığı spektrometreye iletebilen bu mekanizma sayesinde yansıma referansı alınabilir.



Şekil 3.5 Ayna mekanizması (Solda: Ayna mekanizması tasarımı, sağda: Cihaz içerisindeki görünüşü)

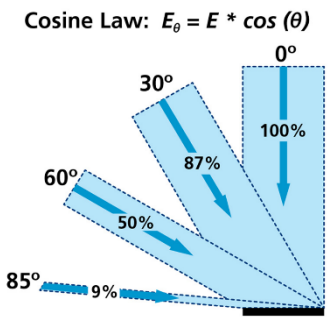
Ayna mekanizması hareketi sağlayan step motor, iki adet 10x10x2mm boyutlarında ayna ve bu aynaları tutan plastik parçadan oluşmaktadır. Step motor aynaları tutan plastik parçaya Şekil 3.5'te göründüğü gibi doğrusal hareket yaptıracak şekilde konumlandırılmıştır. Şekil 3.6'da mekanizmanın güneş ışığını (a) ve topraktan yansıyan ışığı (b) 45 derece açı ile konumlandırılan aynalar ile spektrometreye iletilmesi gösterilmiştir. Üst görünümden de görüldüğü gibi güneş ışığını almak için motorun aynayı sağa ve toprak için de sola hareket ettirmesi gerekmektedir. Spektrometreye ışık girmemesi için ise mekanizma tam ortalanmaktadır. Bu durum spektrometrenin siyah referans alması için düşünülmüştür. Mekanizmanın hangi durumda olduğunu belirlemek için üst görünümden bakıldığında sağda ve solda birer adet mekanik anahtar bulunmaktadır. Siyah referansın alınması için parçanın ortalanması gerekmektedir. Bunun için step motorun soldan sağa gidişi için gereken adım sayısının yarısı kadar hareket ettirilerek mekanizmanın ortalanması sağlanır. Soldan sağa olan adım sayısı her iki yönde bulunan anahtarlar yardımıyla hesaplanmaktadır. Aynanın hareketi mikrodenetleyici ile kontrol edilmektedir.



Şekil 3.6 Ayna mekanizmasının hareketleri

3.1.3. Cosine Corrector

Ayna mekanizmasının güneşe bakan açıklığında güneşin pozisyonunun değişebileceği göz önüne alınarak Ocean Optics firmasının ürettiği Cosine Corrector adlı aparat kullanılmıştır. Bu aparat ışığın geliş yönünden bağımsız bir dağılım (difüzyon) sağlayarak ışığı iletmektedir. Görüş açısı yaklaşık 180 derecedir (Şekil 3.7). Böylece güneş ışınlarını her yönden alabilmektedir. Bu da toprağa gelen ışık hakkında bilgi vermektedir. Alınan bu ışık topraktan alınan ışık için referans olarak kullanılmaktadır. Güneş ışınları alacak şekilde cihazın üst kısmındaki açıklığa takılmaktadır (Şekil 3.8).



Şekil 3.7 Cosine corrector aparatnda gelme açısına göre ışık şiddetinin değişimi

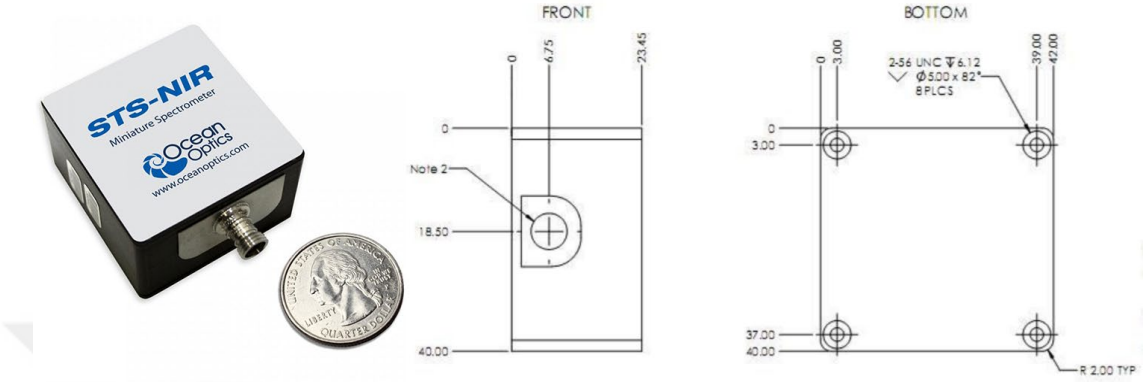


Şekil 3.8 Cosine Corrector aparatı

3.1.4. Spektrometre

Cihazın tasarım amacına uygun olarak 40x42x24mm boyutlarında ve 600-1100nm dalga boyu aralığında ışık spektrumunu 1nm çözünürlükle ölçebilen Ocean

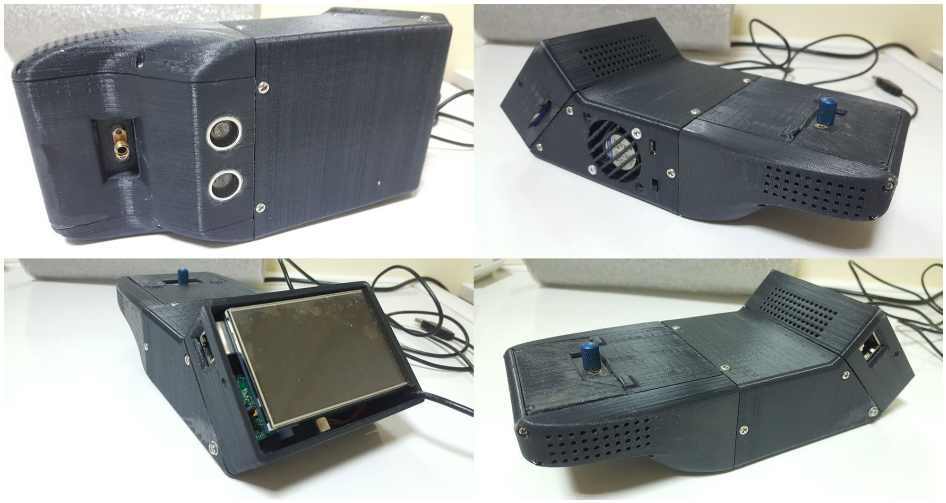
Optics STS NIR model numaralı spektrometre seçilmiştir (Şekil 3.9). Çalışmada toprak ölçümünde kızılötesi ışık spektrumu yöntemi kullanıldığı için spektrometrenin dalgaboyu aralığı belirtildiği gibi seçilmiştir. Spektrometrenin içinde sensör olarak 1024 adet silisyum diyot dizisi bulunmaktadır. Işık giriş yarığı 25 mikrometredir.



Şekil 3.9 Spektrometrenin görünümü ve boyutları

3.1.5. Merkezi kontrol bilgisayarı ve diğer elektronik bileşenler

Cihazın merkezi kontrolü için gömülü sistemlerde ve mobil cihazlarda kullanımı yaygın, tek kartlı bilgisayar olan Raspberry Pi tercih edilmiştir. Küçük yapısından dolayı cihazın boyutunu da küçük tutmaya yardımcı olmaktadır. Şekil 3.2'de görüldüğü gibi bu bilgisayar sistemin tüm kontrolünü sağlar ve veri akışında merkezdedir. Kullanıcı ile olan giriş ve çıkışları köşegen uzunluğu 3.5 inç (8.89mm) olan rezistif dokunmatik LCD sayesinde yapmaktadır. Bu ekran ile SPI haberleşme protokolü kullanarak görüntüyü oluşturur ve kullanıcıdan komutları alır.



Şekil 3.10 Cihazın dış görünüşü

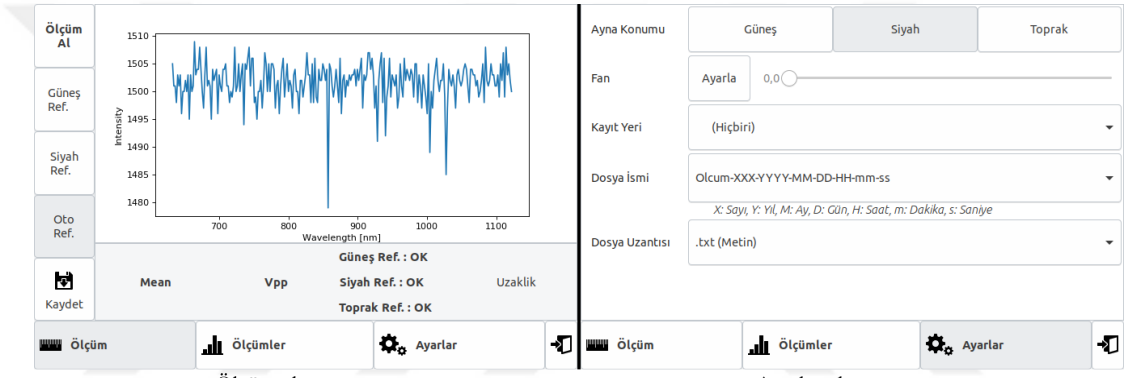
Spektrometre ile USB bağlantısı kullanarak ışık ölçümünü alır. Ayna mekanizmasının motoru, limit anahtarlarını, soğutucu fanı ve ultrasonik uzaklık sensörünü kontrol etmek amacıyla Atmega 328 model numaralı mikrodenetleyiciyi barındıran Arduino Nano kartı kullanılmıştır. Raspberry Pi ile Mikrodenetleyici arasındaki veri alışverişi için UART haberleşme protokolü kullanılmıştır. Ayna mekanizmasının motorunu çalıştırması içi L9110 motor sürücü kartı seçilmiştir. Sistemin taşınabilir olması için arazide güç sağlaması için dâhili lityum iyon batarya eklenmiştir. Bu batarya 3.7 volt gerilim ve 8000mAh kapasiteye sahiptir. Bileşenlerin maksimum güç tüketimi Çizelge 3.2'de verilmiştir. Cihazın bileşenleri sürekli çalışır halde olursa toplamda yaklaşık 9.4 W/saat güç tükettiği anlamına gelir. Batarya 29.6 W/saat güç ürettiğine göre böyle bir senaryoda yaklaşık 3 saat çalışma süresi elde edilir. Pratikte bütün bileşenler maksimum güçte ve aynı anda çalışmadıkları için gerçek çalışma süresi hesaplanan bu süreden daha fazla olur.

Çizelge 3.2 Sistemin bileşenlerinin maksimum güç tüketimi

Bileşen adı	***Maksimum Güç Tüketimi (Watt)***
Spektrometre	0.75 W
Raspberry Pi	3.4 W
Arduino Nano (Atmega 328P)	1W
L9110 Motor sürücü ve step motor	4.25 W
Toplam	***9.4 W***

3.2. Kullanıcı Arayüzü ve Yazılım

Her bilgisayarda olduğu gibi Raspberry Pi için de bir işletim sistemi gerekmektedir. Bu bilgisayara yüklenen işletim sistemi yaygın olarak kullanılan bir Linux işletim sistemi olan Debian tabanlı Raspbian'dır. Sistemin kullanıcı arayüzü ve yazılımı ise Python programlama dili ile yazılmıştır. Yazılımın kaynak kodu eklerde verilmiştir. Kullanıcı arayüzünde Şekil 3.11'de de görüldüğü gibi temel olarak iki ekran bulunmaktadır. İlk açılan ekran olan ölçüm ekranı kullanıcının ölçüm almasını sağlar. Elde ettiği grafiği de aynı ekranda kullanıcıya sunar. Ayarlar ekranında ise kullanıcının cihazı manuel olarak test etme ve dosyaları kaydetme yeri gibi seçenekler bulunmaktadır.



Ölçüm ekranı Ayarlar ekranı

Şekil 3.11 Ölçüm ekranı ve ayarlar ekranı

3.3. Ölçüm ve Kalibrasyon Yöntemi

Bir maddenin üzerine düşen ışığı yansıtma oranına reflektans denir ve denklem (3.1)'de verilen formül ile hesaplanır. Bu denklemde Φ_i gelen ışığın şiddetini Φ_r ise yansıyan ışığın şiddetini belirtmektedir. Toprak örnekleri için reflektans hesaplanırken bağıl reflektans yöntemi kullanılmıştır. Bağıl yansıma oranı hesaplanırken gelen ışınların (Φ_i) direk ölçülmesi yerine ışınlar beyaz referans diye adlandırılan maddenin üzerine düşürülür ve buradan yansıyan ışınlar spektrometre tarafından ölçülür.

