



T.C.  
NECMETTİN ERBAKAN  
ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ



**DERİN ÖĞRENME VE MAKİNE  
ÖĞRENMESİ YÖNTEMLERİ İLE  
HİDROPONİK TARIM**

**Nurten BULUT**

**YÜKSEK LİSANS TEZİ**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Ocak-2023  
KONYA  
Her Hakkı Saklıdır**

## ÖZET

### YÜKSEK LİSANS TEZİ

# DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE HİDROPONİK TARIM

Nurten BULUT

Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: DOÇ.DR. Mehmet HACİBEYOĞLU

2023, 65 Sayfa

Jüri

Danışmanın Doç.Dr. Mehmet HACİBEYOĞLU  
Dr.Öğr.Üyesi Burcu BAKIR GÜNGÖR  
Dr. Öğr. Üyesi Alperen EROĞLU

Günümüzde dünyamızın hızla artan nüfusu karşısında, hızla azalan ham madde ve besin gibi ihtiyaçların karşılanması için araştırmacılar yeni kaynak arayışlarının yanında var olan kaynakları daha etkin ve verimli kullanan çalışmalara da yöneldiler. İnsanlığın en büyük ihtiyaçlarından biri olan besin ihtiyacının karşılanmasında kullanılacak alternatif yöntemlerden biri olan hidroponik tarımın kullanımı gün geçtikçe daha popüler hale gelmiştir. Toprak yerine besin solüsyonlu su kullanılması, hava şartlarından etkilenmemesi, kapalı alanlarda uygulanabilmesi ve dikey yönlü olabilmesi hidroponik tarımı diğer tarım yöntemlerinden daha farklı kılan özelliklerdir. Bunun yanında bu tarım yönteminde toprak bulunmaması beraberinde daha çok gözlem ve gözetim ihtiyacını getirmektedir. Bu çalışmanın amacı, hidroponik tarımda verimin artırılması için gerekli olan gözlem ve gözetim ihtiyacının makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak sağlanabileceğini göstermektir. Bu amaçla beş adet makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak yapılan deneysel çalışmalarda hidroponik tarımın verimliliğinin artırıldığı gözlemlenmiştir. Derin öğrenme yöntemi %99,7 başarı ile diğer yöntemlere göre daha iyi sonuç elde etmiştir.

**Anahtar Kelimeler:** Akıllı Tarım, Derin Öğrenme, Hidroponik Tarım, Makine Öğrenmesi.

**ABSTRACT**

**MS THESIS**

**HYDROPONIC AGRICULTURE WITH DEEP LEARNING AND MACHINE  
LEARNING METHODS**

**Nurten BULUT**

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF  
NECMETTİN ERBAKAN UNIVERSITY  
THE DEGREE OF MASTER OF SCIENCE  
IN COMPUTER ENGINEERING**

**Advisor: Assoc. Prof. Dr. Mehmet HACIBEYOĞLU**

**2023, 65 Pages**

**Jury**

**Advisor Assoc. Prof. Dr. Mehmet HACIBEYOĞLU**

**Dr.Öğr.Üyesi Burcu BAKIR GÜNGÖR**

**Dr. Öğr. Üyesi Alperen EROĞLU**

In the face of the rapidly increasing population of our world today, researchers have turned to studies that use existing resources more effectively and efficiently in addition to searching for new resources in order to meet the rapidly decreasing needs such as raw materials and nutrients. The use of hydroponic agriculture, which is one of the alternative methods that can be used to meet the need for nutrients, which is one of the greatest needs of humanity, has become more popular day by day. The use of nutrient solution water instead of soil, the fact that it is not affected by weather conditions, that it can be applied indoors and that it can be vertically oriented are the characteristics that make hydroponic agriculture different from other agricultural methods. In addition, the lack of soil in this agricultural method brings with it the need for more observation and supervision. The aim of this study is to show that the observation and surveillance needs necessary to increase yield in hydroponic agriculture can be achieved using machine learning and deep learning methods. For this purpose, it has been observed that the efficiency of hydroponic agriculture has been increased in experimental studies conducted using five machine learning and deep learning methods. The deep learning method has achieved better results with 99.7% success compared to other methods.

**Keywords:** Smart Farming, Deep Learning, Hydroponic Farming, Machine Learning.

## ÖNSÖZ

Tez çalışmam sırasında yaptığı katkıları ve desteklerinden dolayı danışmanım Necmettin Erbakan Üniversitesi Bilgisayar Mühendisliği öğretim üyesi Doc. Dr. Mehmet HACIBEYOĞLU'na ve beni daima destekleyen aileme teşekkür ederim.

