

Atf İçin: Güman, Z. ve Günay, F. B. (2024). Nesnelerin İnterneti Yardımıyla Akıllı Tarımda Yapay Zekâ Tabanlı Gübre ve Mahsul Tahmini. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 14(3), 958-973.

To Cite: Güman, Z. & Günay, F. B. (2024). Artificial Intelligence-Based Fertilizer and Crop Forecasting in Smart Agriculture with the Help of the Internet of Things. *Journal of the Institute of Science and Technology*, 14(3), 958-973.

Nesnelerin İnterneti Yardımıyla Akıllı Tarımda Yapay Zekâ Tabanlı Gübre ve Mahsul Tahmini

Zülküf GÜMAN^{1*}, Faruk Baturalp GÜNAY²

Öne Çıkanlar:

- Akıllı tarım uygulamaları
- Nesnelerin interneti ile tarımsal araziden veri elde etme ve arazi ihtiyacına göre işlem yapabilme

Anahtar Kelimeler:

- Akıllı tarım
- Yapay Zekâ
- Makine öğrenmesi
- Nesnelerin interneti
- Mahsul seçimi
- Gübre Seçimi

ÖZET:

Tarımsal faaliyetlerde düşük maliyetler yüksek verimli hasat almak oldukça önemlidir. Hasattan yüksek verim almak için de tarım arazisine uygun ürün ve gübre seçimi yapmak gerekmektedir. Tarımda düşük maliyetler ile yüksek verim alma da akıllı tarım ile mümkün olabilmektedir. Akıllı tarım ile tarımsal faaliyet aşamaları kontrol edilebildiği gibi; dış etkenlerden gelebilecek olumsuzluklara karşı da önlem alınabilmektedir. Tarım arazilerini uzaktan kontrol edebilmek için; nesnelerin interneti (IoT) tabanlı sensörler, bu sensörlerden veri alıp sunucuya göndermek için donanımsal sistemlere ihtiyaç vardır. Sunucuya gönderilen verilerde yapay zekâ algoritmaları ile değerlendirilip sonuca göre arazinin ihtiyacı belirlenir ve tarım aşamasına uygun gübre ihtiyacı, sulama ihtiyacı vb. ihtiyaçlara göre işlem yapılır. Bu amaçla bu çalışmada tarım arazisinden IoT ile sensör verilerinin alınıp sunucuya göndermek amaçlı arazi ve sunucu modülü olmak üzere donanımsal ürünler yapılmıştır. Yapay zekâ alanlarından biri olan makine öğrenmesi yöntemleri ile modelleri eğitmek için açık erişimli internet sitelerinden alınan veri setleri kullanılmıştır. Araziden alınan veriler oluşturulan makine öğrenmesi modelleri ile değerlendirilip araziye uygun ürün ve gübre seçimi yapılmasına olanak sağlanmaktadır.

Artificial Intelligence-Based Fertilizer and Crop Forecasting in Smart Agriculture with the Help of the Internet of Things

Highlights:

- Smart agricultural applications
- Obtaining data from agricultural land with the internet of things and performing operations according to land needs

Keywords:

- Smart farming
- Artificial intelligence
- Machine learning
- Internet of things
- Crop Selection
- Fertilizer Selection

ABSTRACT:

In agricultural activities, it is very important to get high-yield harvests at low costs. To get a high yield from the harvest, it is necessary to choose products and fertilizers suitable for the agricultural land. Getting high yields with low costs in agriculture is also possible with smart agriculture. With smart agriculture, agricultural activity stages can be controlled; Precautions can also be taken against negativities that may arise from external factors. To control agricultural lands remotely; Internet of Things (IoT) based sensors require hardware systems to receive data from these sensors and send them to the server. The data sent to the server is evaluated with artificial intelligence algorithms and the need for the land is determined according to the result and the need for fertilizer, irrigation need, etc. suitable for the agricultural stage is determined. Processing is carried out according to needs. For this purpose, in this study, hardware products, including field and server modules, were developed to capture sensor data from agricultural land with IoT and send it to the server. Data sets taken from open-access websites were used to train models with machine learning methods, one of the fields of artificial intelligence. The data taken from the field is evaluated with the created machine learning models, allowing the selection of products and fertilizers suitable for the land.

^{1*} Zülküf GÜMAN ([Orcid ID: 0000-0001-5777-4267](https://orcid.org/0000-0001-5777-4267)), Atatürk Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Erzurum, Türkiye

² Faruk Baturalp GÜNAY ([Orcid ID: 0000-0001-5472-3608](https://orcid.org/0000-0001-5472-3608)), Atatürk Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Erzurum, Türkiye

*Sorumlu Yazar/Corresponding Author: Zülküf GÜMAN, e-mail: zulkuf.guman13@ogr.atauni.edu.tr

GİRİŞ

Ülkelerin ekonomilerine büyük katkısı olan faaliyetlerden birisi de tarımdır. Tarım, kısaca besin zincirinde temel faaliyetlerin başında gelmektedir. Tarımsal faaliyetlerde düşük maliyet ile yüksek verimli hasat çok önemlidir. Bunun içinde toprak yapısına uygun ürün ve yapılacak üretim aşamaları önem arz etmektedir. Kaliteli tohumun seçimi ile başlayan faaliyet olumlu ya da olumsuz dış etkenlere (sulama, yağmur, yangın, rüzgâr, hava durumu, toprak vb.) bağlı olduğu gibi doğru zamanda ürünün ihtiyacına uygun sulama, gübreleme ve toprağı havalandırma işlemlerine de bağlıdır. Bunlardan en önemlilerinden ikisi de toprağı uygun mahsul ve buna uygun gübre seçimidir. Bu etkenlerde tarımı riskli bir faaliyet sınıfına dahil etmektedir. Fakat bu riskleri ortadan kaldırmak ve kaliteli bir tarımsal faaliyet yapabilmek için çeşitli çalışmalar yapılmaktadır. Bu çalışmalar da, teknoloji ve tarımı bir araya getiren ‘Akıllı Tarım’ kavramının bir alt başlığı olarak ortaya çıkmıştır.

Akıllı tarım, günümüzde her gün gelişen teknoloji her alanda büyük etkiye sahip olduğu gibi tarım alanında da büyük etkilere sahip olmaya başlamıştır. Akıllı tarımda en önemli bileşenler nesnelerin internetini (IoT) kullanan sensör verileridir. Sensör verilerinden alınan bilgiler IoT ile sunucuya gönderilir ve sunucudaki yapay zekâ, derin öğrenme, makine öğrenmesi algoritmaları vb. algoritmalar ile işlenerek daha verimli ve maliyetleri az bir tarım imkânı sağlanmış olmaktadır.

Yaşam alanlarına uzak ve büyük tarım alanlarında ulaşım ve zaman problemi büyük maliyetlere sebep olmaktadır. Akıllı tarım ile bu maliyetlere belli ölçülerde çözüm sağlamak mümkündür.

Tarımda düşük maliyetler ile zamanında doğru işlem tercihleri yüksek verim almayı ve zamandan tasarruf sağlamayı mümkün kılmak için çok önemlidir.