Beyaz referans ışınların yaklaşık 95% ve üzerini yansıtabilecek bir maddeden seçilir. Görünür dalga boyu aralığındaki (380-740nm) ve kızıl-ötesi ışınları iyi yansıtır ve beyaz olarak görünür. Yansımanın türü dağınık (diffuse) yansıma olmalıdır. Yani cisim ayna gibi olmamalıdır ve ölçülecek dalgaboyu aralığında çok iyi bir yansıma sağlamalıdır.

$$R_{diffuse} = \frac{\Phi_r}{\Phi_i} \tag{3.1}$$

Beyaz referans alındıktan sonra siyah veya karanlık referans olarak adlandırılan bir ölçüm daha alınması gerekir. Siyah referans spektrometrenin hiç ışık almadan ürettiği sinyali almak için kullanılır. Teoride sistemin hiç ışık almadığı kabul edilir. Ancak pratikte sistem bazı dış etkenlerden ışık sızmaları ile istenmeyen değerler okuyabilir. Bu karanlık referans aynı zamanda bu dış etkenleri elimine etmek için kullanılabilir. Sıfır değer olarak kabul edilir ve denklem (3.2)'de I_{siyah} adında değişken olarak tanımlanmıştır.

$$R_{bağıl} = \frac{I_{toprak} - I_{siyah}}{I_{güneş} - I_{siyah}} \tag{3.2}$$



Şekil 3.12 Beyaz referans kalibrasyonu için ölçüm alınması

Bağıl reflektans denklem (3.2)'de verilen formül kullanılarak her dalga boyu için ayrı ayrı hesaplanır. Denklemde I_{toprak} topraktan yansıyan ışığın şiddetini, $I_{güneş}$ güneşten alınan referans ışığının şiddetini belirtmektedir. Formülde belirtilen $I_{güneş}$ değeri, cosine corrector aparatıyla alının ölçümü temsil eder. Fakat referans için yüzeye beyaz referans yerleştirip bundan yansıyan ışınlar alınmalıdır. Çalışmada

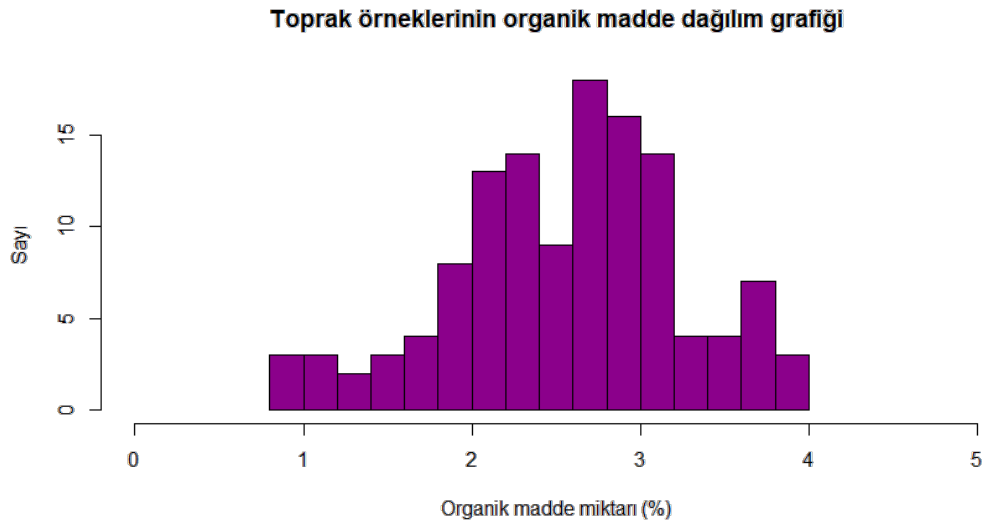
cihazın taşınabilir olması hedeflendiğinden Şekil 3.12'de görünen büyük beyaz referans tabakasının yerine cosine corrector referans almak için kullanılmıştır. Cosine corrector aparatının beyaz referansın yerine geçebilmesi için öncelikle beyaz referans ile kalibre edilmelidir. Kalibrasyonu etkileyen en önemli faktörlerden biri cihazın yüzeye olan uzaklığıdır. Uzaklığa göre alınan ışık miktarı değiştiğinden bu değişimin modellenmesi gerekmektedir.

$$K(h,w) = \frac{R(h,w) - B(h,w)}{C(h,w) - B(h,w)} \tag{3.3}$$

Kalibrasyon modelini üretmek için gereken denklem (3.3)'te verilmiştir. Bu denklemde K, h ve w giriş değişkenlerine bağlı olarak değişen kat sayı fonksiyonudur. Denklemde belirtilen h (cm) cihazın yüzeye olan uzaklığının ve w (nm) dalga boyunun göstergeleridir. R fonksiyonu beyaz referansı; B fonksiyonu daha önce de bahsedilen siyah referansı; C fonksiyonu ise cosine corrector aparatından alınan referansı temsil etmektedir. Beyaz referans ile cosine corector arasındaki oran bu yöntemle bulunmaktadır. Cihazın yere olan uzaklığına göre aradaki oran hesaplandıktan sonra bu ilişki ile genel bir model oluşturmak için eğri uydurma yöntemleri kullanılır. Oluşturulan model daha sonra cihaz ile ölçüm alınmak istendiğinde beyaz referansa gerek kalmadan cosine corrector ile referans alınıp model kullanılarak alınır.

3.4. Toprak Örnekleri ve Ölçüm Yöntemi

Bu çalışmada kullanılan toprak örnekleri Harran Üniversitesi Ziraat Fakültesi Toprak bilimi bölümünün yardımıyla elde edilmiştir. Şanlıurfa'nın Siverek ilçesinden alınan 125 adet toprak örneği bazalt ana materyal üzerinde oluşmuş ve pH olarak nötr özelliktedir. Bu toprak örneklerinin organik madde ve kimyasal özellik analizleri yine aynı bölümün laboratuvarında yapılmıştır. Organik madde miktarları %0.81 ile %3.99 arasında değişmektedir ve dağılım grafiği Şekil 3.13'te verilmiştir.



Şekil 3.13 Toprak örneklerinin organik madde miktarlarının dağılımı

Şekil 3.15'te görüldüğü gibi her bir örnek petri kabında hazırlanıp Şekil 3.14'teki tasarlanan ışık düzeneği kullanılarak toprak örneklerinin reflektans ölçümleri alınır. Şekil 3.15 sol üstte görünen beyaz referans aparatı ile öncelikle referans ışık ölçümü alınır. Daha sonra c kısmında gösterildiği gibi düzeneğin üzerindeki petri kabı kaldırılıp siyah referans alınır. Siyah referans çevresel ışıkların istenmeyen etkisini elemek için alınmaktadır. Daha sonra petri kabına yerleştirilmiş olan örnekten ölçüm alınır.



Şekil 3.14 Işık düzeneği ve 45 derecelik açıyla yerleştirilmiş halojen lamba

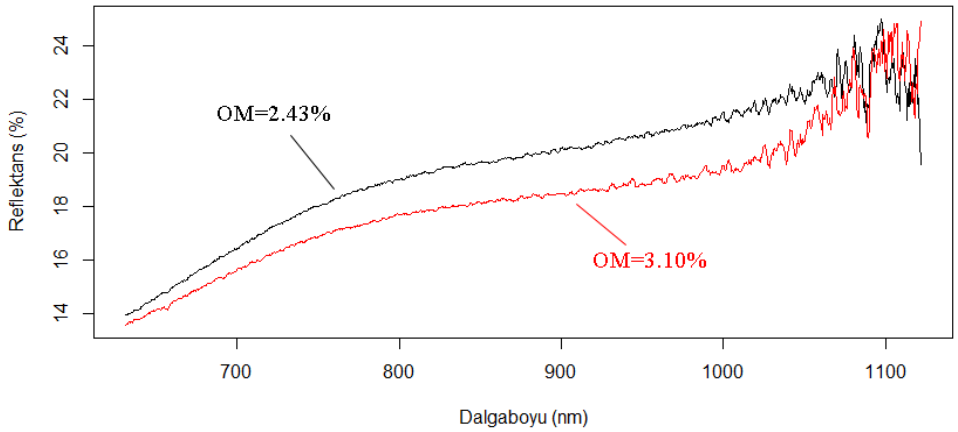
Ölçümler alındıktan sonra denklem (3.2)'de verilen formül ile reflektans değerleri hesaplanır. Aynı zamanda ziraat fakültesine ait ASD Fieldspec markalı spektrometre ile ölçülen değerler daha sonra tasarlanan cihaz ile karşılaştırılır. Böylece ölçümlerin doğruluğu sağlanmış olur.



Şekil 3.15 Toprak örneğinin reflektansının alınması (a: Beyaz referans, b: Referans ölçümü, c: Karanlık referans ölçümü, d: Toprak örneğinin ölçümü)

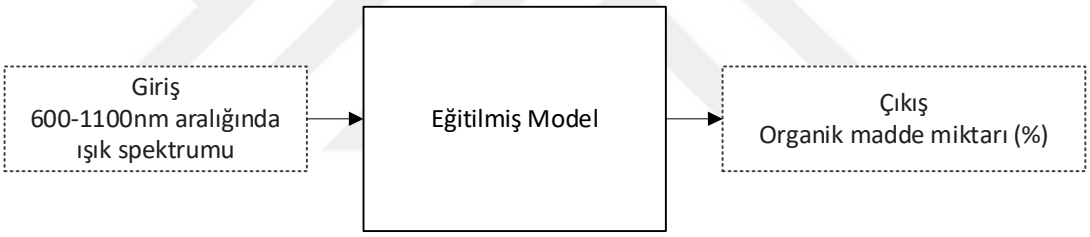
3.5. Veri İşleme ve Makine Öğrenmesi Yöntemleri

Cihazın organik maddeyi tahmin edebilmesi için önceden ölçülmüş ve öğretilmiş bir modelin oluşturulması gerekmektedir. Çalışmada modelin girişi spektral yansıma ölçümlerdir. Şekil 3.16'da organik maddesi farklı iki toprak örneğinin dalga boyuna göre yansıma oranları görünmektedir. Çıkış değerleri ise her bir toprak örneğindeki organik maddenin yüzde oranıdır.



Şekil 3.16 İki farklı toprak örneğinin spektral yansıma ölçümleri

Giriş değişkenleri Şekil 3.17'de görüldüğü gibi birden fazladır. 600-1100nm dalga boyu aralığında 1024 adet nokta vardır ve her biri bir dalga boyunu temsil etmektedir. Çoklu giriş ve tek çıkışa sahip bu modelin eğitilmesi için en uygun algoritma seçilmelidir.



Şekil 3.17 Makine öğrenmesi modeli blok diyagramı

Makine öğrenmesinde birçok algoritma geliştirilmiştir (Smola A. and Vishwanathan, 2010). Bunlar denetimsiz öğrenme, denetimli öğrenme ve takviyeli öğrenme olarak üç ana başlıkta incelenmektedir. Denetimsiz öğrenmede çıkış verileri yoktur. Giriş değişkenleriyle kümeleme yapma yoluyla anlamlı sonuçlar elde edilebilir. Denetimli öğrenmede girişler ve elde edilmesi gereken çıkışlar bilinmektedir. Sınıflandırma ve regresyon yöntemleri, denetimli öğrenme başlığı altında incelenir. Takviyeli öğrenme ise yapılan eyleme karşı verilen ödül ve ceza ile sistemin koşullandırılarak eğitilmesi esasına dayanır. Monte Carlo, Q-Learning ve SARSA algoritmaları yaygın olarak bilinen takviyeli öğrenme yöntemlerindendir.

Cihazda çalışacak model için giriş ve çıkışlar bilindiği için denetimli öğrenme algoritmaları kullanılabilir. Bunlar sınıflandırma ve regresyon olarak iki gruba ayrılmaktadır. Sınıflandırma yöntemlerinde organik maddeyi değer aralıklarına göre çok az, az, orta, iyi, yüksek gibi sınıflara ayırarak model eğitilebilir ve cihaz çıktısına da tahmin ettiği sınıfı aktarabilir. Sınıflandırma yönteminde yaygın olarak kullanılan algoritmalar Naive Bayes, K-Nearest Neighbours (En Yakın Komşu), Decision Tree (Karar Ağacı), Random Forest, Support Vector Machine (Destekçi Vektör Makinesi) dir. Regresyon giriş ve çıkış değişkenleri arasındaki ilişkiyi belirlemeye denir. Regresyon yönteminde zaten yüzdelik olarak belirlendiği için organik madde yani çıkış değişkeninde herhangi bir ön işlem yapmaya gerek yoktur. Giriş değişkenleri de yüzde oranı şeklinde alınan spektral reflektanstan oluştuğu için ölçekleme yapılmamaktadır. Ancak Şekil 3.16'da görünen spektral reflektans ölçümlerinde yumuşatma işlemi yapılabilir. Yumuşatma işlemi işe yaramazsa gürültülü olan kısım silinebilir.

Bu çalışmada MARS (Multivariate Adaptive Regression Splines), PCA/R (Principal Component Analysis/Regression), PLSR (Partial Least Squares Regression) gibi spektral girişlere uygun regresyon algoritmaları kullanılmıştır. Ayrıca makine öğrenme yöntemlerinden biri olan yapay sinir ağları da bu çalışmada kullanılmıştır. Seçilen bu algoritmalar daha önce yapılan ve spektroskopi kullanılan benzer çalışmalarda kullanılmış ve başarılı sonuçlar elde edilmiştir (Gomez et al., 2008; Volkan Bilgili, van Es, Akbas, Durak, and Hively, 2010), (Tonitto and Bilgili, 2016), (Kuang and Mouazen, 2013).