Nurten BULUT  
KONYA-2023

# İÇİNDEKİLER

|  |            |
|--|------------|
| <b>ÖZET</b> .....                        | <b>i</b>   |
| <b>ABSTRACT</b> .....                    | <b>ii</b>  |
| <b>ÖNSÖZ</b> .....                       | <b>iii</b> |
| <b>İÇİNDEKİLER</b> .....                 | <b>iv</b>  |
| <b>SİMGELER VE KISALTMALAR</b> .....     | <b>vii</b> |
| <b>1. GİRİŞ</b> .....                    | <b>1</b>   |
| 1.1. Çalışmanın Amacı.....               | 3          |
| 1.2. Çalışmanın Önemi.....               | 3          |
| 1.3. Tezin Yapısı .....                  | 4          |
| <b>2. KAYNAK ARAŞTIRMASI</b> .....       | <b>5</b>   |
| <b>3. MATERYAL VE YÖNTEM</b> .....       | <b>10</b>  |
| 3.1. Hidroponik Tarım .....              | 10         |
| 3.1.1. Ortam .....                       | 11         |
| 3.1.1.1. Taşyünü .....                   | 11         |
| 3.1.1.2. Genleştirilmiş Kil.....         | 11         |
| 3.1.2. Damlama Sistemi .....             | 12         |
| 3.2. Nesnelerin İnterneti.....           | 12         |
| 3.2.1. Arduino .....                     | 13         |
| 3.2.1.1. Kullanılan Arduino Kartı .....  | 14         |
| 3.2.1.2. Sensör ve Modüller .....        | 15         |
| 3.2.1.2.1. Renk ve Işık Sensörleri ..... | 15         |
| 3.2.1.2.2. Nem ve Sıcaklık Sensörü ..... | 15         |
| 3.2.1.2.3. Kablosuz Haberleşme .....     | 16         |

|  |           |
|--|-----------|
| 3.2.1.2.4. Rôle .....  | 17        |
| 3.2.1.2.5. Diğer.....  | 17        |
| 3.3. Makine Öğrenmesi.....   | 19        |
| 3.3.1. Model Seçimi ve Değerlendirilmesi .....                       | 21        |
| 3.3.1.1 Ampirik Hata ve Aşırı Uyum (Overfitting) .....               | 21        |
| 3.3.1.2. Değerlendirme Yöntemleri .....                              | 22        |
| 3.3.1.2.1. Hold-Out .....  | 22        |
| 3.3.1.2.2. Çapraz Geçerlilik (Cross-Validation) .....                | 22        |
| 3.3.1.3 Performans Ölçüsü.....                                       | 23        |
| 3.3.1.3.1 Hata Oranı ve Doğruluk.....                                | 23        |
| 3.3.1.3.2 Kesinlik (Precision), Duyarlılık (Recall) ve F1 Skoru..... | 23        |
| 3.3.1. Denetimli Öğrenme.....  | 25        |
| 3.3.1.1. Sınıflandırma.....  | 25        |
| 3.3.1.1.1. Naive Bayes .....   | 25        |
| 3.3.1.1.2. Karar ağaçları.....                                       | 26        |
| 3.3.1.1.3. Destek Vektör Makinesi.....                               | 27        |
| 3.3.1.1.4. K-En Yakın Komşu.....                                     | 28        |
| 3.3.1.1. Regresyon.....  | 28        |
| 3.3.1.1.1. Doğrusal Regresyon.....                                   | 28        |
| 3.4. Derin Öğrenme.....  | 29        |
| 3.4.1.Sigmoid .....  | 29        |
| 3.4.2. Softmax .....   | 30        |
| 3.4.3. Adamax Optimizasyon Algoritması.....                          | 31        |
| 3.4.4. Kayıp Oranı Hesaplanması .....                                | 31        |
| 3.4.4.1. CategoricalCrossentropy Sınıfı .....                        | 31        |
| 3.5. SMOTE.....  | 32        |
| 3.6. Veri Seti .....   | 33        |
| <b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>                       | <b>36</b> |
| 4.1.1. Hold - Out Yöntemi .....                                      | 36        |
| 4.1.2. Cross -Validation Yöntemi .....                               | 36        |

|                                      |   |
|--------------------------------------|---|
| 4.2. Performans Ölçütleri .....      | 36                                      |
| <b>5. SONUÇLAR VE ÖNERİLER .....</b> | <b>45</b>                               |
| 5.1 Sonuçlar .....                   | 45                                      |
| 5.2 Öneriler .....                   | 45                                      |
| <b>KAYNAKLAR .....</b>               | <b>47</b>                               |
| <b>ÖZGEÇMİŞ.....</b>                 | <b>Hata! Yer işareti tanımlanmamış.</b> |