Konuyla ilgili çalışmalar incelendiğinde, Erdal ve ark. (2020)'de yaptıkları çalışmada, nesnelerin interneti gelişiminden ve IoT teknolojisini kullanan sistemlerin sunduğı faydalardan bahsedilerek örnek sistemler hakkında bilgi verilmiştir. Bu sistemlerin internete bağlanması ile yönetilebilir olması, sensörler vasıtasıyla veri toplayabilmesi ve sunucu üzerinden veri alışverişi yapabilmesi gibi birçok avantajı bulunmaktadır. Aydın ve ark. (2021) ise yaptıkları çalışmada, nesnelerin internetini kullanan teknolojilerden bahsederek programlanabilen sistemler ile bu bağlamda kullanılan nesnelere arası iletişim sağlayan ortamlar hakkında bilgi vermişlerdir. Nesnelerin internetini kullanabilmek için bu teknolojiyi kullanan en az iki nesnenin olması gerekmektedir ve bu nesnelere birisi bilgi aktarırken diğer nesne de bu bilgiyi okuyup istenilen işlemleri yapmakta ya da farklı sistemlere aktarabilmektedir. Baz (2022)'ın yaptığı çalışmada, bulut sistemleri, nesnelerin interneti ve yapay zekâ uygulamalarından faydalanılmıştır. Tarım ile uğraşanlar için bulut sistemi ve nesnelerin interneti başta olmak üzere diğer teknolojiler de kullanılarak akıllı tarım uygulamalarının tasarlanmasına çalışmada değinilmiştir. Bayrakçı ve ark. (2021) yaptıkları çalışmada, belirli bölgelerden ve açık erişimli internet sitelerinden alınan veriler ile bitki çeşidi, il ve ilçe bilgileri doğrultusunda tespit edilen su harcama miktarlarına göre veri seti oluşturulmuştur. Oluşturulan veri seti üzerinde yapay zekâ algoritmaları kullanılarak harcanan su miktarı tahmin edilmeye çalışılmıştır. Başka bir çalışmada ise Özer ve ark. (2022) akıllı tarımda veri analizi ile ürün tahminini sağlamışlardır. Veri seti olarak; toprak (Azot (N), Fosfor (P), Potasyum (K) değerleri) ve iklim verileri (Hava Sıcaklığı, Yağış Miktarı, Nem) kullanılarak veri madenciliğı algoritmaları ile farklı modeller oluşturulmuş ve bu modeller doğruluk, kesinlik, duyarlılık, f1-skor ve algoritmanın çalışma zamanına göre kıyaslama yapılmıştır. Yenikaya ve ark. (2022)' de tarla ve seralarda toprak değerleri kontrol edilerek ve kontrol merkezi ile internet üzerinden haberleşme sağlanıp gübreleme ve sulama yapılabilmesi üzerine çalışma yürütmüşlerdir. Sensörler kullanılarak toprak verileri sürekli takip altında tutularak söz konusu yöntemle toprak otomatik olarak gerekli düzeyde beslemektedir. Bu amaçla kullanılan yazılım ve donanımları içeren bir sistem, internet üzerinden

yönetilebilecek şekilde tasarlanmıştır. Duman (2022) ise yaptığı çalışmada ise, LoRa haberleşme teknolojisinin özellikleri, avantajları ve diğer teknolojilerden ayırıcı yönlerinden, LoRa teknolojisinin tarımsal uygulamalarda kullanım alanları, sunduğu çözümlerden bahsetmiştir. Akıllı tarımda örnek bir uygulama mimarisi sunulmuş ve analiz yapılmıştır. Ağızan ve ark. (2022) ise yaptıkları çalışmalarında, tarım alanında teknoloji kullanımının gelişmesini inceleyip ülkelere göre karşılaştırmaların yapılması ve Tarım 4.0 teknolojisinin uygulanabilirliği ile avantajları belirlenmeye çalışılmıştır. Çakmakçı ve ark. (2023) yılında yaptıkları çalışmalarında, akıllı tarımda bilginin alınması ve iletilmesi ile başlayan süreçte kullanılan teknolojilerden bahsedilmiştir. Nesnelerin interneti, kablosuz sensörler, yapay zekâ algoritmaları ile makine öğrenmesi yöntemleri kullanılarak tarımda verimliliği artırma adına bulunan öngörüler tartışılarak tarımsal faaliyetlerde uygulanabilirliği değerlendirilmiştir. Yaman ve ark. (2023) yaptıkları çalışmada ise, nesnelerin interneti teknolojisinin insanlık için önemli olduğundan bahsederek akıllı tarım uygulamalarında kullanılmakta olan bazı uygulamalardan bahsetmişlerdir. Bu uygulamalar arasında sensörleri, insansız hava araçlarını, robot teknolojilerini ve uydu teknolojilerini kullanan sistemlerin yapay zekâ ile makine öğrenmesi yöntemleri kullanılarak geliştirildiği anlatılmıştır.

Bu çalışmada, tarım arazisinde toprakta bulunan elementlere göre ekilmesi en uygun mahsul tahmini yapabilmek için bir veri seti ve yine toprakta bulunan elementlere göre ve ekilmek istenilen ürüne en uygun gübre tavsiyesi yapılması için farklı bir veri seti kullanılmıştır.

Makine öğrenmesi yöntemleri ile eğitilen modeller sonucunda; çalışma kapsamında tasarlanan cihazlardan alınan sensör verileri değerlendirilip tarım arazisine ekilebilecek en uygun ürün ve gübre tavsiyesi sonucuna erişilebilmektedir.

Tarım arazilerine ekim yapmadan önce ürün ve gübre seçimi yapılabilir ve gübre tavsiyesi de büyüme aşamalarında da bakılarak ürünün büyüme aşamasında belli periyotlar da gübre ihtiyacı tespit edilebilir ve bu tespit ile de bu ihtiyaca doğru olarak karşılık verebilme olanağı sağlamış olur.

Tasarlanan cihazlar yazılım katmanları ile, ulaşım yerlerine uzak ve büyük tarım arazilerinde tarımsal faaliyetleri kolaylaştırma adına; nesnelerin interneti (IoT) yardımı ile topraktan alınacak sensör verileri ile yapay zekâ algoritmaları kullanılarak modern tarım yapabilmek ve tarım arazilerine uygun düşük maliyet ile yüksek verimli ürün elde edebilme, tarımsal faaliyetleri ürünün ihtiyacına göre zamanında yapabilme olanağı sağlamaktadır. Mahsul büyürken gerçek zamanlı alınan sensör verilerine göre anlık mahsulün ihtiyacı belirlenebilmektedir.

Bu sebeple de tarımsal faaliyetler de hem zamandan hem de masraflardan büyük ölçüde tasarruf sağlanabileceği gibi büyük arazileri kontrol altında tutabilmek de kolaylaşmaktadır.

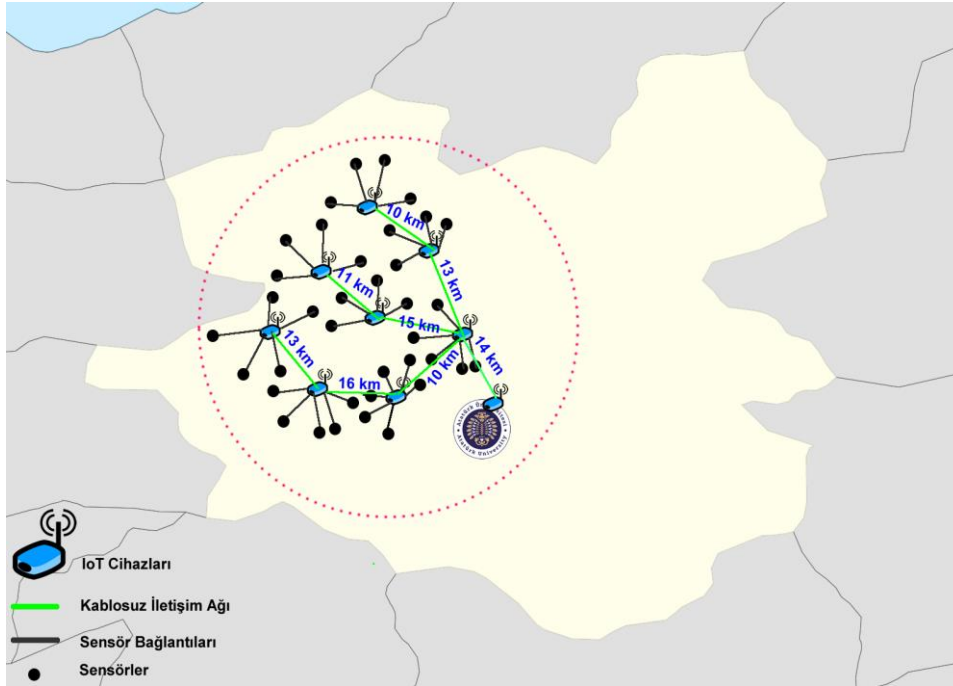
Bu çalışmanın literatüre katkılarından bazıları şunlardır; diğer çalışmalarda genellikle bir veri seti kullanılırken bu çalışma kapsamında iki farklı veri seti kullanılmış ve modelleri test etmek için de tarım arazisinden sensörler vasıtasıyla alınan gerçek zamanlı veriler kullanılmıştır. Bu sayede hem mahsul tahmini hem de gübre tahmini aynı çalışma içerisinde gerçekleştirilmektedir. Toprak yapısına hangi mahsulün uygun olduğu ve söz konusu mahsul ile ilgili süreçlerin genel anlamda tavsiye edilmesi literatüre bir katkı sunmaktadır.