3.5.1. Modellerin değerlendirme ölçütleri

Oluşturulan modellerin doğruluğunu test etmek için birçok ölçüt vardır. R^2, RMSE ve MAE bunlar arasında en çok kullanılan ölçütlerdir. Modeller eğitilirken eldeki veri seti eğitim ve test seti olmak üzere belli bir oranda ayrılır. Genelde eğitim setindeki örnek sayısı test setindeki örnek sayısından fazla seçilir.

Regresyon modelinde Ty_i tahmin edilen, Gy_i ise gerçek değer diyelim. Organik madde oranını temsil eden bu değişkenlerde i indisi toprak örneğinin sıra numarası olarak tanımlanmıştır. Denklem (3.4), (3.5), (3.6) sırayla belirleme katsayısı (R^2),

ortalama mutlak hata (MAE) ve kök ortalama kare hatayı (RMSE) hesaplamak için kullanılan formülleri belirtmektedir. Bu denklemlerde n örnek sayısını temsil etmektedir.

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(Gy_i - Ty_i)^2}{\sum_{i=1}^{n}\left(Gy_i - \frac{\sum_{i=1}^{n} Gy_i}{n}\right)^2} \tag{3.4}$$

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|Gy_i - Ty_i| \tag{3.5}$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(Gy_i - Ty_i)^2} \tag{3.6}$$

Modeller bu ölçütler ile karşılaştırılarak en iyi sonucu veren model cihaz bilgisayarında kullanılabilir.

3.5.2. Spektral verinin ön işlemlerden geçirilmesi

Spektral veriler modelde eğitilmeden önce bazı ön işlemlerden geçirilerek model eğitilebilir. Bu ön işlemler gürültüyü azaltma, sapmayı azaltma ve şekil değiştirmesini sağlayarak daha iyi yorumlanabilir hale getirilebilir. Yumuşatma ve yeniden örnekleme işlemleri veriden gürültünün arındırılmasını sağlamaktadır. Normalizasyon ve şekil değiştirme işlemleri ise spektral verinin başka özelliklerini ortaya çıkarır. Böylece modele verinin direk değeri yerine başka bir özelliği girer. Örneğin türev alınarak verinin noktalar arasındaki artma ve azalma oranı elde edilir. Bu işlemler her uygulamada kullanışlı olmayabilir. Bu nedenle aşağıdaki seçilen işlemler çeşitli kombinasyonlar ile birleştirilip modeller eğitilebilir. Karşılaştırma yaparak da bu uygulama için hangisinin en iyi sonucu vereceği bulunabilir.

Yumuşatma ve yeniden örnekleme:

- Mv, Moving average (hareketli ortalama)

- Bn, Binning (yeniden örnekleme, değişken indirgeme)
- Sg, Savitzky-Golay (Savitzky and Golay, 1964) yumuşatma filtresi

Normalizasyon ve şekil değiştirme:

- Diff, Türev alma
- SgDiff, Savitzky-Golay&Gap-segment türev
- Snv, SNV (Standard Normal Variate, Standart Normal Değişkenliği)
- SnvDe, SNV-Detrend (Barnes, Dhanoa, and Lister, 1989)

3.5.3. Temel bileşen analizi ve regresyonu (PCA, PCR)

Temel bileşen analizi, aralarında yüksek oranda ilişki bulunan giriş değişkenlerini indirgeyerek veya birleştirerek aralarında ilişki bulunmayan daha az sayıda değişkenlere dönüştürür. Böylece birbirine bağımlı olan değişkenleri azaltarak analizde bağımsız yeni değişkenler oluşturup daha yüksek başarı oranı sağlamaktadır. Temel bileşen regresyonu ise oluşturulan yeni değişkenleri kullanarak bir öğrenme modelinin çıkarılmasıdır. Bu modelde giriş değişkenleri artık oluşturulan bu yeni değişkenler olmaktadır.

Bu öğrenme yöntemi genellikle giriş değişkenleri örnek sayısından fazla ise ve aralarında güçlü bir korelasyon varsa tercih edilmektedir (Ni, 2011). PCR'nin temel prensibi şöyle açıklanabilir: PCA kullanarak birbirine bağımlı giriş değişkenleri indirgenir daha sonra sıradan en küçük kareler (OLS) regresyon yöntemi kullanılarak çıkış ve giriş arasındaki ilişki eğitilerek modellenir.

Temel bileşen analizi yönteminde oluşturulacak bileşen sayısı önceden belirlenir. Bileşenler (3.7) ve (3.8) denklemlerindeki gibi x giriş değişkenlerinin türünden hesaplanır. A matrisi bileşenleri hesaplamak için kullanılan kat sayı matrisidir. A matrisi giriş değişkenlerinin birbiri arasındaki korelasyonları ile hesaplanır. Denklemlerde sadece iki bileşen gösterilmiştir. Gerekirse daha fazla bileşen eklenebilir.

$$B_1 = A_{11}x_1 + A_{12}x_2 + \cdots + A_{1n}x_n \quad (3.7)$$

$$B_2 = A_{21}x_1 + A_{22}x_2 + \cdots + A_{2n}x_n \quad (3.8)$$

Görüldüğü gibi çok sayıda olan giriş değişkenleri birkaç bileşene indirgenmiş olur. Bu bileşenler daha sonra denklem (3.9)'da verilen lineer modelde kullanılır. Y çıkış değişkenini (organik madde miktarı), a_i model katsayılarını ve B_i ise bileşen değerini temsil etmektedir. Katsayılar daha önce belirtildiği gibi en küçük kareler yöntemi kullanılarak hesaplanır ve model eğitilir.

$$Y = a_0 + a_1 B_1 + a_2 B_2 + \cdots + a_n B_n \tag{3.9}$$

3.5.4. Kısmi en küçük kareler regresyon (PLSR)

PLSR yöntemi de PCR yöntemi gibi giriş değişkenleri arasında yüksek korelasyon olması ve giriş değişkenlerinin örnek sayısından fazla olması durumlarında kullanılmaktadır. NIR spektroskopide bu yöntem sıklıkla kullanılmaktadır. PLSR yöntemi PCR yönteminin geliştirilmiş hali olarak düşünülebilir. Kısmi en küçük kareler yöntemi Herman Wold tarafından 1966 yılındaki makalede bahsedilmiştir (Wold, 1966).

PCR yönteminde bileşenler hesaplanırken sadece giriş değişkenlerinden yararlanılır. Bu çıkış değişkeninin bileşenler ile alakasız olması sorununu ortaya çıkarmaktadır. PLSR yöntemi bu soruna bir çözüm getirme amacıyla geliştirilmiştir. X (giriş) ve Y (çıkış) değişkenleri (3.10) ve (3.11) denklemlerinde gösterildiği gibi temel bileşenlerine dönüştürülür. T ve U bileşen katsayıları matrisleri, P ve Q giriş çıkış değişkenlerini temsil eden dönüştürülmüş değerler matrisleri, E ve F ise hata matrisleridir. Matrisler oluşturulduktan sonra denklem (3.12)'de bulunan R korelasyon sabitleri matrisi U ve T matrisleri arasındaki ilişkiyi en iyi şekilde açıklayacak şekilde hesaplanır.

$$X = TP^{Transpoz} + E \tag{3.10}$$

$$Y = UQ^{Transpoz} + F \tag{3.11}$$

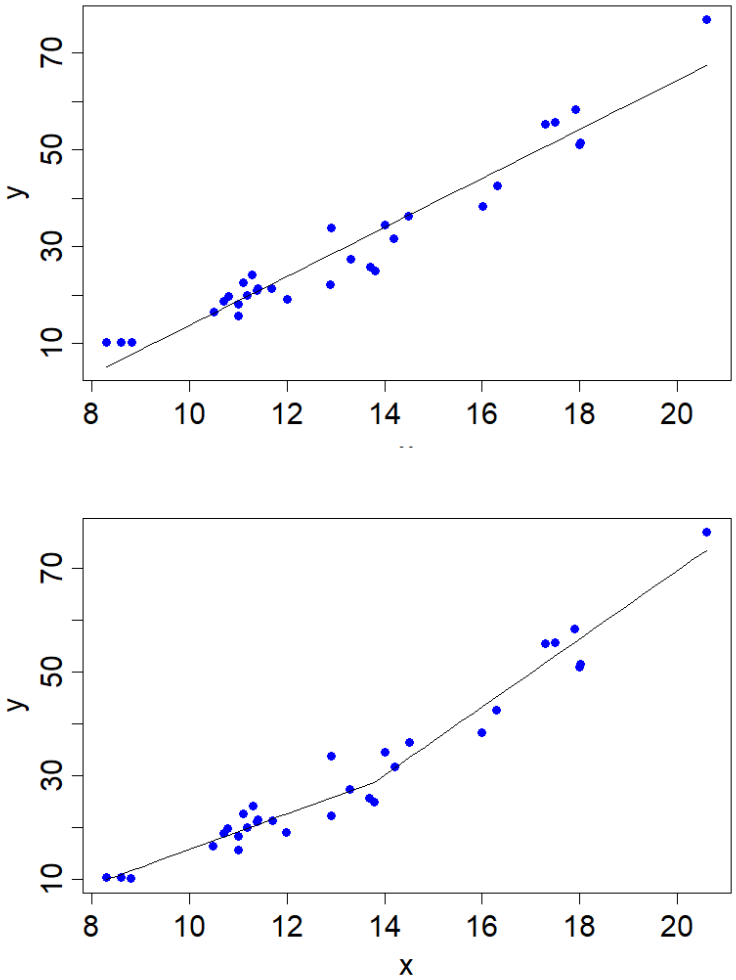
$$U = RT \tag{3.12}$$

Böylece hem giriş hem de çıkış değişkeni kullanılarak bileşenler tespit edilmiş olup model eğitilebilir.

3.5.5. Çok değişkenli uyarlanabilir regresyon eğrileri (MARS)

Giriş değişkenleri ile çıkış değişkenleri arasında her zaman doğrusal ilişkiler olmayabilir. MARS algoritması bu tür problemlerde kullanılabilir. Aynı zamanda önemli değişkenleri ve önemsiz değişkenleri ayırabilir. PLSR gibi MARS yöntemi de spektroskopide analiz yapmak için kullanılan yöntemlerdendir. 1991 yılında Jerome Friedman tarafından doğrusal regresyon yöntemlerine alternatif olarak geliştirilmiştir (Jerome H Friedman, 1991). Veri setinde giriş ve çıkışlar arasındaki ilişkiyi birden fazla doğrusal ilişki olarak modellemektedir.

Şekil 3.18'de üstte klasik doğrusal yöntem ile modelleme yapılırken altta MARS yöntemi kullanılarak daha açıklayıcı bir model elde edilmiştir.

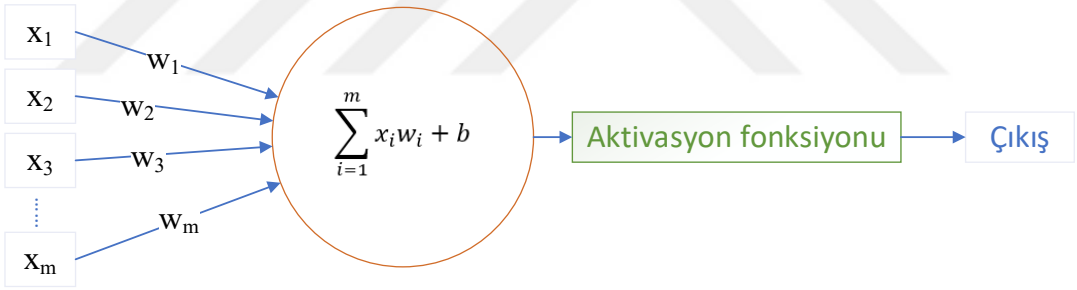


Şekil 3.18 Klasik doğrusal modelleme ve MARS modeli (J H Friedman, 1993)

3.5.6. Yapay sinir ağları (ANN)

Canlılardaki sinir sistemini örnek alan bu yöntem, sinir sisteminin öğrenme ve adapte olma özelliğini kullanır. Sinir sisteminde bulunan nöronlar sinyal alıp iletmede görevli hücrelerdir. Yapay sinir ağlarında da nöronlar birbirine bağlanarak veri akışını sağlarlar. Bu yöntemin temelleri Warren McCulloch ve Walter Pitts tarafından 1943 yılında atılmıştır (McCulloch and Pitts, 1943).