## SİMGELER VE KISALTMALAR

### Simgeler

|             |                    |
|-------------|--------------------|
| $\cup$      | Birleşim           |
| $\cap$      | Kesişim            |
| $\emptyset$ | Boş Küme           |
| $\in$       | Kümenin Elemanıdır |

### Kısaltmalar

|         |   |
|---------|---|
| AI      | Yapay Zeka  |
| EC      | Elektrik İletkenliği  |
| DNN     | Derin Sinir Ağları  |
| FAO     | Birleşmiş Milletler Gıda ve Tarım Örgütü                    |
| kNN     | k-En Yakın Komşu  |
| ICSP    | Devre İçi Seri Programlama                                  |
| IoT     | Nesnelerin İnterneti  |
| LED     | Işık Yayan Diyot  |
| M.Ö.    | Milattan Önce   |
| MQTT    | MQ Telemetry Aktarımı (Message Queuing Telemetry Transport) |
| OWL     | Ontoloji Web Dili   |
| pH      | Potansiyel Hidrojen   |
| PPM     | Milyonda Bir Parça  |
| RDF     | Kaynak Açıklama Çerçevesi                                   |
| SD Kart | Güvenli Sayısal Hafıza Kartı                                |
| SVM     | Destek Vektör Makinesi                                      |
| SMOTE   | Sentetik Azınlık Aşırı Örnekleme Tekniği                    |
| TDS     | Toplam Çözünmüş Katılar                                     |
| TCP/IP  | İletim Kontrol Protokolü/İnternet Protokolü                 |
| UN-BM   | Birleşmiş Milletler   |
| USB     | Evrensel Seri Veri Yolu                                     |
| Wi-Fi   | Kablosuz Bağlantı Alanı                                     |

## 1. GİRİŞ

Dünya nüfusu büyüdükçe artan gıda üretimi talepleri genişlemekte ve toprak, su ve besin gibi kaynaklar üzerindeki stresler gittikçe artmakta, bu nedenle gıdayı sağlamak için alternatif, sürdürülebilir ve güvenilir yöntemler bulmak amacıyla acil bir ihtiyaç duyulmaktadır (Goddek ve diğ., 2019). Bu kaynakların mevcut tüketimi veya kaynakların bozulması küresel yenilenme oranlarını aşmaktadır (Van Vuuren ve diğ., 2010).

Sürdürülebilir Kalkınma için 2030 Gündemi, iklim değişikliğinden yoksulluğa kadar değişen küresel zorlukların üstesinden gelme ihtiyacını vurgulamaktadır ve sürdürülebilir gıda üretimi yüksek bir önceliğe sahiptir (Brandi, 2017; UN, 2017). BM'nin Sürdürülebilir Kalkınma Hedefi 2'ye (UN, 2017) yansıdığı üzere, dünyanın karşı karşıya olduğu en büyük zorluklardan biri, 2050 yılına kadar yaklaşık 10 milyara çıkması öngörülen büyüyen küresel nüfusun beslenme ihtiyaçlarını karşılayabilmesinin nasıl sağlanacağıdır. 2050 yılına kadar iki milyar insanı daha beslemek için gıda üretiminin küresel olarak %50 artması gerekecektir (FAO, 2017). Daha fazla gıda üretilmesi gerekmektedir birlikte, artan kentleşme nedeniyle kırsal işgücünün daralması söz konusudur (dos Santos, 2016). Küresel kırsal nüfus 1960'tan 2015'e kadar olan dönemde %66,4'ten %46,1'e düşmüştür (FAO, 2017). 2017 yılında kentsel nüfus toplam dünya nüfusunun %54'ünden fazlasını temsil ederken, dünya nüfusunun neredeyse gelecekteki tüm büyümesi kentsel alanlarda gerçekleşecektir, öyle ki 2050 yılına kadar küresel nüfusun %66'sı şehirlerde yaşayacaktır (UN, 2014).