Eğitim veri setleri kullanılarak oluşturulan modeller ile test verileri değerlendirilip incelenen toprak yapısı için ekilebilecek uygun ürün ile gübre tavsiyesi tahmini yapılmıştır. Ürün ve gübre tahminin de en başarılı sonucu veren model ile topraktan sensörler vasıtasıyla alınan test verisi değerlendirilmeye sokulmuş ve işlem sonucunda ürün tavsiyesi 'Pirinç', gübre tavsiyesi 'Düşük K: Potasyum Hidrojen Florür ekleyin' gibi tahmin sonuçlarına ulaşılmıştır.

MATERYAL VE METOT

Bu çalışmada kullanılacak yöntem, saha modülü ve sunucu modülü (donanımsal katmanlar), web tabanlı sunucu yazılımı, yapay zekâ yazılımı ve veri tabanı (yazılım katmanları) olmak üzere 5 ana katmandan oluşan akıllı tarım yönetim cihazları tasarlanmıştır. Yapılan donanım katmanları ile sahadan belirli periyodlarda sürekli toplanan sensör verilerinin nesnelerin interneti yardımı ile sunucu yazılımına göndermesi, sunucuda depolanıp yapay zekâ tabanlı tarım arazisine uygun ürün ve gerekli gübre çeşidi tahmini edilmesi ya da ekilmek istenilen başka bir ürüne uygun olacak gübre tahmini sağlanacaktır.

Saha ve sunucu modülleri birbirleri ile LoRa teknolojisini kullanılarak kablosuz olarak uzak mesafelerde haberleştirilip bu sayede ise haberleşme maliyeti ortadan kaldırılmış olmaktadır. Saha modüllerinin bir diğer özelliği de kapsama alanı içerisinde, yani LoRa modüllerinin kapsama alanına göre yaklaşık olarak 0-15 km çapındaki alanda bulunan ve sunucu ile doğrudan haberleşme mesafesinde bulunmayan diğer modüller ile haberleşip alınan verileri toplayıp sunucu modülüne gönderebilmektedir. Bu durum ise Erzurum ovası gibi büyük tarım alanlarından veri teminini kolaylaştırdığı için tarımsal faaliyetlerde büyük ölçüde maliyeti düşürüp, büyük arazilerde kontrollü tarım sağlayacağı gibi yapılması gereken tarımsal işlemleri doğru ve zamanında yapılmasına imkân sağlamakta ve verim artışına fayda sunmaktadır. Bunun yanı sıra yapılan donanımsal modüller yardımı ile otomatik sulama, gübreleme vb. gibi işlemlerinin yapılması ve kontrolü de mümkün hale gelmiştir.



Şekil 1. Çalışmada kullanılan donanım modüllerinin Erzurum ovası için örnek gösterimi

Saha Modülü

Tarım alanından alınacak olan; PH, Azot, Fosfor, Potasyum, Fotosentez, EC (Elektriksel İletkenlik), Sulama Miktarı, Hava Nemi, Rüzgâr Hızı, Rüzgâr Yönü, Yağmur Miktarı, Hava Sıcaklığı, Toprak Sıcaklığı ve Toprak Nemi sensör verileri saha modülünde toplanarak şifreli bir veri yapısında LoRa modülü ile uzak mesafedeki sunucu modülüne gönderilecektir. Sahadan alınacak olan bu veriler 7 farklı sensör vasıtasıyla toplanacaktır. Bu sensörler sırasıyla; hava nem sensörü, meteoroloji sensörü (Rüzgâr hızı, rüzgâr yönü ve yağmur miktarı), dış ortam hava sıcaklık sensörü, toprak nem sensörü, sulama akış miktarı ölçme sensörü, fotosentez ölçme sensörü ve toprak sensörüdür (Toprak sıcaklığı, potansiyel hidrojen, elektriksel iletkenlik, azot, fosfor ve potasyum). Modül üzerinde bulunan röle

devreleri ile de web yazılımı ile sunucu modülü üzerinden gönderilen sulama, gübreleme vb. gibi işlemlerin aktif edilmesi ya da kapatılması için kullanılacaktır. Saha modülü Şekil 2’de gösterildiği gibi tasarlanmıştır.


-PH (Potansiyel Hidrojen): Toprakta pH değeri 7 ise nötr, 7’nin üstünde ise alkali, 7’nin altında ise asidiktir. Ekilen ürünlerin büyüme ve gübrelerden faydalanma kabiliyetleri topraktaki pH seviyesine bağlıdır. Bu sebeple de pH seviyesinin ekilen ürüne göre doğru bir şekilde ayarlanması sağlıklı büyümesi ve verimin artmasını sağlar. Ekilecek ürün veya gübre seçiminde önemli bir etmen olarak kullanılmaktadır.

-Azot, Fosfor, Potasyum (NPK): Ekilen tüm ürünlerin büyümesi için gerekli olan üç temel besin maddesidir. Topraktaki miktarları ölçülerek gerekli gübreleme miktarının belirlenmesinde önem arz etmektedir.

-Fotosentez: Güneş ışınlarından alınabilecek enerji miktarını tespit etmekte kullanılmaktadır.

-EC (Elektriksel İletkenlik): EC topraktaki tuz minerallerinin miktarını ölçmek için kullanılır. İletkenlik topraktaki besin maddelerinin tespitinde kullanılır ve yüksek seviyelerde ise ürünlerde kurumaya sebep olmakta, düşük seviyelerde ise ürünlerin besin maddelerine ulaşmasının zorlaştığı anlamına gelmektedir.

-Sulama miktarı, hava nemi, rüzgâr hızı, rüzgâr yönü, yağmur yağış miktarı, hava sıcaklığı, toprak sıcaklığı ve toprak nemi bilgileri tarım arazisinde ekilen ürüne göre toprağa uygulanacak işlemler için faydalanılan diğer parametreler olacaktır.



Şekil 2. Saha modülünün görüntüsü

Sunucu Modülü

Saha modülünden nesnelerin interneti (IoT) yardımıyla şifreli olarak gönderilen veri yapısındaki sensör verilerinin şifreleri çözülerek internet ile web tabanlı sunucu yazılımına gönderilip veri tabanına kaydedilmesi sağlanmaktadır. Web sunucu tarafından gönderilen sulama, gübreleme gibi görev bilgilerini kontrol edip saha modülüne görev bilgilerini gönderme işlemi de bu modül ile sağlanmaktadır. Sunucu modülü Şekil 3’te gösterildiği gibi tasarlanmıştır.

Saha modülü topladığı verileri LoRa teknolojisi kullanarak sunucu modülü ile iletişim sağlamaktadır. LoRa (Long Range) adından da anlaşılacağı gibi uzun mesafeler de nesnelerin interneti aracılığı ile bilgi aktarımı kullanılan sistemler tarafından tercih edilen bir teknolojidir. Uzun mesafede radyo sinyalleri ile ve güvenli bir şekilde veri aktarımı yapılabilir.