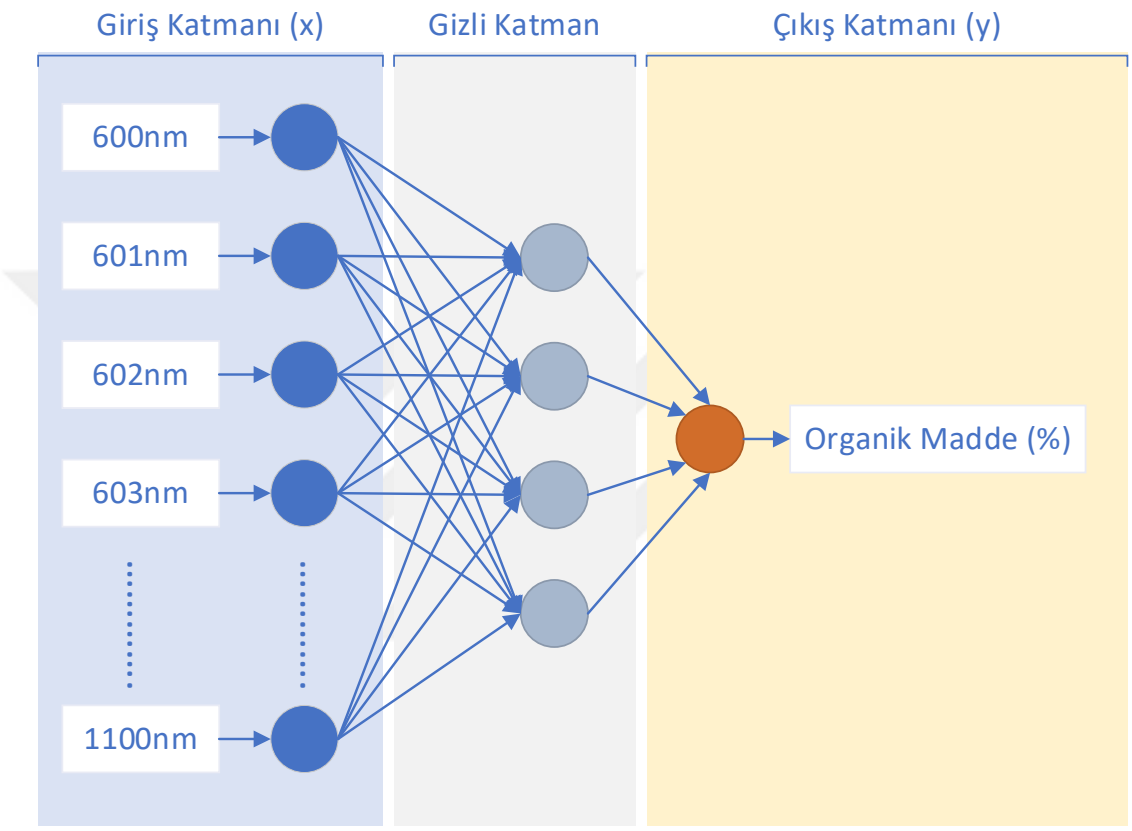
Yapay sinir ağında bir nöronun matematiksel modeli Şekil 3.19'da verilmiştir. Buna göre giriş sinyalleri (x_i) belirli ağırlıklarla (w_i) çarpılıp toplandıktan sonra sapma miktarı (b) eklenir. Daha sonra aktivasyon fonksiyonundan geçirilir. Bu aktivasyon fonksiyonu istenilen çıkışa göre değişmektedir. Genellikle kullanılan fonksiyonlar lineer, basamak, sigmoid ve tanh'dir. Aktivasyon fonksiyonu aynı zamanda çıkışın limitini de belirler. Sınıflandırma problemlerinde çıkış 0 veya 1 alırken regresyon analiz problemlerinde 0 ve 1 arasındaki değerleri de alabilecek fonksiyonlar seçilir.



Şekil 3.19 Yapay nöronun matematiksel modeli

Yapay sinir ağlarının da diğer yöntemler gibi eğitilmesi gerekmektedir. ANN'nin eğitilmesi için birçok algoritma geliştirilmiştir. Bunların başında geri yayılım (backpropagation) algoritması gelir. Başlangıçta yapay sinir ağı rastgele veya belirli ağırlıklarla ve özelliklerle (aktivasyon fonksiyonları, nöron sayıları, sapma miktarları vb.) oluşturulur. Hazırlanan eğitim veri setinde girişler nöronlara verilir hesaplamalar yapıldıktan sonra çıkışta gözlemlenen değer ile olması gereken çıkış değeri arasındaki hataya göre mevcut ağırlıklar değiştirilir. Bu süreç hata kabul edilebilir bir değere düşene kadar devam eder. Böylece sinir ağı eğitilmiş olur.

Şekil 3.20'de çalışmada kullanılan veri setinin yapay sinir ağı yöntemine uygulanması blok diyagramı şeklinde verilmiştir. Giriş katmanında giriş değişkeni kadar nöron bulunmaktadır. Gizli katmandaki nöron sayıları rastgele belirlenmiştir. En iyi sonucu verecek şekilde model güncellenebilir. Çıkış katmanında ise çıkış değişkeni olarak sadece organik madde olduğu için tek bir nöron bulunmaktadır.



Şekil 3.20 Yapay sinir ağı modelinin blok diyagramı

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

4.1. Cihazın Kullanımı ve Ölçüm Yazılımı

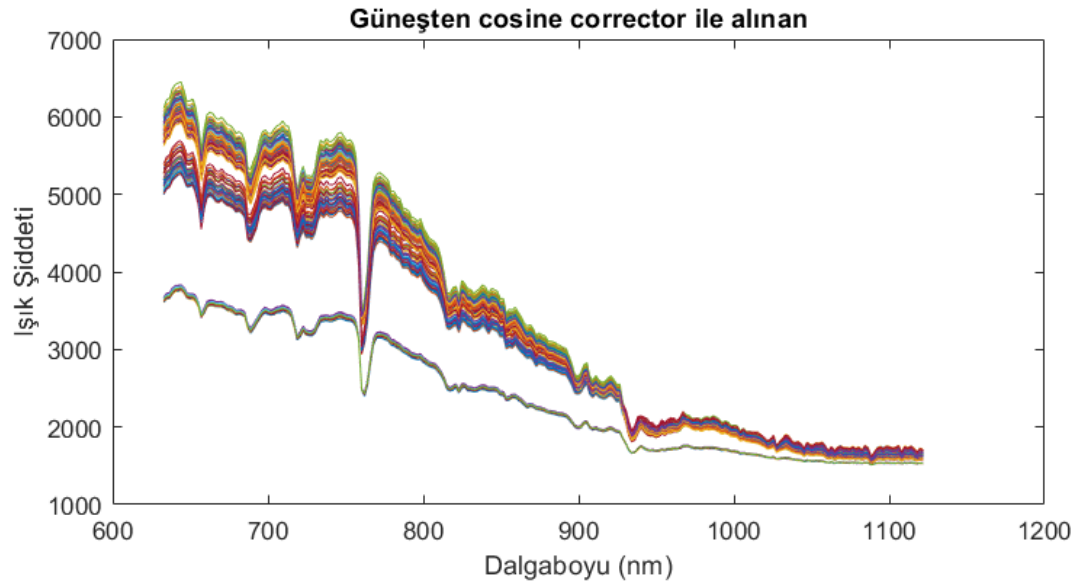
Sahada ölçüm almak için tasarlanan sistemin laboratuvar şartlarında da kullanılabilir olduğu tespit edilmiştir. Petri kaplarında hazırlanan toprakların tasarlanan ışık düzeneği reflektans ölçümlerinin alınabilir olduğu gözlemlenmiştir. Cihaz içerisinde bulunan ayna mekanizması istenildiği gibi çalışmakta ve her iki yönden de ışığı spektrometreye iletebilmiştir. Kullanıcı ara yüzünün kullanılan LCD ekranın rezistif dokunatik panel olması nedeniyle dokunma ile komut vermeyi biraz kısıtladığı görülmüştür.

Raspberry Pi'nin spektrometre ile olan bağlantısı için PHP programlama dilinde bir web ara yüzü yazılmıştır. Bu program spektrometre ile USB üzerinden komut göndererek spektrometrenin yanıt olarak ışık verilerini göndermesini sağlamaktadır. Gelen verileri çıktıya göndererek istenilen yerde kullanılmasını sağlamaktadır.

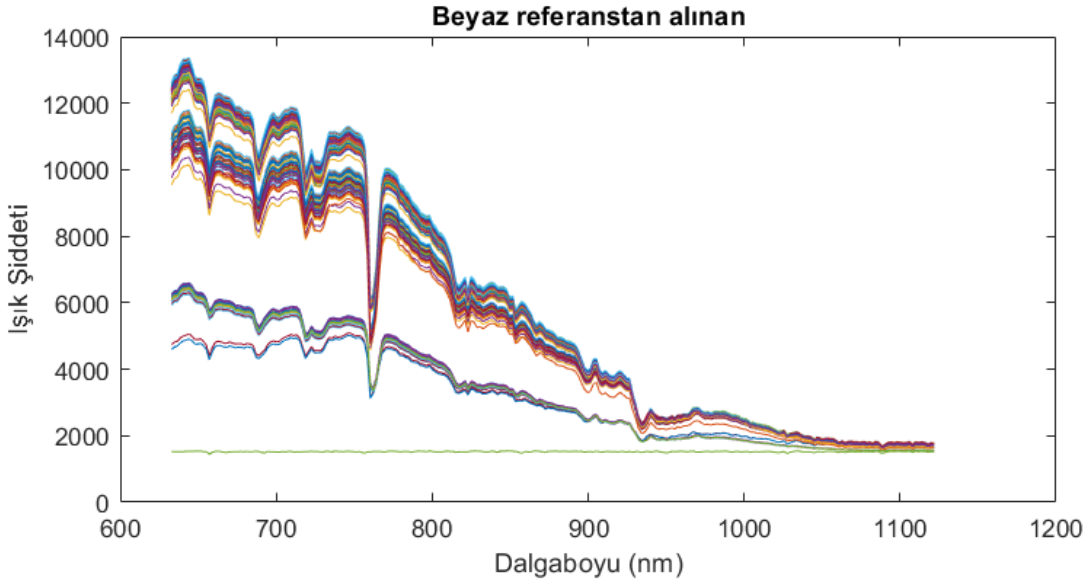
Spektrometre ile bağlantı kuran web ara yüzünden verileri alabilmesi için Python3 programlama dilinde program yazılmıştır. Aynı zamanda LCD ekran için kullanıcı ara yüzü de bulundurmaktadır.

4.2. Kalibrasyon Modeli

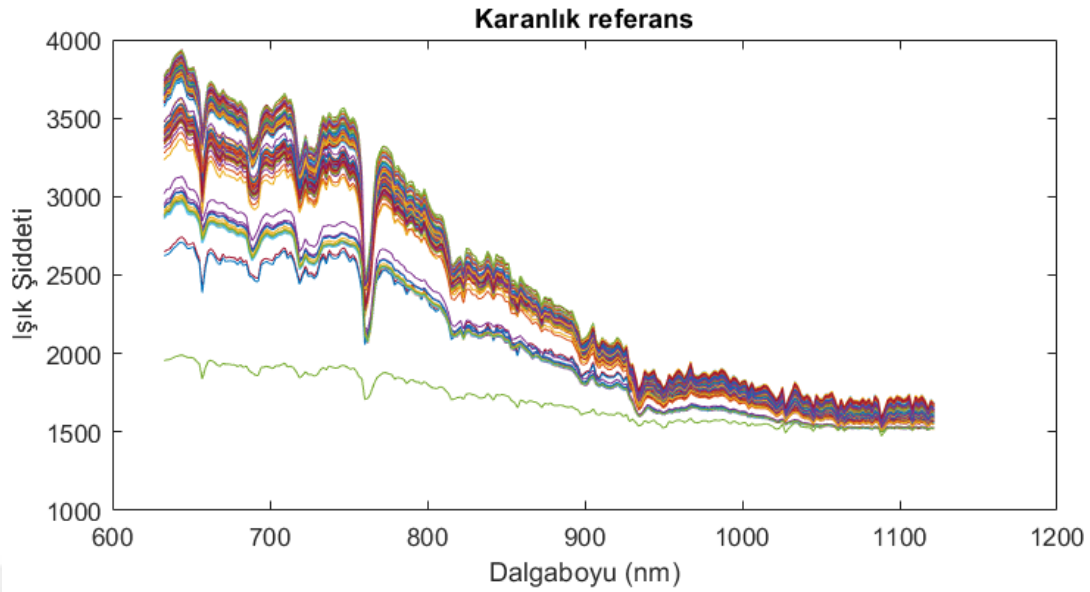
Kalibrasyon için çeşitli yüksekliklerden ve farklı güneş ışığı koşullarında toplamda 139 ölçüm alınmıştır. Güneşten (cosine corrector ile) alınan, baryum sülfat kaplanmış tabakadan yansıyan ışıktan alınan ölçümler ve karanlık referans sırayla Şekil 4.1, Şekil 4.2 ve Şekil 4.3'te verilmiştir. Ek 1'de verilen MATLAB kodu ile veriler hazırlanmış ve kalibrasyon için hazır hale getirilmiştir.