Küresel gıda güvenliğini sağlamak için, 'aşırı yoksulluk ve açlığın ortadan kaldırılması' ve ayrıca 'çevresel sürdürülebilirliğin sağlanması' da dahil olmak üzere Binyıl Kalkınma Hedeflerini (FAO 2009) karşılamak üzere toplam gıda üretiminin önümüzdeki yıllarda %70'in üzerinde artması gerekecektir. Aynı zamanda, gıda üretimi kaçınılmaz olarak iklim değişikliği, kirlilik, biyo-dönüşüm kaybı, tozlayıcı kaybı ve ekilebilir arazilerin bozulması gibi diğer zorluklarla karşı karşıya kalacaktır. Bu koşullar, zaten küresel ölçekte toprak, su ve biyoçeşitlilik düşmeye devam ederken, daha verimli ve sürdürülebilir tarım sistemi üretim yöntemleri ve hızlı gıda tedarik zinciri teknolojilerinde gelişmeler olmasını gerektirir (Foley ve diğ., 2011; Godfray ve diğ., 2010).

Bu faktörlerin üstesinden gelinmesi için hidroponik gibi değişik tarım teknikleri denenebilir. Hidroponik terimi oldukça yeni bir terim gibi görünse de topraksız bitki yetiştiriciliği fikri oldukça eskilere dayanır. Babil'in asma bahçeleri ve Meksika'nın

Azteklerinin yüzen bahçeleri gibi çok daha erken dönem örnekleri mevcuttur (Resh H.M., 2012).

Hidroponik bitki üretimi, son yıllarda dünya çapında önemli ölçüde artmıştır, çünkü su ve gübrelerin daha verimli kullanılmasına, ayrıca iklimin ve zararlı faktörlerin daha iyi kontrol edilmesine olanak sağlamaktadır. Ayrıca, hidroponik üretim, ürün kalitesini ve üretkenliğini arttırmak da, bu da daha yüksek rekabet gücü ve ekonomik gelirlerle sonuçlanmaktadır (T. Asao., 2012).

Hidroponik sistemdeki temel bileşen besin çözeltisi ile temsil edilir. Elektriksel iletkenlik veya ozmotik basınç olarak adlandırılan besin çözeltisi konsantrasyonunun kontrolü, çok çeşitli türlerin kültürüne izin verir. Dahası, bitkiye besin tedarikinin doğru kontrolü, topraksız kültürün ana avantajını temsil eder. Ek olarak, diğer faktörlerin yanı sıra pH, kök sıcaklığının düzenlenmesi, verim ve kalitenin artmasını sağlar.

Hidroponik, çok yönlü bir teknolojidir. Bu teknoloji hem köy hem de arka bahçe üretim sistemleri için uygun olmakla beraber aynı zamanda yüksek teknolojikli uzay istasyonlarına uygun çok yönlü bir teknolojidir. Hidroponik teknoloji, çöller, dağlık bölgeler veya kuzey kutbu toplulukları gibi aşırı çevresel ekosistemlerden gıda üretimi için etkili bir araç olabilir. Yüksek nüfuslu bölgelerde, hidroponik, yapraklı sebzeler veya kesme çiçekler gibi yerel olarak yetiştirilen yüksek değerli ürünler sağlayabilir.

Ekonomik faydaların yanı sıra, hidroponik, suyun korunması, enerjinin kojenerasyonu, gelir üreten istihdam ve yaşam kalitesinin iyileştirilmesi anlamına gelir. Günümüzde, hidroponiğin geliştirilmesi ve kullanılması, hem gelişmekte olan hem de gelişmiş ülkelerdeki birçok topluluğun ekonomik refahını arttırmıştır (T. Asao., 2012).

Herhangi bir hidroponik sistemde, hassas tarımda etkili bitki büyümesi ve verim tahmini önemlidir. Model büyüme sistemlerinin iyileştirilmesi, gelişmiş bitkisel üretim ve daha kaliteli gıda için bitki büyüme koşullarını iyileştirebilir ve piyasa talebini daha düşük maliyetlerle karşılayan kaynak kullanım verimliliğini (örneğin hafif kullanım verimliliği, gübre kullanım verimliliği, su kullanım verimliliği) artırabilir. Son zamanlarda, farklı Yapay Zeka (AI) teknikleri güçlü analitik araçlar sağlamak için makine öğrenimi ve derin öğrenme yöntemleri kullanılır (Mohmed, G. ve diğ., 2022).

Makine öğrenimi, çevreden öğrenerek insan zekasını taklit etmek için tasarlanmış, gelişen bir hesaplama algoritmaları dalıdır. Makine öğrenimine dayalı teknikler örüntü tanıma, bilgisayarla görme, uzay aracı mühendisliği, finans, eğlence ve hesaplamalı biyolojiden biyomedikal ve tıbbi uygulamalara kadar çeşitli alanlarda başarıyla uygulanmıştır (El Naqa, I. ve diğ., 2015).