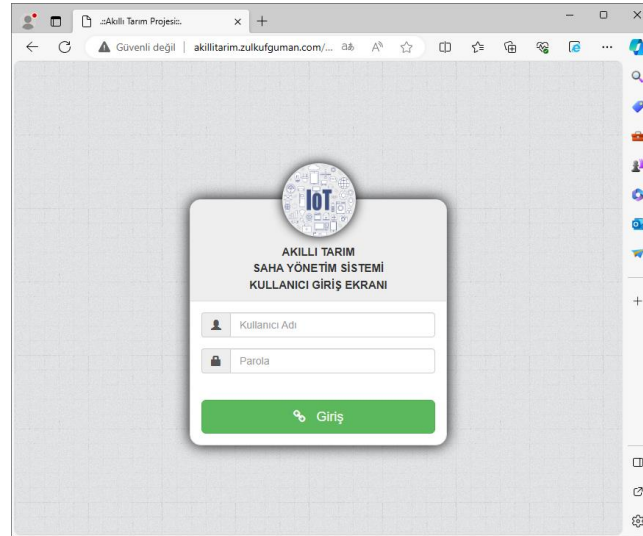


Şekil 3. Sunucu modülünün görüntüsü

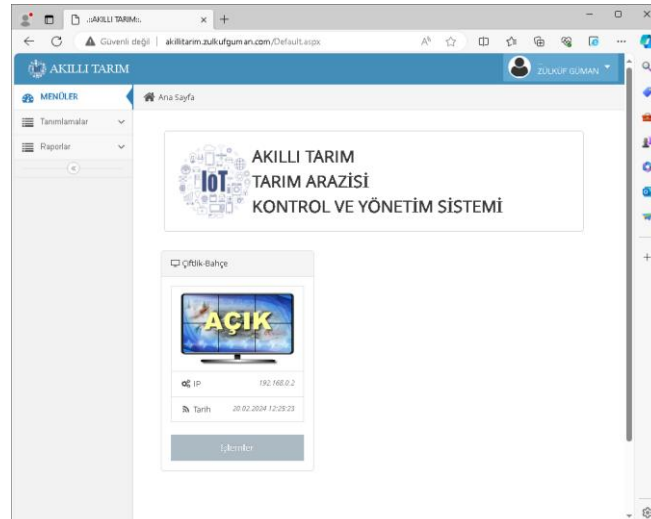
Web Tabanlı Sunucu Yazılımı

Sistem yönetim yazılımı ile verilerin depolandığı veri tabanı web tabanlı sunucuda bulunmaktadır. Sunucu modülünden gelen saha (tarla) sensör verileri veri tabanına kaydedilir. Bu kayıtlar sonraki zamanlarda da bitkinin büyüme aşamalarına göre incelenebilir ve daha sonraki zamanlarda yapılacak faaliyetler de kullanılmak üzere faydalı olacaktır.

Web sunucu yazılımına Şekil 4'teki kullanıcı giriş ekranından kullanıcı adı ve parolası ile giriş yapılarak sistemin yönetildiği ve verilerin gösterildiği ekranlara ulaşılmaktadır.

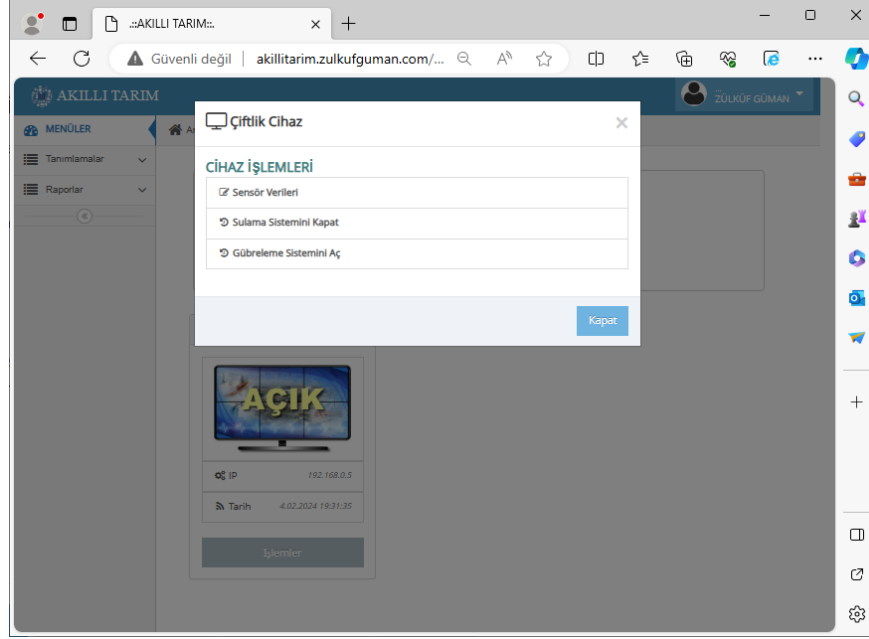


Şekil 4. Web sunucu yazılımı sisteme giriş ekranı görüntüsü




Şekil 5. Web sunucu yazılımı arazi sistem yönetim ekranı görüntüsü

Web sunucu yazılımı saha panelleri yönetim sayfası; sahada bulunan sistemler bu ekranda görülmektedir ve ilgili modülün yönetimi, alınan veriler ile gönderilecek görevler Şekil 5 ve Şekil 6'daki görsellerdeki ekrandan yapılmaktadır.



Şekil 6. Web sunucu yazılımı arazi sistemi görev gönderme ekranı görüntüsü

Bu çalışma kapsamında tasarlanan sistemin çalışma prensibi genel olarak Şekil 7'deki blok diyagramda gösterilmiştir.



Şekil 7. Sistemin çalışma prensibini gösteren blok diyagramı

Veri Seti

Bu çalışmada veri seti olarak; toprak yapısına göre ekilebilecek uygun ürün tahmini yapabilmek için açık erişimli olan Kaggle sitesinden alınan veri seti “Crop analysis and prediction” alınmıştır (Kaggle, 2023). Toprak yapısına uygun ve ekilmek istenilen ürün çeşidine uygun olacak gübre seçimi yapabilmek için açık erişimli Github sitesinden alınan “crop_fertilizer_prediction_ML” veri seti kullanılmıştır (Github, 2023). Mahsul seçimi için kullanılan veri setine ait veri özellikleri ile örnek bir veri seti Çizelge 1’de ve uygun gübre seçimi için kullanılan veri setlerine ait özellikler ve örnek veri seti Çizelge 2’de gösterilmiştir.

Çizelge 1. Ürün tahmini için kullanılan veri seti örneği

Özellik	Birim	Açıklama	Örnek Veri
N	mg/kg	Azot	85
P	mg/kg	Fosfor	58
K	mg/kg	Potasyum	41
Sıcaklık	°C	Sıcaklık	21.77
Nem	%	Nem	80.31
PH	pH	pH	7.04
Yağış Oranı	mm/m ²	Yağış miktarı	226.66
Ürün Tavsiyesi	-	Ürün tavsiyesi	Pirinç

Çizelge 2. Gübre tahmini için kullanılan veri seti örneği

Özellik	Birim	Açıklama	Örnek Veri
N	mg/kg	Azot	65
P	mg/kg	Fosfor	50
K	mg/kg	Potasyum	36
Sıcaklık	°C	Sıcaklık	23.06
Nem	%	Nem	83.37
PH	pH	pH	7.07
Yağış Oranı	mm/m ²	Yağış miktarı	251.06
Ürün İsmi	-	Ürün	Pirinç
Gübre Tavsiyesi	-	Gübre Tavsiyesi	Düşük N: Üre Gübresi Ekleyin (46-0-0)

Bu çalışma kapsamında yapılan saha modülü ile tarım arazisinden gerçek zamanlı toplanan sensör verileri sunucu modülüne gönderilerek kayıt altına alınmış olup, alınan bu toprak özelliklerini gösteren veriler, veri özelliğinin birimlerini, açıklamalarını ve örnek bir veri setini içeren veri paketi Çizelge 3’te gösterilmiştir.