Şekil 4.1 Kalibrasyon için cosine corrector kullanılarak güneşten alınan ölçümler

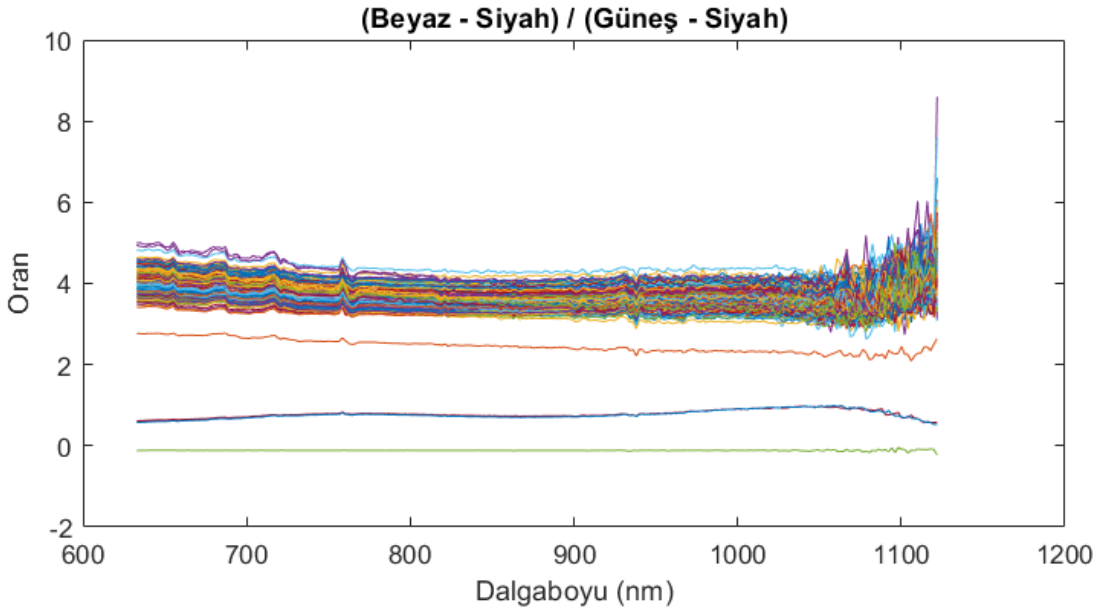


Şekil 4.2 Beyaz referans için baryum sülfat kaplı tabakadan alınan ölçümler



Şekil 4.3 Karanlık referans için alınan ölçümler

Ölçülen bu üç sinyal denklem (3.3)'te verilen formülde yerine konulduğunda Şekil 4.4'teki sonuç elde edilmiştir. Güneş, beyaz referans ve siyah referans ölçümlerinde görünen kümelenme değişik güneş ışığı koşullarından kaynaklanmaktadır. Bazı ölçümlerde ışık açısı gün içerisinde zamanla değişmiştir. Buna rağmen reflektans denklemi (kalibrasyon denklemi) (3.3) kullanıldığında ortaya çıkan oranın sabit olduğu gözlenmiştir (Şekil 4.4).

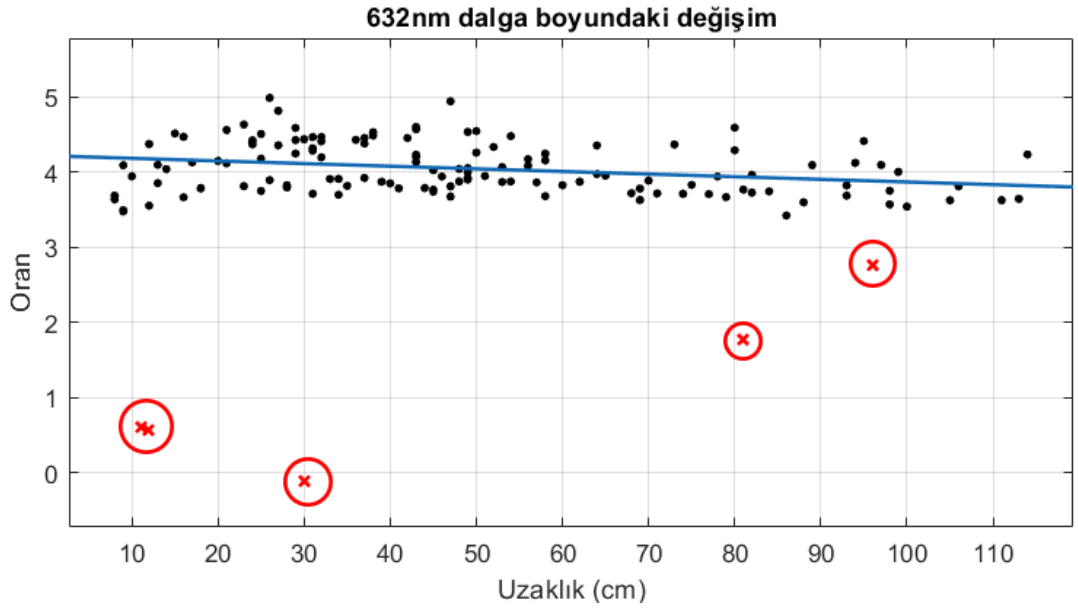


Şekil 4.4 Ölçümlerin denklemde kullanılmasıyla ortaya çıkan sonuç

632 nm dalga boyundaki uzaklığa bağlı olarak değişen reflektans oranı Şekil 4.5'te görülmektedir. Çember içine alınan ölçümler ekstrem noktalar olarak belirlenmiş olup modele dahil edilmemiştir. Bu noktalar ölçümlerin düzgün bir şekilde alınmadığını temsil etmektedir. Polinom doğrusal küçük kareler eğri uydurma yöntemi ile şekilde görünen çizgi ile model oluşturulmuştur. Denklem (4.1)'de bu modelin fonksiyonu yer almaktadır.

$$f(x) = -0.003504x + 4.221 \quad (4.1)$$

Oluşturulan model sadece 632 nm dalga boyu için geçerlidir. Aynı şekilde bu model bütün dalga boyları için çıkarılmıştır. Kalibrasyon modeli için Ek 2'de kullanılan MATLAB kodu kullanılmıştır. Uzaklık değişiminin reflektans değerine olan etkisi çok az olarak gözlenmiştir. Bunun nedeni toprak kısmına bakan açıklığın görüş alanının uzaklığa bağlı olarak çok az değişmesidir.

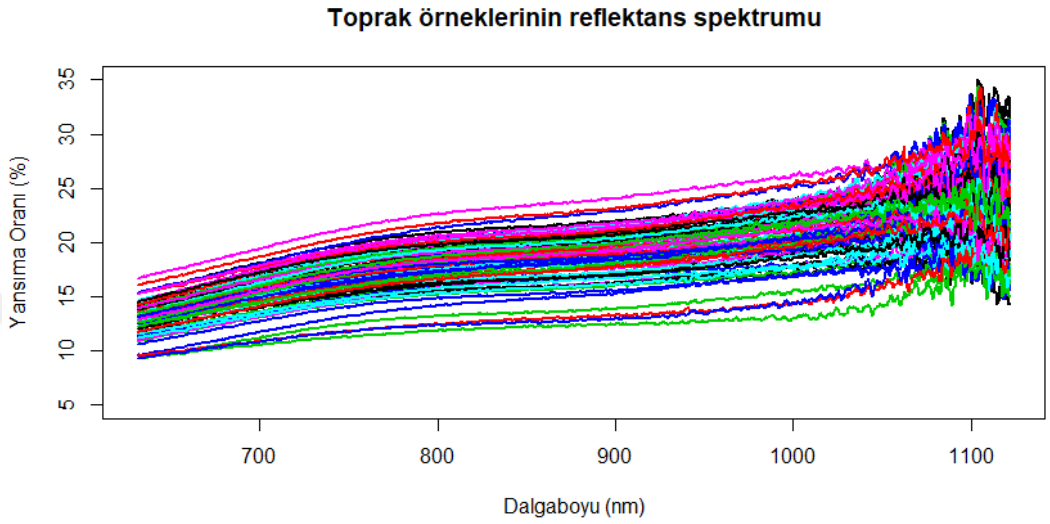


Şekil 4.5 Uzaklığa göre 632 nm dalga boyundaki yansıma oranının değişimi

Cosine corrector aparatından alınan değerin gerçek beyaz referanstan alınan değere oranı 632 nm dalga boyu için yaklaşık olarak 0.23 olduğu görünmektedir. Sahada ölçüm alınırken elde edilen toprak reflektans değerini 632 nm için bu modeldeki fonksiyon kullanılarak bulunan oran ile çarpılarak gerçek reflektans değeri bulunmuş olur. Aynı işlem tüm dalga boyları için yapılmıştır.

4.3. Toprak Örneklerinin Spektral Ölçümleri

Toprak örnekleri petri kabında hazırlanıp ışık düzeneği ile spektral ölçümleri alınmıştır. Elde edilen reflektans grafiği Şekil 4.6'da verilmiştir. Şekilde görüldüğü gibi organik maddeleri farklı toprak örneklerinin reflektans ölçümleri de farklıdır.

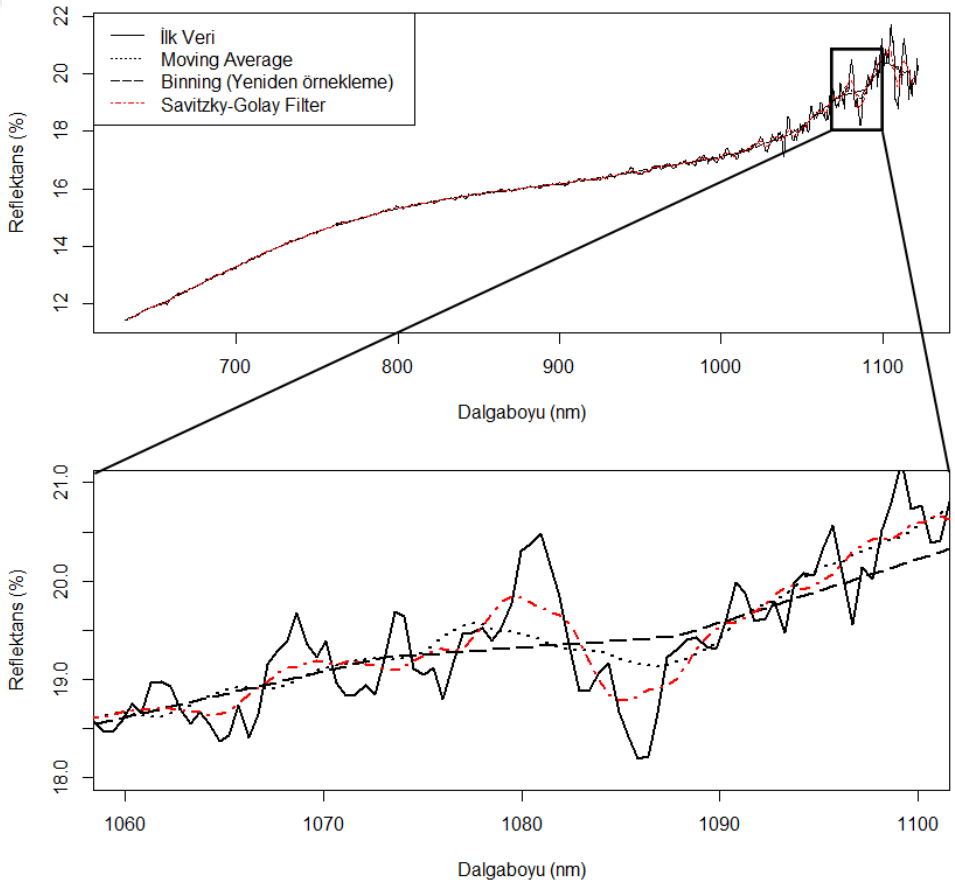


Şekil 4.6 Toprak örneklerinin reflektans spektrumu

Alınan spektral ölçümlere materyal ve yöntemler bölümünde belirtilen yumuşatma ve yeniden örnekleme yöntemleri uygulanmış olup Şekil 4.7'de örneği görünmektedir. Model eğitimlerinde kullanılan yöntem kombinasyonları Çizelge 4.1'de verilmiştir. İşlem yapılmayan ve sadece yumuşatma kullanılan önişlem haricinde diğer önişlemlerde yeniden örnekleme yapılarak dalga boyu sayısı 256'ya düşürülmüştür. Spektrometreden elde edilen 1024 dalga boyu değeri spektrometrenin hassasiyeti nedeniyle küçük çaplı gürültüler içerdiğinden önişlem yapılarak bu sayı düşürülmüştür.