Derin öğrenme, birden çok işlem katmanından oluşan hesaplama modellerinin, verilerin temsillerini birden çok soyutlama düzeyiyle öğrenmesini sağlar. Bu yöntemler, konuşma tanıma, görsel nesne tanıma, nesne algılama ve ilaç keşfi ve genomik gibi diğer birçok alanda en son teknolojiyi önemli ölçüde geliştirmiştir. Derin öğrenme, bir makinenin her katmandaki gösterimi önceki katmandaki gösterimden hesaplamak için kullanılan iç parametrelerini nasıl değiştirmesi gerektiğini belirtmek için geri yayılım algoritmasını kullanarak büyük veri kümelerindeki karmaşık yapıyı keşfeder. Derin kıvrımlı ağlar, görüntü, video, konuşma ve ses işlemede atılımlara yol açarken, tekrarlayan ağlar metin ve konuşma gibi sıralı verilere ışık tutmuştur (LeCun, Y., ve diğ., 2015).

### **1.1. Çalışmanın Amacı**

Bu tez çalışmasında derin öğrenme ve makine öğrenmesi yöntemleri kullanılarak hidroponik tarımda hassas olarak tanımlanan bitki ihtiyaç değerlerinin tahmininde kullanılıp kullanılmayacağı araştırılmıştır. Çalışmada araştırma için oluşturulan hidroponik tarım sisteminde 12 adet domates bitkisi kullanılmıştır. Çalışma için bitkilerin en çok ihtiyaç duydukları pH, elektrik iletkenliği, sıcaklık ve benzeri değerler ölçülerek toplanmıştır. Ölçümler sonucu bitkinin en önemli değerlerinden olan pH ve EC değerinin sınıflandırılması amaçlanmıştır.

### **1.2. Çalışmanın Önemi**

Hidroponik tarımda bitki hataları tolere eden toprak etmenine sahip olmadığı için değişimlerden daha çabuk etkilenmektedir. Ayrıca bitki kökleri aynı su kanalını kullanmaları nedeniyle sistemdeki herhangi bir bitkide yaşanacak problemin, hastalıkların ya da sorunların diğer bitkilere yayılması oldukça kolay olacaktır. Bu nedenle hidroponik tarım pek çok faydalı özelliklerine rağmen dikkatli takip ve sisteme hızlı müdahale edilmesini gerekli bulmak gibi zorluklara sahip olmaktadır. Son yıllarda yaşanan teknolojik gelişmelerle birlikte makine öğrenmesi ve derin öğrenme yöntemleri bu soruna çözüm olup olmayacağı hususundaki araştırmalarda kullanılan yöntemler olmaya başlamıştır.

Bu çalışma var olan araştırmaların göz önüne alınmasının yanında sektördeki gerçek üretici mühendisler ile iletişime geçerek elde edilen teorik ve pratik bilgilerin

harmanlanması ile yeni bir sistem tasarımı önermektedir. Bu sistem tasarımı var olan arařtırmalardaki özelliklerin ölçümünün yanında sistemin giriş ve çıkış deęerlerinin ayrı ayrı ölçülmesi ile sistemdeki bitki saęlığını kontrol etmektedir. Bu sistem tasarımı daha geniş kapsamlı ve sistem hakkında daha detaylı bilgi saęlayan özelliklere sahip olmuştur.

Bu çalışmanın konusu olan hidroponik tarım bu alandaki tecrübeli tarımcı eksiğini azaltmak amacıyla bitkinin ihtiyaç duyduğu deęerleri tespit ederek katkı saęlamaktadır.

### **1.3. Tezin Yapısı**

Bu tez çalışması toplamda beş ana bölümden oluşmaktadır.

Birinci bölümde çalışmanın konusunu oluşturan hidroponik tarımda yaşanan problemler ve makine ile derin öğrenme yaklaşımından bahsedilmiştir.

İkinci bölüm olan kaynak arařtırmasında ise literatürde bulunan önceki çalışmalar incelenmiştir.

Üçüncü bölüm, çalışmada sınıflandırılması amaçlanan hidroponik tarım alanları, sınıflandırmada kullanılacak derin öğrenme algoritmaları ve kullanılan teknolojiler ile çalışmada kullanılan veri seti hakkında bilgiler içermektedir.