Çizelge 3. Tarım arazisinden alınan sensör verileri veri seti örneği

Özellik	Birim	Açıklama	Örnek Veri
N	mg/kg	Azot	62
P	mg/kg	Fosfor	10
K	mg/kg	Potasyum	70
PH	pH	pH	6.85
EC	mS/cm	Elektrik iletkenlik	2.32
Fotosentez	mol/m ² /s	Fotosentez	10
Sıcaklık	°C	Sıcaklık	4.44
Nem	%	Hava nemi	40
Toprak Nemi	%	Toprak nemi	70
Toprak Sıcaklığı	°C	Toprak sıcaklığı	6.13
Rüzgâr Hızı	kPh	Rüzgâr hızı	0.04
Rüzgâr Yönü	°C	Rüzgâr yönü	135
Yağış Oranı	mm/m ²	Yağış miktarı	0
Sulama Miktarı	l/min	Sulama miktarı	0

Makine öğrenmesi yöntemlerinde mahsul tahmini için kullanılan veri seti ile gübre tahmini için kullanılan veri setinde bulunan azot (N), fosfor (P), potasyum (K), sıcaklık, nem, pH ve yağış oranı değerlerinin veri seti içerisindeki ortalama değerleri hesaplanarak Çizelge 4’te gösterilmiştir.

Çizelge 4. Mahsul ve gübre tahmini veri seti özneliklerinin ortalama değerleri

Özellik	Birim	Mahsul Veri Seti	Gübre Veri Seti
N	mg/kg	50.55	49.66
P	mg/kg	43.36	43.60
K	mg/kg	48.15	49.38
Sıcaklık	°C	25.61	25.38
Nem	%	71.48	71.37
PH	pH	6.47	6.47
Yağış Oranı	mm/m ²	103.46	106.29

Bu çalışmada mahsul tahmini ve gübre tahmini yapabilmek için yedi farklı makine öğrenmesi algoritması kullanılmıştır. Bu algoritmalar şunlardır; Lojistik Regresyon, Support Vector Machines (SVM, Destek Vektör Makineleri), Decision Tree (KA, Karar Ağacı), k-Nearest Neighbor (k-NN, k-en Yakın Komşu), Naive Bayes, Random Forest (RF, Rastgele Orman) ve Gradient Boosting (Gradyan Arttırma)'tir.

Makine Öğrenmesi Sınıflandırma Algoritmaları

Logistic Regresyon (LR)

Lojistik Regresyon, bağımlı olan değişkenin bir veya birden fazla bağımsız değişken ile ilişkisini sayısal verilerle analiz edebilen etkili makine öğrenmesi yöntemlerinden biridir (Stoltzfus, 2011).

Lojistik regresyonda hedef bağımsız değişken değerini tahmin etmektir. Yani kategorilere ayrılmış birden fazla bağımsız değişken ile bağımlı olan değişkenin arasındaki ilişkiyi göstermektedir (Basu ve Pal, 2017; Arabameri ve ark., 2018).

Support Vector Machine (SVM)

Destek vektör makineleri, veri seti sınıflandırmada ve problemlerin çözümünde yüksek performans göstermiş ve literatürde yerini almış makine öğrenmesi algoritmalarından birisidir (Ayhan ve Erdoğan, 2014; Wang, 2005). Verileri iki kategoriye ayırıp n boyutlu hiperdüzlem oluşturarak çalışırken iki katman halinde bir yapay sinir ağına sahip bir yapıdadır (Yakut, 2014).

Az sayıda eğitim veri seti ile farklı sınıflar arasında en iyi hiperdüzlemi bulmaya çalışmaktadır. Bu düzlem sınıflar arasındaki sınırları daha net hale getirir (Boser ve ark., 1992; Foody ve ark., 2007).

k-Nearest Neighbor (k-NN)

K-En Yakın Komşu yöntemi hem regresyon hem de sınıflandırma yapmak amaçlı kullanılan en basit yöntemlerden biridir. K en yakın komşu sayısını parametre olarak ifade eder. Eğitim verileri ile sınıflandırılacak yeni veri noktasının en yakında bulunan komşuları girdi verisi ile veri kümesindeki tüm veri noktalarının mesafesinin hesaplanması sonucu bulunur. K değeri sınıflandırma sonucu ile doğru orantılıdır. Kısaca k değeri ne kadar büyükse sınıflandırma sonucu da o kadar iyidir diye yorumlanır (Harrison 2018, Brownlee 2016).

K-en yakın komşu algoritmasında veri setinde sınıfı belirsiz olan verilerin eğitim setindeki sınıfı belli olan verilerle karşılaştırılıp uzaklıkları hesaplanarak k tane yakın komşusu belirlenip buna göre sınıfı belirsiz verinin hangi sınıfa ait olduğu sınıfı belirlenmektedir. Performansı k değerinin seçimi ile doğru orantılıdır (Yıldırım ve ark., 2023).

Decision Tree (Karar Ağacı-KA)

Karar ağacı algoritması büyük bir veri setini, kümeleme algoritmasını kullanarak verileri küçük gruplar halinde gruplandırmak için kullanılan bir yöntemdir. Karar ağacı da k-nn algoritması gibi hem regresyon hem de sınıflandırma için kullanılabilen yöntemlerdendir. En üstte bulunan hücre kök (root veya root node), kök hücrenin altındaki hücrelere de düğüm (interval nodes veya nodes), en altta bulunan

hücrelere ise yaprak (leaf nodes veya leaves) adı verilir. Bir karar ağacının düğüm sayısı ile doğru orantılı olarak karmaşıktır (Çetinkaya ve Horasan 2021).

Random Forest (Rastgele Orman-RF)

Rastgele Orman topluluk öğrenme algoritmasıdır. Bu yöntemde hem sınıflandırma hem de regresyon için kullanılabilen algoritmalarındandır. Rastgele Orman yönteminin çalışma prensibi; birden çok karar ağacı üretmek veri setinde sınıflandırma yapar ve sınıflandırma değerini yükseltmeyi amaçlar. Bir arada bulunan bağımsız karar ağaçları arasından en yüksek puan alan değerini seçilmesine dayalı yöntemdir. Regresyon ise; yaprak düğümlerde az sayıda birim kalıncaya dek bölünme işlemi devam eder (Akar ve ark., 2012, Özdemir, 2018).

Denetimli sınıflandırma yöntemlerinden biri olan rastgele orman yöntemi birçok karar ağacını eğiterek sonuçta ortaya çıkan bütün ağaçların içerisinde çoğunlukta olan sınıfı döndüren bir topluluk algoritmasıdır (Lorena ve ark., 2019).

Naive Bayes

Naive Bayes sınıflandırma ve tahmin için kullanılması basit bir denetimli bir öğrenme yöntemidir. “Bağımsız Özellik Modeli” ile çalışmaktadır. En önemli faydalarından biri, sınıflandırma için tahmin yapabilmek için az miktarda eğitim verisine ihtiyaç duymasıdır. Tahmin işlemi önceki deneyimlere dayalı olarak yapılır (Priya ve ark., 2018).

Algoritma bir verinin her durumda olasılığı hesaplanarak çıkan en yüksek değere göre sınıflandırma yapmaktadır. Bir sınıftaki verini diğer verilerle doğrudan ilişkisi olmadığı düşünülmektedir. Bir sınıfa ait verilerin birbiri arasında bağımlı olabileceği varsayılmaktadır (Rish, 2001).

GradientBoosting (Gradyan Artırma-GA)

2001 yılında Friedman’ın ortaya çıkardığı Gradient Boosting algoritması rastgele orman algoritması gibi çekirdek karar ağacı algoritmasını kullanmaktadır. Bu sebeple de karar ağaçlarına benzer bir yapıda çalışmaktadır. Algoritmanın genel prensibi hatayı tahmin edip hatanın iyileştirilmesi yönündedir (Friedman, 2001; Alan ve ark., 2020). Artırma ifadesi daha iyi bir sonuç elde etmek için zayıf sonuç ağaçlarının bir arada toplandığı bir algoritma çeşididir (Xie ve ark., 2019).

Karar ağaçlarına benzer şekilde çalışan Gradyan artırma yöntemi, modelin doğruluk oranını artırmak için birçok düşük doğruluğa sahip veriyi bir araya getirir. Aşırı öğrenme sorununa çözüm olarak yeni bir ağaçtan gelen değeri doğrulamak için bir öğrenme oranı kullanmaktadır (Yoon, 2021).