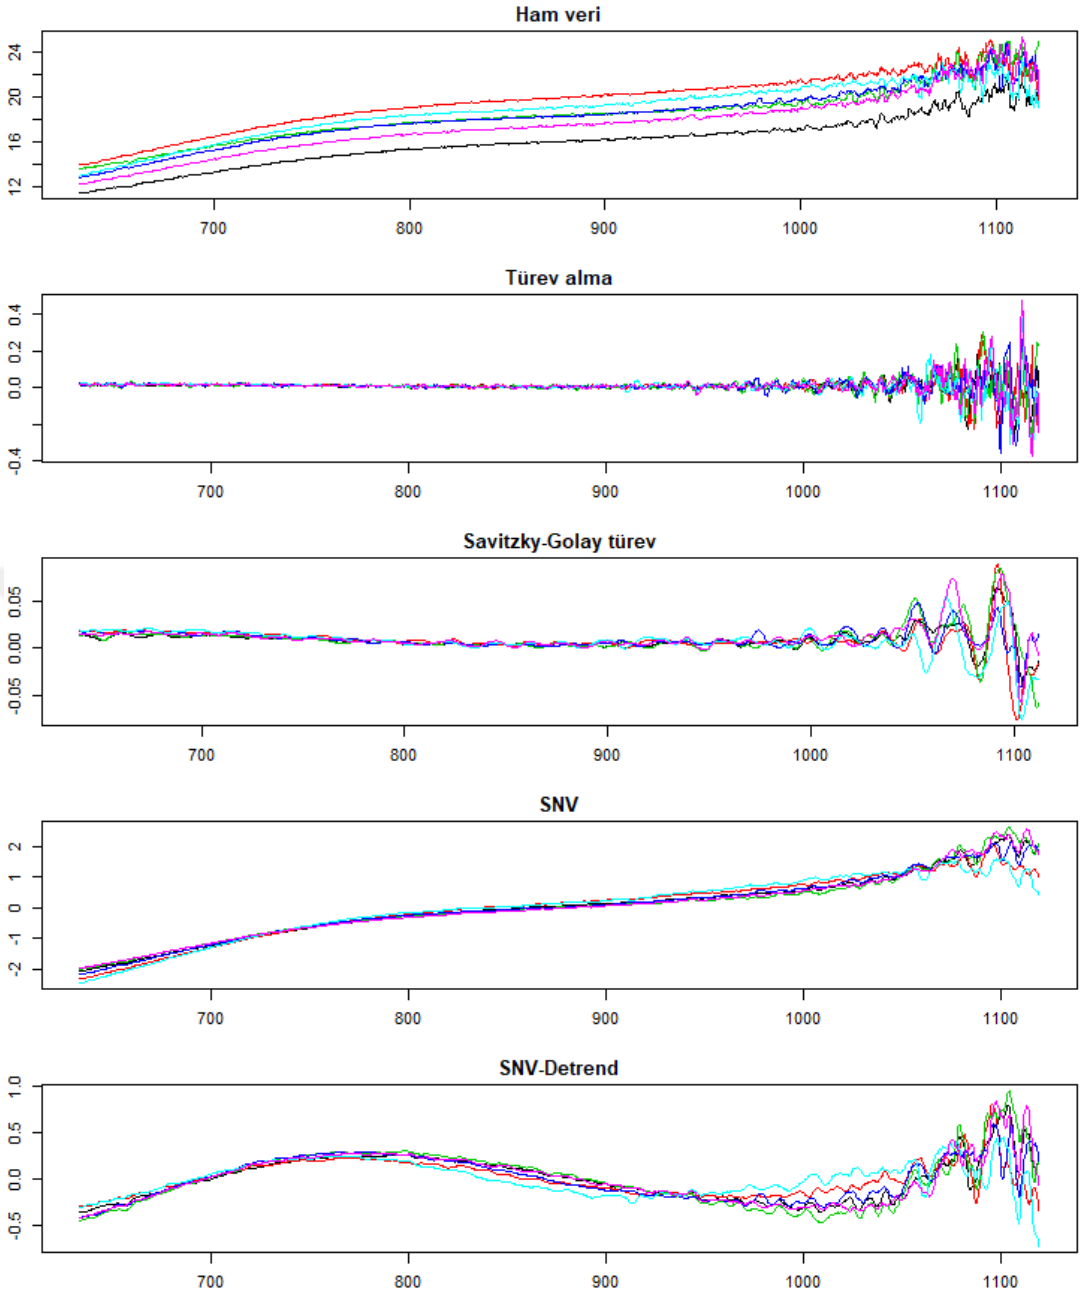
Çizelge 4.1 Spektral veriye yapılan ön işlemler ve işlem sonrası değişken sayısı

İşlem No	*İşlemler*	*Değişken Sayısı*
1	İşlem yok (Ham reflektans verisi)	1024
2	Mv	1024
3	Bn	256
4	Mv > Bn	256
5	Sg > Bn	256
6	Mv > Diff > Bn	256
7	Mv > SgDiff > Bn	256
8	Mv > Snv > Bn	256
9	Mv > SnvDe > Bn	256
10	Mv > Bn > SgDiff	256
11	Mv > Sgdiff > SnvDe > Bn	256



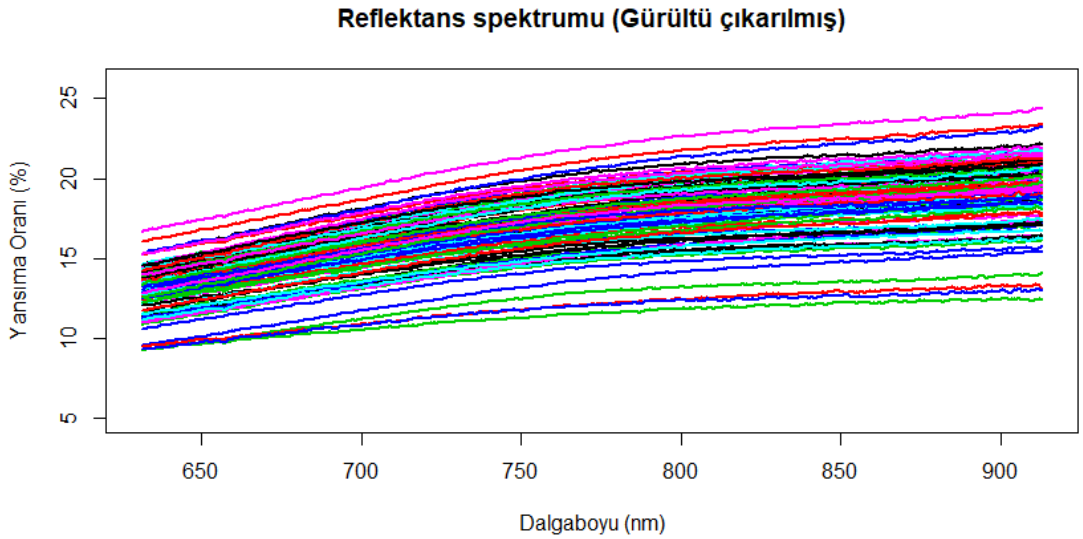
Şekil 4.7 Bir toprak örneğine ait reflektans verisi ve yumuşatma yöntemleri uygulanmış hali

Altı adet toprak örneğine ait spektrum verisinin normalizasyon ve şekil değiştirme ön işlemlerinden geçirilmiş hali Şekil 4.8'de verilmiştir.



Şekil 4.8 Normalizasyon ve şekil değiştirme işlemleri uygulanmış örnek spektrum

Ölçümlerde spektrometrenin hassasiyetinden kaynaklı olarak 915nm dalga boyundan itibaren reflektansın gürültülü olduğu tespit edilmiştir. Yukarıda anlatılan yumuşatma yöntemleri kullanılmıştır. Ancak model eğitilirken gürültülü kısmına istenmeyen bir şekilde anlam yüklenebilir ve sonuçlar bunlardan etkilenebilir. Bu nedenle spektrumun 987 nm'den sonraki kısmı çıkarılarak aynı işlemler uygulanmıştır (Şekil 4.9).



Şekil 4.9 Reflektans spektrumunun gürültülü kısmın çıkarılmış hali

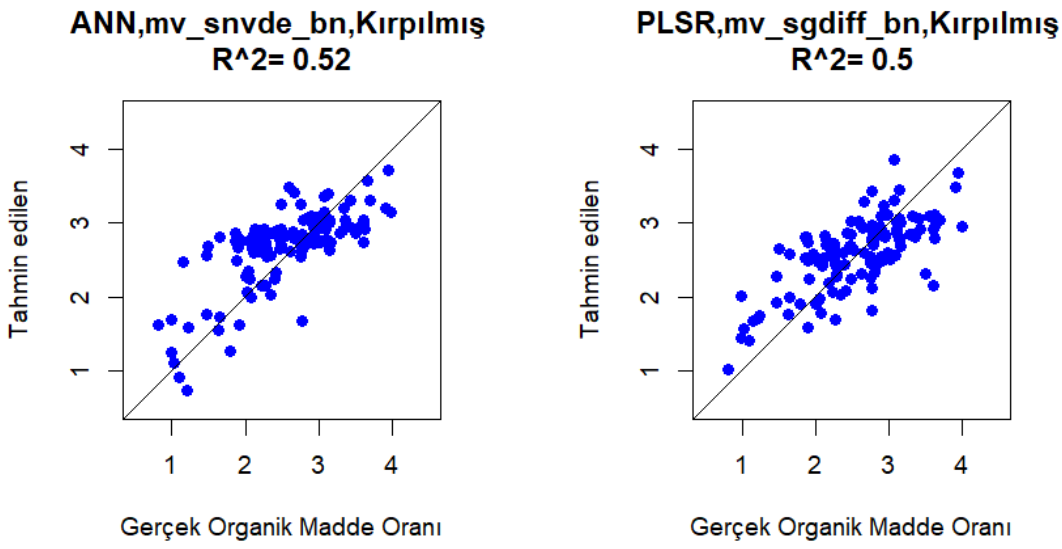
4.4. Makine Öğrenmesi Modellerinin Oluşturulması

Veriler Ek 3'te yer alan tablodaki yöntemler kullanılarak ön işlemlerden geçirilmiştir. Bunun sonucunda toplam 11 adet yeni giriş seti elde edilmiştir. Yapılan işlemler aynı zamanda gürültülü kısımlar çıkarıldıktan sonra yeniden uygulanmıştır. Toplamda 22 adet spektrum girişi ve 4 farklı regresyon yöntemi kullanılarak 88 adet model elde edilmiştir. Veri setinin %75'i eğitim, %25'si test amacıyla ayrılmıştır. Yani 96 adet toprak örneği eğitim, 29 adet toprak örneği test için ayrılmıştır. Eğitim veri seti ile modeller eğitilmiş olup daha sonra test veri seti ile bu modeller test edilmiştir. Bütün işlemler istatistik için uygun olan R programlama dilinde yapılmıştır. Ek 3'te eğitilen tüm modellerin eğitim performansları ve test performansları verilmiştir. Çizelge 4.2'de ise en iyi performans ölçütlerine sahip 12 model listelenmiştir.

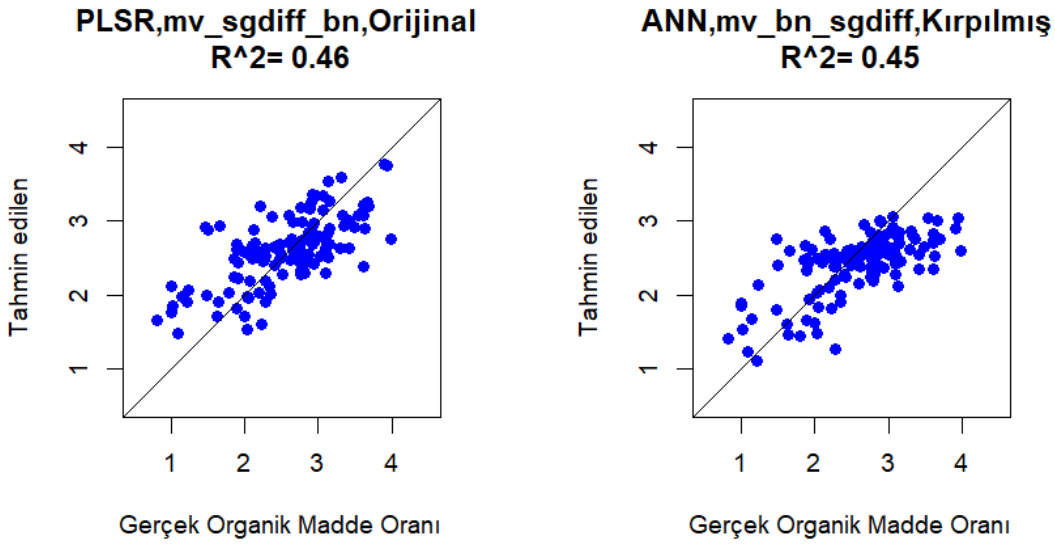
Çizelge 4.2 R^2 ölçütüne göre en iyi 12 eğitim modelinin performans ölçütleri

				R^2		RMSE		MAE	
Metot	***No***	***Veri Türü***	***Önişlem***	***Eğitim***	***Test***	***Eğitim***	***Test***	***Eğitim***	***Test***
PCR	7	Orijinal	mv_sgdiff_bn	0.420	0.281	0.522	0.677	0.432	0.528
PCR	21	Kırpılmış	mv_bn_sgdiff	0.411	0.531	0.509	0.555	0.413	0.442
PCR	3	Orijinal	bn	0.411	0.173	0.540	0.741	0.424	0.572
PLSR	18	Kırpılmış	mv_sgdiff_bn	0.424	0.360	0.526	0.627	0.437	0.517
PLSR	7	Orijinal	mv_sgdiff_bn	0.415	0.364	0.529	0.645	0.436	0.528
PLSR	1	Orijinal	Ham veri	0.399	0.164	0.547	0.739	0.465	0.601
MARS	5	Orijinal	sg_bn	0.376	0.362	0.565	0.623	0.475	0.503
MARS	18	Kırpılmış	mv_sgdiff_bn	0.369	0.409	0.539	0.622	0.437	0.486
MARS	7	Orijinal	mv_sgdiff_bn	0.368	0.410	0.539	0.622	0.436	0.486
ANN	20	Kırpılmış	mv_snvde_bn	0.461	0.450	0.524	0.607	0.421	0.489
ANN	21	Kırpılmış	mv_bn_sgdiff	0.392	0.458	0.536	0.641	0.421	0.490
ANN	10	Orijinal	mv_bn_sgdiff	0.388	0.494	0.541	0.588	0.440	0.436