Dördüncü bölümde çalışma kapsamında arařtırılmış makine ve derin öğrenme modeller veri setine uygulanmış ve yapılan test sonuçları paylaşılmıştır.

Beşinci bölümde ise elde edilen sonuçlar deęerlendirilmiş, yorumlar yapılmış ve muhtemel yeni çalışmalar hakkında bilgilere verilmiştir.

## 2. KAYNAK ARAŞTIRMASI

Hidroponik tarımın ihtiyaç duyduğu dengeler oldukça hassas olduğu için pek çok çalışma bu konuya yardımcı olarak tarımda yeni bir ilerleme sağlamanın yolunu açmaya çalışmaktadır. Pek çok çalışma hidroponik tarıma yardımcı olmak için gelişen teknolojiden yararlanmak istemektedir.

Bazı çalışmalar, hidroponik tarım için kendin yap sensör tabanlı otomatik kontrol mobil uygulamalar tasarlamışlardır. Bu mobil uygulama tasarımında sıcaklık, nem ve ışık gibi farklı sensörler kullanarak hidroponik için otomatik çevre kontrolü sağlanmıştır. Dikim taleplerini yerine getirmek için, veri kayıtlarının planlanması, yürütülmesi ve hasat edilmesinden oluşur. Yetiştirme için bu hasat kayıtları göz önüne alınabilir. Çiftçi, mahsulün ilerlemesini uzaktan izleyebilir (Chanya P., ve diğ., 2016).

Mobil uygulama oluşturulan bir başka çalışmada ise uygulamanın çiftçiye rehberlik yapması amaçlanmıştır. Bu mobil uygulamada, sensör teknolojisi cihazları mobil cihaz üzerinden kesin ve doğru bir şekilde kontrol edecektir. Kalan kısım, çeşitli aşamalardaki bitki büyümesi, sulama planları ve günlük ihtiyaç duyulan su miktarı izleme sistemi ile yapılmaktadır. Çiftçiye uygun zamanda rehberlik ve yardım sağlar. Veri koleksiyonları için Thingspeak bulut hizmeti kullanılır. Sistem konum bilgisi, pazarlama, hava durumu tahmini sağlar (Jumras P, ve diğ., 2016).

Bazı diğer araştırmalarda değer takibinin yanında çiftlik ile ilgili değişen koşullar çiftçiye bildirim olarak gönderilmiştir. Tarım alanıyla tam otomatik ve entegre olabilen sistem iş güdüsü amacı içinde tasarlanmış ve inşa edilmiştir. Uygun sıcaklık yönetimi kullanılarak su ve besin için Arduino tabanlı otomasyon yapılır. Olumsuz bir durumda, göstergeler ve alarmlarla uyarı sağlar. Çiftlik ile ilgili tüm detayları çiftçiye sürekli olarak bildirir (R. Nalwade, ve diğ., 2017)..

Bazı araştırmacılar ise çiftçileri hedef kitle olarak alan sistem tasarımları yerine profesyonel olmayan kullanıcıları hedeflemişlerdir. Sistem, şehirlerde yaşayan ve tarım yapan profesyonel olmayan çiftçileri desteklemektedir. Hidroponik tarım ekosistemi, nemi, sıcaklığı, pH'ı ve elektriksel iletkenliği izlemek için nesnelerin interneti cihazlarını kullanır. Üç bölüm vardır: sensörler, sensörlerin düzenlenmesi için manipüle edilen kontrol sistemi ve uygulama. MQTT Komisyoncusu, IoT için bağlantı protokolü, verileri göndermek ve almak için bir ara maddeye sahiptir. Android uygulaması, sistemi güvenilir ve kullanımı kolay hale getirmek için kullanılır (S. Ruengittinun, ve diğ., 2017).

Nesnelerin internetine dayalı hidroponik tarımın izlenmesi ve yönetimi için entegre bir sistem sunan başka arařtırmalar da bulunmaktadır. Yukarıdaki sistemler gibi sistem aynı zamanda hayatta kalmak amacıyla bitkiler için ideal ortamı saęlamaktan bahseder. Basit bir mekanizma ile sistem kontrollü bir sulama ve besin solüsyonu iletilmesini saęlar. Sistemin arka ucu sensörler ve bulut tabanlı teknoloji tarafından saęlanan verilerdir. İnternet ile bilgiler kullanıcılar tarafından saklanır, yönetilir, uygulanır ve paylaşılır. Sistem, drenaj, fan, yaęmurlama ve su pompasının kontrolü için web uygulamasını kullanır. Kaynakların etkin yönetimi verimli bir hidroponik sistemle sonuçlanır (C. J. G. Aliac, ve dię., 2018).