Performans Metrikleri

Makine öğrenmesi modellerinin performanslarını değerlendirmek için performans metrikleri kullanılır. Bu metrikler doğruluk, duyarlılık, özgünlük, kesinliktir ve denklemleri (1), (2), (3), (4)’te gösterildiği gibidir (Gültepe, 2021; Japkowicz, 2011).

Bu denklemlerde; DP (Doğru Pozitif) doğru şekilde sınıflandırılan mahsul ve gübre tahmin sayısını, DN (Doğru Negatif) doğru şekilde sınıflandırılan alt sınıf mahsul ve gübre tahmin sayısını, YP (Yanlış Pozitif) yanlış bir şekilde sınıflandırma yapılan alt sınıf mahsul ve gübre tahmin sayısını, YN (Yanlış Negatif) ise yine yanlış bir şekilde sınıflandırma yapılan mahsul ve gübre tahmin sayısını ifade etmektedir.

Doğruluk, doğru bir şekilde sınıflandırılan mahsul ve gübre verilerinin tüm veriler içindeki oranını hesaplayıp sınıflandırma yönteminin performansını hesaplar. Duyarlılık, doğru olarak sınıflandırılan alt sınıf mahsul ve gübre verilerinin tüm alt sınıf mahsul ve gübre verilerine oranını ifade eder. Kesinlik,

doğru şekilde sınıflandırılan mahsul ve gübre verilerinin doğru olarak sınıflandırılan tüm verilere oranını gösterir. F_1 skor, duyarlılık ve kesinlik sonuçlarının harmonik ortalamasıdır.

$$\text{Doğruluk (Acc)} = \frac{DP + DN}{DP + YP + YN + DN} \quad (1)$$


$$\text{Duyarlılık (Sen)} = \frac{DP}{DP + YN} \quad (2)$$

$$\text{Kesinlik (Pre)} = \frac{DP}{DP + YP} \quad (3)$$

$$F_1 = \frac{2*DP}{2*DP + YP + YN} \quad (4)$$

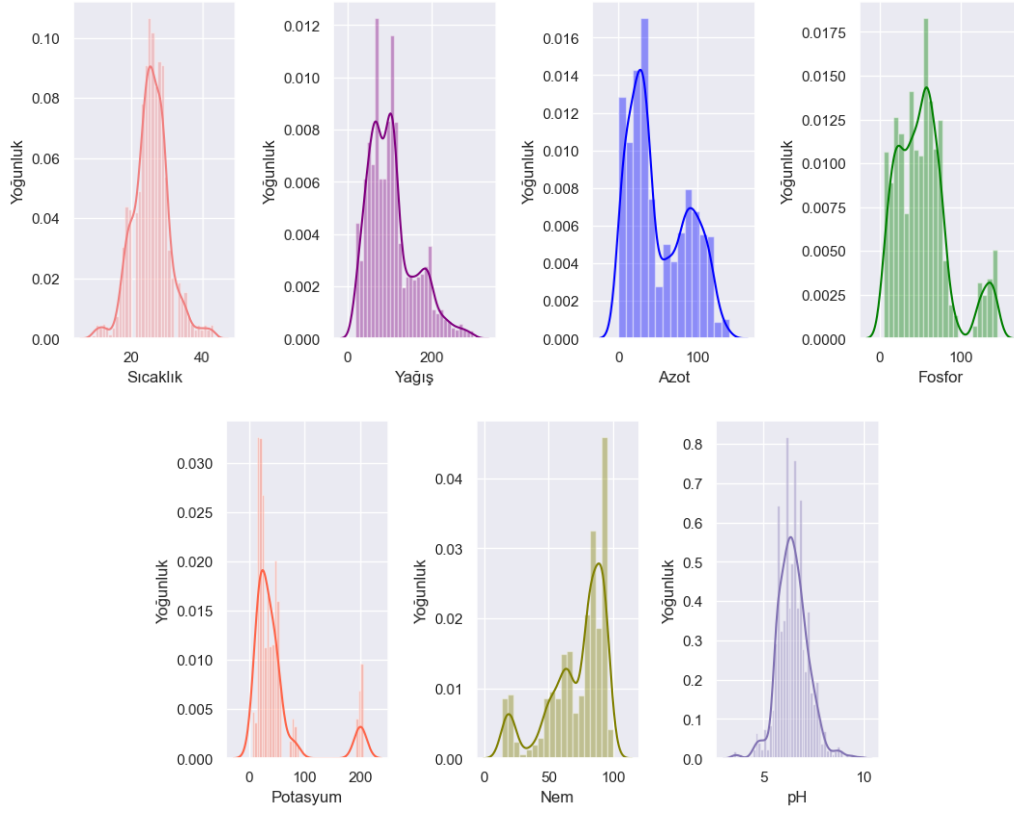
BULGULAR VE TARTIŞMA

Veri setlerindeki özelliklerin birbirleri arasındaki ilişkileri belirlemek için korelasyon matrisleri oluşturulmuştur. Bu matriste değerler -1 ile +1 arasındadır. Pozitif korelasyon +1'e yakınlığı ile, negatif korelasyon da -1'e yakınlığı ile yorumlanır. Aralarında pozitif korelasyon olan özellikler birlikte artma eğilimi veya birlikte azalma eğilimlidirler, diğer taraftan aralarında negatif korelasyon olan değişkenler de biri artarken diğeri azalma eğilimindedirler. Bu çalışmadaki veri setleri ile oluşturulan korelasyon matrisleri Şekil 8'de gösterilmiştir. Korelasyon matrislerine bakılınca özelliklerin mahsul ve gübre tahminine yönelik bireysel katkısı olabileceği görülmektedir.

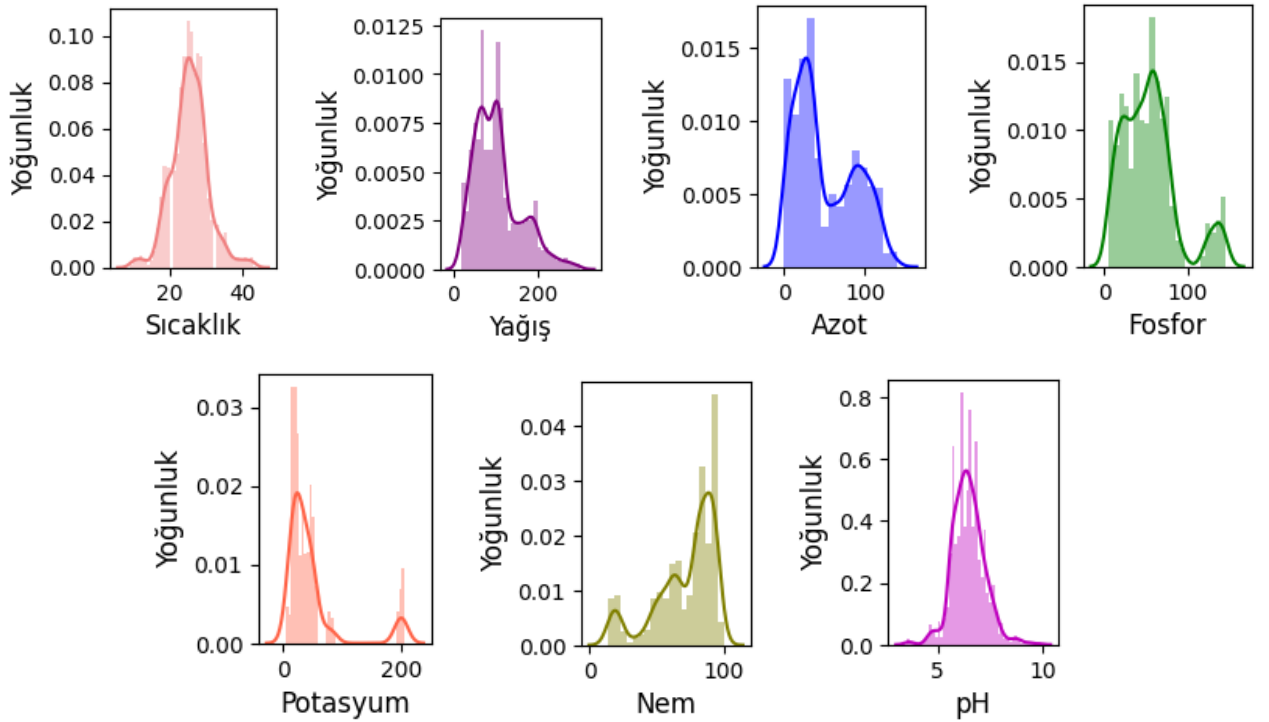


Şekil 8. Veri setlerindeki mahsul ve gübre öznitelikleri için korelasyon matrisleri

Şekil 9'da mahsul tahmini veri setinden bulunan özniteliklerin yoğunluk grafikleri ve Şekil 10'da ise gübre tahmini için kullanılan veri setinden bulunan özniteliklerin yoğunluk grafikleri gösterilmektedir.