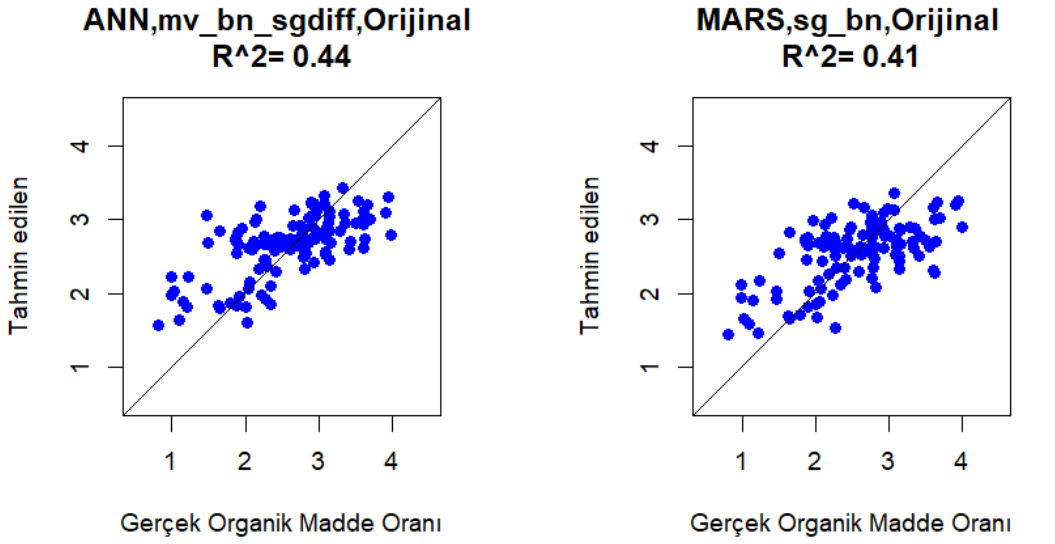
Eğitilen 88 model arasından en iyi sonucu veren 8 adet modelin gerçek organik madde ve tahmin edilen organik madde arasındaki ilişkiyi gösteren grafikler Şekil 4.10, Şekil 4.11, Şekil 4.12 ve Şekil 4.13'te verilmiştir.



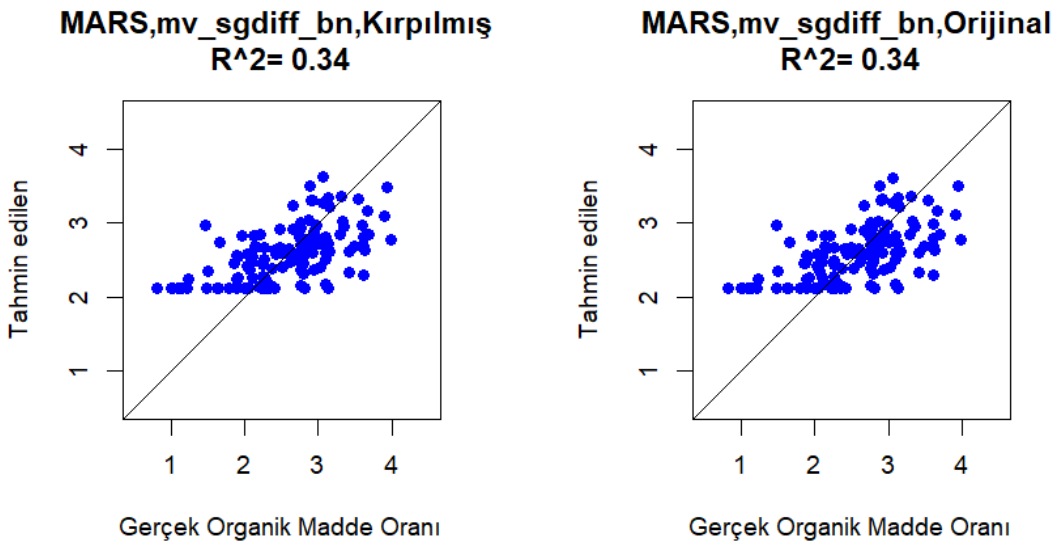
Şekil 4.10 En iyi sonucu veren birinci ve ikinci modelin tahmin ve gerçek değer ilişkisi



Şekil 4.11 En iyi sonucu veren üçüncü ve dördüncü modelin tahmin ve gerçek değer ilişkisi



Şekil 4.12 En iyi sonucu veren beşinci ve altıncı modelin tahmin ve gerçek değer ilişkisi



Şekil 4.13 En iyi sonucu veren yedinci ve sekizinci modelin tahmin ve gerçek değer ilişkisi

5. SONUÇLAR ve ÖNERİLER

5.1. Sonuçlar

Proje kapsamında yapılmış olan cihaz laboratuvar koşullarında test edilmiştir. Gerekli kalibrasyondan sonra eğitilen modellerden sırayla yapay sinir ağları, PLSR ve MARS yöntemleri en iyi sonucu vermiştir. Çizelge 5.1'de bu modeller R^2 ölçütü büyükten küçüğe sıralanmış hali listelenmiştir.

Çizelge 5.1 En iyi sonucu veren 8 adet modelin performansları

				R^2		*RMSE*		*MAE*	
Metot	***No***	***Veri Türü***	***Önişlem***	***Eğitim***	***Test***	***Eğitim***	***Test***	***Eğitim***	***Test***
ANN	20	Kırpılmış	mv_snvde_bn	0.461	0.450	0.524	0.607	0.421	0.489
PLSR	18	Kırpılmış	mv_sgdiff_bn	0.424	0.360	0.526	0.627	0.437	0.517
PLSR	7	Orijinal	mv_sgdiff_bn	0.415	0.364	0.529	0.645	0.436	0.528
ANN	21	Kırpılmış	mv_bn_sgdiff	0.392	0.458	0.536	0.641	0.421	0.490
ANN	10	Orijinal	mv_bn_sgdiff	0.388	0.494	0.541	0.588	0.440	0.436
MARS	5	Orijinal	sg_bn	0.376	0.362	0.565	0.623	0.475	0.503
MARS	18	Kırpılmış	mv_sgdiff_bn	0.369	0.409	0.539	0.622	0.437	0.486
MARS	7	Orijinal	mv_sgdiff_bn	0.368	0.410	0.539	0.622	0.436	0.486

Spektral veriye uygulanan önişlemlerin tahmin sonuçlarına katkısı fazla olmuştur. Önişlemler içerisinde mv_sgdiff_bn (hareketli ortalama > sg-türev > yeniden örnekleme) ve mv_snvde_bn (hareketli ortalama > snv-detrend > yeniden örnekleme) yöntemleri sonuca en çok katkı verenlerdir. Orijinal ve gürültüsü kırpılmış verinin de sonuçlara etkisi olmuştur. Dolayısıyla spektral ölçümlerde yumuşatma ve şekil değiştirme işlemlerinin önemli olduğu ortaya çıkmaktadır.

Elde edilen kalibrasyon modelleri ile toprak organik maddesinin uzaktan ölçümünün mümkün olduğu görülmüştür. Çalışmada karşılaşılan en önemli sorun, maddi kaynak ve zaman yetersizliğinden dolayı sahada ölçüm alınamamasıdır. Bu nedenle çalışmada laboratuvar koşullarında yapay ışık kaynağı ile eldeki toprak örneklerinden ölçümler alınmıştır. Toprak örneği sayısının ve özelliklerinin limitli olması da sonuçlara olumsuz yönden etki etmiştir.

5.2. Öneriler

Cihazın daha kullanışlı olabilmesi için birkaç geliştirme yapılabilir. Elde taşımanın daha kolay olabilmesi için cihaz şasesi yeniden tasarlanabilir. LCD ekran parlaklığının güneş ışığı altında yetersiz kaldığı için gölgeleme için aparat takılabilir. Cihaz sahada kullanılmak üzere tasarlandığından daha sonraki çalışmalarda GPS modülü eklenerek ölçülen konum kaydedilebilir. Laboratuvarda sabit bir ışık kaynağı ve cihaz yüksekliğini sabit tutacak bir aparat ile kalibrasyon düzeneği oluşturulursa daha iyi kalibrasyon modeli çıkarılabilir. Sahada belirli bir düzende cihaz ile ışık ölçümleri ve toprak örnekleri alınıp bunlar ile ölçüm modelleri daha iyi eğitilebilir.

Sonraki çalışmalarda cihaz insansız hava aracına monte edilerek toprak organik maddesinin ölçümü daha da hızlandırılabilir. Ek olarak daha fazla alanı tarayabileceği için haritalandırma yapılabilir.

KAYNAKLAR

AIMRUN, W., GHOLIZADEH, A., ASMINDA, J. N. A., and AMIN, M. S. M., 2014. Development of on-The-go soil organic matter sensor.Indian Journal of Agricultural Sciences, 84(10): 1201–1204.

BARNES, R. J., DHANOA, M. S., and LISTER, S. J., 1989. Standard normal variate transformation and de-trending of near-infrared diffuse reflectance spectra.Applied Spectroscopy, 43(5): 772–777.

BEN-DOR, E., and BANIN, A., 2010. Near-Infrared Analysis as a Rapid Method to Simultaneously Evaluate Several Soil Properties.Soil Science Society of America Journal, 59(2): 364.

CONFORTI, M., MATTEUCCI, G., and BUTTAFUOCO, G., 2018. Using laboratory Vis-NIR spectroscopy for monitoring some forest soil properties.Journal of Soils and Sediments, 18(3): 1009–1019.

FRIEDMAN, J H., 1993. Fast MARS, Department of Statistics. Stanford University, Tech. Report LCS110.

FRIEDMAN, Jerome H., 1991. Multivariate adaptive regression splines.The Annals of Statistics, 19(1): 1–67.

GOMEZ, C., VISCARRA ROSSEL, R. A., and MCBRATNEY, A. B., 2008. Soil organic carbon prediction by hyperspectral remote sensing and field vis-NIR spectroscopy: An Australian case study.Geoderma, 146(3–4): 403–411.

HE, Y., SONG, H., PEREIRA, A. G., and GOMEZ, A. H., 2005. Measurement and analysis of soil nitrogen and organic matter content using near-infrared spectroscopy techniques.Journal of Zhejiang University SCIENCE, 6B(11): 1081–1086.

KIM, H. J., SUDDUTH, K. A., and HUMMEL, J. W., 2009. Soil macronutrient sensing for precision agriculture.Journal of Environmental Monitoring, 11(10): 1810–1824.

KUANG, B., and MOUAZEN, A. M., 2013. Non-biased prediction of soil organic carbon and total nitrogen with vis-NIR spectroscopy, as affected by soil moisture content and texture.Biosystems Engineering, 114(3): 249–258.

LOBSEY, C., ROSSEL, R. V., and MCBRATNEY, A., 2010. An automated system for rapid in-field soil nutrient testing.19th World Congress of Soil Science, Soil Solutions for a Changing World, 1–6.

MCCULLOCH, W. S., and PITTS, W., 1943. A logical calculus of the ideas immanent in nervous activity.The Bulletin of Mathematical Biophysics, 5(4): 115–133.

MUTUO, P. K., SHEPHERD, K. D., ALBRECHT, A., and CADISCH, G., 2006. Prediction of carbon mineralization rates from different soil physical fractions using diffuse reflectance spectroscopy.Soil Biology and Biochemistry, 38(7): 1658–1664.

NELSON, D. W., and SOMMERS, L., 1982. Total carbon, organic carbon, and organic matter 1.Methods of Soil Analysis. Part 2. Chemical and Microbiological Properties, (methodsofsoilan2): 539–579.

NI, L., 2011. Principal component regression revisited.Statistica Sinica, 741–747.