Bazı sistemler ise sadece izlenme deęil, sistemin kontrolünü de saęlar. Sistem, sensör aęlarını ve aktüatörleri kullanarak bitki büyümesi sırasında izlemeyi minimize eder. Sensör aęları, çiftlikteki farklı fiziksel olayların izlenmesine ve kontrol edilmesine yardımcı olur. Mesaj sistemi üzerinden kararlar verilerek fiziksel olaylar kontrol edilir. Sistem tarafından gösterilen sensör deęerlerindeki minimum dalgalanma otomatik kontrol ile sonuçlanacaktır. Sistem, kullanıcıya doęru kararlar verilmesinde yardımcı olur ve mahsulün büyümesine yardımcı olur (P. Belhekar, ve dię., 2018).

IoT kavramı ile bir hidroponik sistem tasarlanmış, geliştirilmiş, uygulanmış ve veri toplama modülü olarak açık bahçe kullanılmıştır. Veriler toplandıktan sonra bulut sunucusuna ulařır ve ardından Wi-Fi modülü ile aktarılır. Veriler, web veya akıllı telefondaki web uygulaması veya android uygulaması kullanılarak görüntülenir (A. Munandar, ve dię., 2018).

Başka bir arařtırmada oluşturulan otomatik sistemde ise LED aydınlatma teknolojisi ile birlikte IoT tarafından etkinleřtirilen akıllı bir hidroponik sistem oluşturulmuştur. Çeřitli kořullar altında bitkiler yetiřtirilir ve parametreler karakterize edilir. Mavi ek ışığın kullanılması, yaprak yoğunluęunun, biyokütlenin ve dięer özelliklerin daha fazla birikmesine yol açmıştır. LED ışık dizileri mikrodenetleyici tarafından kontrol edilmiş ve düzenlenmiştir. Gerçek zamanlı görüntü aktarımı yapabilen kamera kullanımı ile sensör deęerlerinin, aktüatörlerin ve güneř enerjisinin gerçek zamanlı izlenmesi saęlanmıştır. Verileri bulut sunucusuna iletmek için Wi-Fi modülü kullanılmıştır. Akıllı kararların yürütülmesi ve izlenmesi amaçlanan sistemde çiftçilerin kolay eriřim için sistem tamamen otomatiktir (T. Namgyel, ve dię., 2018).

Bir başka arařtırmacı ise kapalı çevrim hidroponik sistemlerde otomatik besin tedariki için iki alternatif teknik önermiştir. Önerilen her iki sistem de girdi olarak elektrik iletkenlięi ve pH'ı ve çıktı olarak besin veya tatlı su ilavesini kullanır. İlk sistem birkaç

pompa kullanır (biri her besin için diğeri tatlı su için), ikincisi ise sadece iki pompaya sahiptir (biri gübre için diğeri tatlı su için). Araştırmacı, her iki sistemin de hidroponik sistemlerdeki besin maddelerinin yenilenmesinde kullanılabileceği sonucuna varmıştır (Savvas D., ve diğ., 2002).

Ayrıca, başka araştırmacılar, besin seviyesini ölçmek için parametre olarak pH, sıcaklık ve elektrik iletkenliğini kullanan otomatik bir hidroponik sistem geliştirdi. Sıcaklığın hem pH hem de elektrik iletkenliği ile doğrudan ilişkili olduğu için çok önemli bir parametre olduğunu savundular. Sistem marul (*Lactuca sativa* L.) yetiştiriciliğinde kullanıldı. Önerilen sistemde, her besin için bir tane olmak üzere bir elektrikli valf sistemi kullanıldı. Bu valf sistemleri, besin çözeltisinin pH seviyesini kontrol etmek için kullanıldı. Araştırmacılar, önerilen sistemin uzmanlar tarafından kontrol edilen hidroponik sistem kontrolü kadar iyi olduğunu göstermektedir (D.S.Domingues, ve diğ., 2012).

Başka araştırmacılar ise geliştirilen hidroponik sistem için ontolojiye dayalı besin çözeltisi kontrol sistemi geliştirmiştir. Araştırmacılar, akıllı bir hidroponik sistem inşa etmenin karmaşık bir görev olduğunu ve Ontoloji Web Dili (OWL) ve Kaynak Açıklama Çerçevesi (RDF) kullanılarak tasarlanması gerektiğini savundular. Sistem, ayrı bir asit tankı kullanılarak iki besin tankı ve pH seviyeleri ile besin tedarikini kontrol eder. Sistem ayrıca su temini için dördüncü bir depoya sahiptir. Sistem besin çözeltisini izlemek için EC kullanır. Araştırmacılar, OWL ve RDF'den kontrol değişkenlerinin bir ontolojisini oluşturdu. Ontoloji, hidroponik sistemleri daha etkin hale getiren yapı ve mekanizmayı tasarlayabilir (A.Phutthisathian, ve diğ., 2011).