Şekil 9. Mahsul tahmini veri setinde özniteliklerin yoğunluk grafikleri



Şekil 10. Gübre tahmini veri setinde özniteliklerin yoğunluk grafikleri

Mahsul ve gübre veri setlerinde sınıflandırma yapmak için kullanılan makine öğrenmesi algoritmaları modellerinin eğitilmeleri neticesinde elde edilen sonuç verilerine göre yöntemlerinin başarı sonuçları Çizelge 7 ile Çizelge 8’de gösterilmiştir.

Çizelge 7. Makine öğrenmesi yöntemlerinin mahsul tahmini için sınıflandırma başarı oranları

Yöntem	Doğruluk	Kesinlik	Duyarlılık	F ₁ Skor
Lojistik	0.97	0.96	0.95	0.95
SVM	0.98	0.98	0.98	0.98
Karar Ağaçları	0.99	0.98	0.98	0.98
k-NN	0.99	0.98	0.98	0.98
Naive Bayes	0.99	0.99	0.99	0.99
Rastgele Orman	0.91	0.87	0.89	0.86
Gradyan Arttırma	0.99	0.99	0.99	0.99

Çizelge 8. Makine öğrenmesi yöntemlerinin gübre tahmini için sınıflandırma başarıları

Yöntem	Doğruluk	Kesinlik	Duyarlılık	F ₁ Skor
Lojistik	0.66	0.53	0.59	0.56
SVM	0.66	0.48	0.65	0.55
Karar Ağaçları	0.93	0.71	0.70	0.70
K-NN	0.76	0.64	0.66	0.65
Naive Bayes	0.80	0.68	0.70	0.68
Rastgele Orman	0.61	0.48	0.61	0.51
Gradyan Arttırma	0.91	0.66	0.64	0.65

Mahsul tahmini veri setinde 22 sınıf (ürün çeşidi) ve gübre tahmini veri setinde ise 241 sınıf (gübre tavsiyesi) bulunmaktadır. Makine öğrenmesi algoritmaları arasından çalışma kapsamında oluşturulan modellerde başarı yüksek olan KA algoritması modeli kullanılmıştır. KA modeli kullanılarak eğitilen veri seti ile değerlendirme sonucunda makale kapsamında yapılan modüller vasıtasıyla tarım arazisinden alınan veriler arasından rastgele seçilen örnek verilere göre tahmin sorgulamaları sonucunda ekilmesi uygun mahsul tavsiyesi ve bu mahsule veya ekilmek istenilen başka bir mahsule uygun gübre tavsiyesi Çizelge 9’da gösterilmiştir.

Çizelge 9. Makine öğrenmesi yöntemleri sonucu mahsul ve gübre tahminleri

N	P	K	Sıcaklık	Nem	PH	Yağış Oranı	Mahsul Tavsiyesi	Gübre Tavsiyesi
90	40	40	20	80	7	200	Pirinç	Düşük K: Potasyum Hidrojen Florür ekleyin
68	13	76	15	80	6.7	105	Nar	Yüksek N-P, Düşük K: Toprağın üstüne malç ekleyin, Konsantre Süperfosfat (CSP) ekleyin, K açısından zengin besinler eklemeyin
67	12	75	6.81	97	6.75	97	Papaya	Düşük N: Üre Gübresi Ekleyin (46-0-0)
20	5	25	13	75	5.05	35	Güve Fasulyesi	Düşük N-P-K: N-Primer Azot Takviyesi, Süperfosfat (OSP), Potasyum Tetraflorborat ekleyin
20	5	25	13	75	5.05	35	Pirinç	Düşük N-P-K: Üre, Amonyum Polifosfat (APP), Potasyum Tetraflorborat ekleyin

SONUÇ

Bu çalışmada, toprakta bulunan özniteliklere göre ekilebilecek en uygun mahsul tahmini ve ekilecek mahsule uygun gübre tahmini yapabilmek için makine öğrenmesi algoritmalarının performansları karşılaştırılmıştır. Çalışma kapsamında yapılan donanımsal sistemler yardımı ile tarım arazisinden elde edilen toprak özellikleri değerlendirilerek mahsul ve gübre tavsiyesi sonucu elde edilmiştir.

Bu çalışmada tarımda verimliliği arttırmak ve maliyetleri azaltmak amacıyla nesnelerin interneti ile tarım arazisinden sensörler vasıtasıyla alınan veriler makine öğrenmesi yöntemleri kullanılarak sınıflandırılmıştır. Çoklu Sınıflandırma (multi-class classification) metodu kullanılan bu çalışmada arazi için en uygun ürün ve kullanılması uygun olacak rasyonel gübre tahmin edilmiştir. Sınıflandırma için veri seti %75’i eğitim ve %25’i test verisi olacak şekilde ayrılmıştır. Makine öğrenmesi algoritmalarından SVM, KA, RO, GA, K-NN, LR ve NB olmak üzere 7 farklı sınıflandırma algoritması kullanılarak sonuçlar karışıklık matris ile değerlendirilmiştir. Çalışma sonunda algoritmaların

sınıflandırma performanslarına bakıldığında ürün tahmini için KA, K-NN, NB ve GB algoritmaları ile %99 olarak en yüksek doğruluk oranı elde edilmiştir. Aynı algoritmalar kullanılarak gübre tahmini için oluşturulan modellerin performansları analiz edildiğinde KA algoritmasıyla %93 olarak en yüksek doğruluk oranı elde edilmiş, en düşük doğruluk oranı ise %61 olarak RO algoritmasıyla alındığı olduğu görülmüştür.

Değerlendirme sonuçlarına bakınca çalışma kapsamında oluşturulan modellerin büyük oranda başarılı bir şekilde sınıflandırma yaptığı görülmektedir. Akıllı tarım konusunda yapılan diğer çalışmalar incelendiğinde bu çalışma kapsamında tasarlanan modellerin başarı oranları genel olarak daha yüksek sonuç vermiştir. Ayrıca bu çalışmayı diğer çalışmalardan ayıran bir özellikte hem ürün hem de mahsul tahmini yapabilmek için farklı iki veri seti kullanılıp ayrı ayrı eğitilen modeller ile gerçek ortamdan alınan verilerin test edilmesidir (Özer ve ark., 2022; Yenikaya ve ark., 2022).

Saha ve sunucu cihazları arasında iletişimi sağlamak için kullanılan LoRa sensörleri kullanılırken iki modül arasında iki yönlü veri aktarımı sağlanmış ve veri yapısı olarak yığın bellek yapısı kullanılmıştır. Veri aktarımında gönderilen ve alınan veri boyutları iki modülde de ayrı ayrı incelenmiş ve iki cihaz arasında (yaklaşık 4-5 km mesafe) veri iletiminde kayıp görülmemiştir.