RUWANPATHIRANA, P. P., JINENDRA, B. M. S., and BANDARA, K. M. T. S., 2016. Rapid detection of soil organic carbon using shortwave near infrared (sw-

nir) spectroscopy.International Journal of Scientific & Engineering Research, 7(6): 1126–1130.
SAVITZKY, A., and GOLAY, M. J. E., 1964. Smoothing and differentiation of data by simplified least squares procedures.Analytical Chemistry, 36(8): 1627–1639.
SMOLA A., and VISHWANATHAN, S., 2010. Introduction to Machine Learning. Cambridge University Press.
TEIXEIRA, S., GUIMARÃES, A. M., PROENÇA, C. A., ROCHA, J. C. F. da, and FÁVERO, E., 2014. Data Mining Algorithms for Prediction of Soil Organic Matter and Clay Based on Vis-NIR Spectroscopy.International Journal of Agriculture and Forestry, 4(4): 310–316.
TONITTO, C., and BILGILI, A. V., 2016. Combustion and Spectral Methods for Quantifying Carbon and Nitrogen Concentrations in Pacific Northwest Douglas-Fir Forest Soils.Journal of Agricultural Science, 8(6): 8.
VOLKAN BILGILI, A., VAN ES, H. M., AKBAS, F., DURAK, A., and HIVELY, W. D., 2010. Visible-near infrared reflectance spectroscopy for assessment of soil properties in a semi-arid area of Turkey.Journal of Arid Environments, 74(2): 229–238.
WOLD, H., 1966. Estimation of principal components and related models by iterative least squares.Multivariate Analysis, 391–420.
YU, J., MAO, J., PAN, T., CHEN, P., and YAO, L., 2017. Application of Portable Near-Infrared Spectrometer for Analysis of Organic Carbon in Marine Sediments.Journal of Geoscience and Environment Protection, 05(05): 108–114.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Yasin ASLAN
Uyruğu : Türkiye Cumhuriyeti
Doğum Yeri ve Tarihi : Diyarbakır, 07.04.1992
e-Mail : yyasin.aslan@gmail.com

EĞİTİM

Derece		Adı, İlçe, İl	Bitirme Yılı
Lise	:	Birlik Lisesi, DİYARBAKIR	2011
Üniversite	:	Dicle Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği, DİYARBAKIR (Not: 73.79/100)	2015
Yüksek Lisans	:	Harran Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Ana Bilim Dalı, ŞANLIURFA (Not: 3.5/4.0)	2019

TEKNİK BİLGİLER

Bilgisayar ve Yazılım Bilgileri

- Bilgisayar destekli çizim programları (Autocad, 3DS Max, Blender, Solidworks, Matlab)
- C, C++, C# & WPF, Python dilleri ile uygulama geliştirme
- Web tabanlı tasarım ve programlama (PHP, MYSQL, CSS, Angular, JS)
- Sayısal mantık tasarımı (Verilog, VHDL, FPGA)

Elektrik Elektronik Bilgileri

- Baskı devre kartı tasarımı (PCB)
- Gömülü sistem tasarımı
- Analog ve dijital sistemler (Mixed signal)
- Endüstriyel PLC uygulamaları

YABANCI DİLLER

İngilizce (YDS 70, YÖKDİL 82.5)

EK 1 Kod: Kalibrasyon verisinin hazırlanması ve grafiklerin çizimi

```
soilRef = unifiedNarSoil(2:end,2:end);
blackRef = unifiedNarBlack(2:end,2:end);
sunRef = unifiedNarSun(2:end,2:end);

wavelengths = unifiedNarBlack(2:end,1)';
distances = unifiedNarBlack(1,2:end);

reflectance = (soilRef - blackRef) ./ (sunRef - blackRef);
reflectanceWoBlack = soilRef ./ sunRef;

%% Kalibrasyon modelleri

models = {};
for i=1:length(wavelengths)
    models{i} = createFit(distances, reflectance(i,:), false);
end

%% plot models
figure;
for i=1:length(wavelengths)
    plot(models{i}),hold on;
end
hold off;


%% plot0

figure;

scatter(distances, reflectance(1,:),25,'filled','r');
hold on;
scatter(distances, reflectance(240,:),25,'filled','b');
title('632nm deki değişim');
xlabel('Uzaklık (cm)');
ylabel('Oran');
%xlim([0 10])
ylim([-1 6]);

%% plot1

figure;

subplot(1,3,1);
scatter(distances, sunRef(1,:),25,'filled');
title('632nm deki değişim (Güneşten alınan)');
xlabel('Uzaklık (cm)');
ylabel('Işık Şiddeti');


subplot(1,3,2);
scatter(distances, soilRef(1,:),25,'filled');
title('632nm deki değişim (Beyaz Referans)');
xlabel('Uzaklık (cm)');
ylabel('Işık Şiddeti');
```

```
subplot(1,3,3);
scatter(distances, blackRef(1,:),25,'filled');
title('632nm deki değişim (karanlık referans)');
xlabel('Uzaklık (cm)');
ylabel('Işık Şiddeti');


%% plot2

figure;

subplot(2,2,1);
plot(wavelengths, sunRef(:,[1:116, 118:end]));
title('Güneşten cosine corrector ile alınan');
xlabel('Dalgaboyu (nm)');
ylabel('Işık Şiddeti');

subplot(2,2,2);
plot(wavelengths, soilRef(:,[1:116, 118:end]));
title('Beyaz referanstan alınan');
xlabel('Dalgaboyu (nm)');
ylabel('Işık Şiddeti');

subplot(2,2,3);
plot(wavelengths, blackRef(:,[1:116, 118:end]));
title('Karanlık referans');
xlabel('Dalgaboyu (nm)');
ylabel('Işık Şiddeti');

subplot(2,2,4);
plot(wavelengths, reflectance(:,[1:116, 118:end]));
title('(Beyaz - Siyah) / (Güneş - Siyah)');
xlabel('Dalgaboyu (nm)');
ylabel('Oran');
```

EK 2 Kod: Kalibrasyon modeli fonksiyonu

```
function [fitresult, gof] = createFit(x, y, varargin)

numvarargs = length(varargin);
if numvarargs > 1
    error('createFit:TooManyInputs', ...
        'En fazla 3 argüman girilebilir ->
x,y[,makePlot=(true)|false]');
end

optargs = {true};
[optargs{1:numvarargs}] = varargin{:};
[makePlot] = optargs{:};

[xData, yData] = prepareCurveData( x, y );

ft = fittype( 'poly1' );
excludedPoints = excludedata( xData, yData, 'Indices', [7 8 40 117
129] );
opts = fitoptions( 'Method', 'LinearLeastSquares' );
opts.Exclude = excludedPoints;

[fitresult, gof] = fit( xData, yData, ft, opts );

if makePlot == true
    figure( 'Name', 'Doğrusal model' );
    h = plot( fitresult, xData, yData, excludedPoints,'x' );
    legend( h, 'Ölçümler', 'Çıkarılan ölçümler', 'Doğrusal model',
'Location', 'SouthEast' );

    xlabel 'Uzaklık (cm)'
    ylabel 'Oran'
    grid on
end
```

EK 3 Çizelge: Eğitilen modellerin eğitim ve test performansı sonuçları

Eğitim Sonuçları			PCR			PLSR			MARS			ANN		
No	Veri Türü	Önişlem	R^2	RMSE	MAE	R^2	RMSE	MAE	R^2	RMSE	MAE	R^2	RMSE	MAE
1	Orijinal	Ham veri	0.356	0.548	0.448	0.399	0.547	0.465	0.260	0.586	0.471	0.113	0.804	0.677
2	Orijinal	mv	0.376	0.530	0.446	0.352	0.556	0.444	0.256	0.578	0.482	0.088	0.945	0.798
3	Orijinal	bn	0.411	0.540	0.424	0.295	0.571	0.455	0.313	0.582	0.470	0.239	0.965	0.844
4	Orijinal	mv_bn	0.398	0.527	0.450	0.334	0.539	0.427	0.317	0.544	0.447	0.038	0.809	0.657
5	Orijinal	sg_bn	0.359	0.528	0.421	0.311	0.562	0.461	0.376	0.565	0.475	0.329	0.721	0.599
6	Orijinal	mv_diff_bn	0.407	0.525	0.429	0.317	0.549	0.446	0.248	0.583	0.468	0.328	0.534	0.417
7	Orijinal	mv_sgdiff_bn	0.420	0.522	0.432	0.415	0.529	0.436	0.368	0.539	0.436	0.359	0.552	0.440
8	Orijinal	mv_snv_bn	0.337	0.549	0.448	0.274	0.561	0.463	0.275	0.627	0.493	0.284	0.602	0.501
9	Orijinal	mv_snvde_bn	0.283	0.564	0.445	0.390	0.522	0.427	0.272	0.650	0.514	0.318	0.577	0.468
10	Orijinal	mv_bn_sgdiff	0.380	0.516	0.418	0.333	0.543	0.446	0.212	0.593	0.496	0.388	0.541	0.440
11	Orijinal	mv_sgdiff_snvde_bn	0.255	0.569	0.477	0.215	0.592	0.493	0.189	0.618	0.506	0.239	0.668	0.561
12	Kırpılmış	Ham veri	0.347	0.534	0.437	0.342	0.548	0.433	0.225	0.665	0.544	0.078	0.918	0.784
13	Kırpılmış	mv	0.373	0.537	0.433	0.347	0.548	0.466	0.263	0.573	0.470	0.210	0.864	0.721
14	Kırpılmış	bn	0.400	0.545	0.439	0.324	0.552	0.433	0.358	0.583	0.470	0.280	0.748	0.625
15	Kırpılmış	mv_bn	0.390	0.517	0.450	0.330	0.545	0.440	0.221	0.655	0.533	0.232	0.826	0.702
16	Kırpılmış	sg_bn	0.353	0.533	0.438	0.345	0.544	0.432	0.293	0.558	0.452	0.302	0.841	0.671
17	Kırpılmış	mv_diff_bn	0.357	0.511	0.425	0.365	0.530	0.434	0.222	0.594	0.481	0.337	0.559	0.443
18	Kırpılmış	mv_sgdiff_bn	0.399	0.528	0.446	0.424	0.526	0.437	0.369	0.539	0.437	0.304	0.575	0.460
19	Kırpılmış	mv_snv_bn	0.353	0.551	0.451	0.335	0.538	0.442	0.250	0.609	0.493	0.302	0.630	0.535
20	Kırpılmış	mv_snvde_bn	0.401	0.532	0.445	0.360	0.532	0.450	0.320	0.596	0.467	0.461	0.524	0.421
21	Kırpılmış	mv_bn_sgdiff	0.411	0.509	0.413	0.349	0.521	0.427	0.347	0.555	0.453	0.392	0.536	0.421
22	Kırpılmış	mv_sgdiff_snvde_bn	0.328	0.552	0.451	0.313	0.564	0.455	0.144	0.684	0.558	0.280	0.649	0.551

Test Sonuçları			PCR			PLSR			MARS			ANN		
No	Veri Türü	Önişlem	R^2	RMSE	MAE	R^2	RMSE	MAE	R^2	RMSE	MAE	R^2	RMSE	MAE
1	Orijinal	Ham veri	0.291	0.657	0.497	0.164	0.739	0.601	0.206	0.696	0.543	0.095	0.882	0.769
2	Orijinal	mv	0.169	0.738	0.615	0.334	0.647	0.488	0.127	0.783	0.587	0.026	0.800	0.679
3	Orijinal	bn	0.173	0.741	0.572	0.279	0.662	0.510	0.202	0.703	0.538	0.026	1.079	0.859
4	Orijinal	mv_bn	0.158	0.748	0.620	0.337	0.646	0.488	0.174	0.739	0.562	0.084	0.779	0.631
5	Orijinal	sg_bn	0.326	0.641	0.492	0.220	0.708	0.558	0.362	0.623	0.503	0.136	0.787	0.660
6	Orijinal	mv_diff_bn	0.084	0.857	0.665	0.193	0.710	0.557	0.419	0.611	0.491	0.192	0.713	0.547
7	Orijinal	mv_sgdiff_bn	0.281	0.677	0.528	0.364	0.645	0.528	0.410	0.622	0.486	0.267	0.704	0.596
8	Orijinal	mv_snv_bn	0.331	0.663	0.520	0.423	0.619	0.478	0.467	0.610	0.472	0.478	0.680	0.537
9	Orijinal	mv_snvde_bn	0.443	0.611	0.508	0.467	0.580	0.499	0.391	0.626	0.527	0.457	0.701	0.580
10	Orijinal	mv_bn_sgdiff	0.394	0.626	0.473	0.334	0.649	0.496	0.515	0.545	0.417	0.494	0.588	0.436
11	Orijinal	mv_sgdiff_snvde_bn	0.067	0.804	0.609	0.038	0.802	0.623	0.073	0.764	0.609	0.031	0.933	0.739
12	Kırpılmış	Ham veri	0.445	0.595	0.449	0.345	0.631	0.485	0.119	0.741	0.554	0.026	0.970	0.759
13	Kırpılmış	mv	0.488	0.579	0.445	0.242	0.697	0.582	0.340	0.634	0.503	0.026	0.857	0.657
14	Kırpılmış	bn	0.376	0.619	0.496	0.345	0.631	0.485	0.073	0.760	0.571	0.102	0.803	0.684
15	Kırpılmış	mv_bn	0.309	0.652	0.545	0.523	0.548	0.448	0.282	0.660	0.520	0.026	1.029	0.810
16	Kırpılmış	sg_bn	0.438	0.589	0.455	0.346	0.631	0.485	0.295	0.658	0.521	0.085	0.866	0.666
17	Kırpılmış	mv_diff_bn	0.382	0.613	0.503	0.498	0.572	0.437	0.368	0.630	0.504	0.346	0.647	0.527
18	Kırpılmış	mv_sgdiff_bn	0.336	0.642	0.521	0.360	0.627	0.517	0.409	0.622	0.486	0.294	0.671	0.523
19	Kırpılmış	mv_snv_bn	0.507	0.547	0.462	0.571	0.579	0.475	0.568	0.530	0.441	0.274	0.780	0.626
20	Kırpılmış	mv_snvde_bn	0.238	0.753	0.622	0.280	0.738	0.616	0.249	0.687	0.582	0.450	0.607	0.489
21	Kırpılmış	mv_bn_sgdiff	0.531	0.555	0.442	0.482	0.579	0.443	0.419	0.610	0.478	0.458	0.641	0.490
22	Kırpılmış	mv_sgdiff_snvde_bn	0.220	0.712	0.580	0.190	0.752	0.615	0.152	0.792	0.642	0.073	0.939	0.761