Bu çalışma kapsamında yapılan donanımsal cihazlar ve değerlendirmeler sonucunda, tarım arazisine ekilmeye en uygun ürün ile bu ürüne uygun gübre tavsiyesi almak tarımsal faaliyetler öncesinde faydalı olacaktır. Yukarıdaki yöntemler sonucunda bu çalışmalarda da uygun mahsul ve gübre tahmini gerçekleştirilmiş olup, tarım ile ilgili kişilerin arazi hakkında daha nitelikli verilere sahip olması da sağlanmıştır. Çalışmada tasarlanan cihazlar, cihaz yazılımları ve sistem yönetim yazılımları bu çalışmayı öne çıkarmaktadır.

Gelecekte saha modüllerinin sayısı artırılarak daha geniş tarım arazileri kontrol edilerek kaynaklardan daha fazla tasarruf etme oranı artabilecektir.

Daha sonraki çalışmalarda yeni algoritmalar aynı çatı üstünde denenebilecektir. Ayrıca haberleşme verimliliği değişen LoRa ve anten parametreleri ile değerlendirerek çalışmayı farklı bir düzeyde sunmak mümkün olacaktır. Yine frekans çeşitliliğinin haberleşme üzerindeki etkisi de irdelenebilecektir.

Çıkar Çatışması

Makale yazarları arasında herhangi bir çıkar çatışması olmadığını beyan ederler.

Yazar Katkısı

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan eder.

KAYNAKLAR

- Abdullah, A. L. A. N., & KARABATAK, M. (2020). Veri seti-sınıflandırma ilişkisinde performansa etki eden faktörlerin değerlendirilmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 32(2), 531-540.
- Ağızan, K., Bayramoğlu, Z., & Ağızan, S. (2022). Akıllı Tarım Teknolojilerinin Tarımsal İşletme Yöneticiliğine Sunduğu Avantajlar. *Turkish Journal of Agriculture-Food Science and Technology*, 10(9), 1697-1706.
- Arabameri, A., Pradhan, B., & Rezaei, K. (2019). CBS'de kesinlik faktörü ve rastgele orman modelleri ile entegre coğrafi ağırlıklı regresyon kullanarak oyuntu erozyonu bölgelendirme haritalaması. *Çevre yönetimi dergisi*, 232, 928-942.

- Atalay, M., & Çelik, E. (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları artificial intelligence and machine learning applications in big data analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- Aydın, A., Usanmaz, B., & Göktaş, Y. (2021). Nesnelerin interneti'nin eğitimde kullanıldığı alanlar ve bu alanlara etkileri. *Yükseköğretim ve Bilim Dergisi*, 11(2), 425-436.
- Ayhan, S., & Erdoğan, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
- Basu, T., & Pal, S. (2018). Identification of landslide susceptibility zones in Gish River basin, West Bengal, India. *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards*, 12(1), 14-28.
- Bayrakçi, H. C., Çiçekdemir, R. S., & Özkahraman, M. (2021). Tarım Arazilerinde Harcanan Su Miktarını Yapay Zekâ Teknikleri Kullanarak Belirlenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 9(6), 237-250.
- Baz, F. Ç. (2022). Cloud Systems Used in Smart Agriculture, the Internet of Things and Uses of Other Technologies and a Smart Agriculture Architectural Proposal. *Turkish Journal of Agriculture-Food Science and Technology*, 10(6), 1066-1071.
- Biçakçi, S. N. (2019). Nesnelerin interneti. *Takvim-i vekayi*, 7(1), 24-36.
- Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992, July). A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory* (pp. 144-152).
- Brownlee, J. (2016). K Nearest Neighbors for Machine Learning. Retrieved March 23, 2020,
- Çakmakçı, M. F., & Cakmakçı, R. (2023). Uzaktan Algılama, Yapay Zekâ ve Geleceğin Akıllı Tarım Teknolojisi Trendleri. *Avrupa Bilim ve Teknoloji Dergisi*, (52), 234-246.
- Çetinkaya, Z., & Horasan, F. (2021). Decision trees in large data sets. *International Journal of Engineering Research and Development*, 13(1), 140-151.
- Duman, E. (2022). Akıllı Tarımda LoRa Haberleşmesinin Rolü, Uygulama Alanları, Bir Mimari Önerisi ve Performans Analizi. *Artificial Intelligence Studies*, 5(2), 56-70.
- Erdal, E., & Ergüzen, A. (2020). Nesnelerin İnterneti (IoT). *International Journal of Engineering Research and Development*, 12(3), 24-34
- Foody, G. M., Boyd, D. S., & Sanchez-Hernandez, C. (2007). Mapping a specific class with an ensemble of classifiers. *International Journal of Remote Sensing*, 28(8), 1733-1746.
- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*, 1189-1232.
- GitHub, 2023 Mahsul Gübre Tahmini ML, Erişim adresi: https://github.com/vinubhat092/crop_fertilizer_prediction_ML (Erişim Tarihi: 08.02.2024).
- Gültepe, Y. (2021). Performance of lung cancer prediction methods using different classification algorithms. *CMC_Computers Materials & Continua*, 67(2), 2015-2028.
- Harrison, O. (2018). Machine Learning Basics with the KNearest Neighbors Algorithm. Retrieved March 23, 2020
- Japkowicz, N. (2011). Performance evaluation for learning algorithms. *Cambridge University Press, Cambridge* 2011.
- Kaggle, 2023 Mahsul Analizi ve Tahmini, Erişim adresi: <https://www.kaggle.com/code/theeyeschico/crop-analysis-and-prediction/input> (Erişim Tarihi: 08.02.2024)

- Lorena, A. C., Jacintho, L. F., Siqueira, M. F., De Giovanni, R., Lohmann, L. G., De Carvalho, A. C., & Yamamoto, M. (2011). Comparing machine learning classifiers in potential distribution modelling. *Expert Systems with Applications*, 38(5), 5268-5275.
- Orhan, Y., & Türker, T. (2023). Akıllı Tarım Uygulamaları için Histogram ve Makine Öğrenimi Kullanan Bitki Sınıflandırma Yöntemi. *Acta Infologica*, 7(1), 17-28.
- Özdemir, S. (2018). Random Forest Yöntemi kullanılarak potansiyel dağılım modellemesi ve haritalaması: Yukarıgökdere Yöresi örneği. *Turkish Journal of Forestry*, 19(1), 51-56.
- Özer B, Kuş S & Yıldız O. (2022). Veri Madenciliği Yöntemleri İle Tarımsal Veri Analizi: Bir Akıllı Tarım Sistemi Önerisi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 10(4), 1417-1429.
- Özlem, A. K. A. R., & Güngör, O. (2012). Rastgele orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması. *Jeodezi ve Jeoinformasyon Dergisi*, (106), 139-146.
- Priya, R., Ramesh, D., & Khosla, E. (2018, September). Crop prediction on the region belts of India: a Naïve Bayes MapReduce precision agricultural model. In 2018 international conference on advances in computing, communications and informatics (ICACCI) (pp. 99-104). IEEE.
- Rish, I. (2001). An empirical study of the naive Bayes classifier. In IJCAI 2001 workshop on empirical methods in artificial intelligence (Vol. 3, No. 22, pp. 41-46).
- Stoltzfus, J. C. (2011). Logistic regression: a brief primer. *Academic emergency medicine*, 18(10), 1099-1104.
- Xie, Y., & Peng, M. (2019). Forest fire forecasting using ensemble learning approaches. *Neural Computing and Applications*, 31, 4541-4550. <https://doi.org/10.1007/s00521-018-3515-0>.
- Yakut, Y. B. E. T. Y., YAKUT, E., & Yavuz, S. (2014). Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 19(1), 139-157.
- Yenikaya, M. A., Güvenoğlu, E., & Kondakci, S. (2022). Nesnelerin İnterneti (IoT) Tabanlı Akıllı Sulama ve Gübreleme Sistemi. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 15(1), 14-23.
- Yıldırım, O., Gunay, F. B., & Yağanoğlu, M. (2023). Makine Öğrenmesi Yöntemleriyle Orman Yangını Tahmini. *Journal of the Institute of Science and Technology*, 13(3), 1468-1481.
- Yoon, J. (2021). Forecasting of real GDP growth using machine learning models: Gradient boosting and random forest approach. *Computational Economics*, 57(1), 247-265.