Başka bir araştırmacı, geliştirdiği küçük bir kapalı hidroponik sistemle 10 baş marul yetiştirdi. Bu araştırmada, kapalı bir hidroponik sistem, iç mekanlarda veya aydınlatmanın kontrol edilebileceği bir serada kullanılmak üzere tasarlanmış bir hidroponik sistemdir. Sistem, sistemin ve dış çevresinin sıcaklığını ve nemini izlemek için sensörlere sahiptir. Ayrıca ortam ışığını ölçmek için bir ışık sensörüne sahiptir. Sistemde beyaz LEDler, bir soğutma fanı, besin çözeltisine oksijen sağlamak için bir hava pompası bulunur. Sistemi gözlemlemek için kameralı bir Raspberry Pi de kuruldu. Araştırmacılar ayrıca hidroponik sistemi yönetmek için yenilenebilir enerji kullandılar. Kurşun-asit akü ve hidrojen yakıt hücresel akü kullanan hibrit bir enerji kontrol sistemi devreye alındı. Önerilen sistem, kurulum kolaylığı nedeniyle her eve topraksız tarım getirme potansiyeline sahiptir. Ayrıca yenilenebilir enerji kullanımını sistemin karbon ayak

izini azaltır. Araştırmacılar marulları 28 gün sonra hasat edebildiler. Fakat önerilen sistemin verimli çalışabilmesi için insan müdahalesi gerektirmektedir.

Bir başka araştırmada ise otomatik çiftleştirilmiş kapalı bir akuaponik sistem geliştirilmiştir. Bir Arduino Mega mikrodenetleyici tarafından yönetilen sistem, balıkları besler, su sıcaklığını ve seviyesini izler ve kontrol eder. Pompa, sistemde kullanılan su ıspanağı (*Ipomoea aquatica*) ve ıspanak (*Spinacia oleracea*) sulamak için kullanıldı. Ek olarak, bağımsız sistem mikrodenetleyicinin faaliyetlerinin günlüğünü tutmak için bir SD kart kullanır. Bununla birlikte, sistem kullanıcı tarafından belirlenen sabit parametrelere bağlıdır, ayrıca sistem akuaponik sisteminin sıcaklığını artırabilecek 100W'LIK bir ışık kaynağı kullandı (S.Yamaguchi, ve diğ., 2018).

Bir başka araştırmacı, domates F1 Hibrit Suhana tohumlarını yetiştirmek için otomatik bir hidroponik sistem geliştirdi. Sistem, su, ışık, besin miktarı ve sıcaklık gibi sensörden Raspberry Pi modeline yazılarak kaynakların sınıflandırılması kullanılarak kontrol edilir; sıcaklık seviyesi (Soğuk, Orta, Sıcak), su seviyeleri (Düşük, Normal, Yüksek), pH seviyeleri(Asit, Nötr, Alkali) ve Işık Şiddeti (Düşük, Normal, Yüksek) şeklinde uygulanan kapalı bir hidroponik sistemdir. Araştırmacıların çıktı eşiği basitçe uygun veya uygunsuz olan bir sistem şeklinde kategorize etmenin, sistemi okumayı otomatikleştirmek için bir model geliştirmeyi kolaylaştıracağını savundular. Makale, taksonomi sistemlerinin AI kontrollü bir hidroponik sistem için kullanılabilirliği sonucuna varmıştır. Bununla birlikte, verilerin evrensel kategorilere sınıflandırılması zor olabilir, çünkü her bitkinin mutlaka diğer bitkilerin kapsamına girmeyecek farklı bir gereksinimi vardır (G.Dbritto, ve diğ., 2018).

Bir başka araştırmadaki yazarlar, 3 klasik makine öğrenimi sınıflandırıcısının performansını araştırdılar: karar ağacı, Naive Bayes, çok katmanlı algılayıcı ve hidroponik bir sistemden hasat edilen bitki örtüsünün tazeliğini tespit etmede bir tür derin sinir ağı. Önerilen sistem, taze ve solmuş sebzeleri tespit etmek için görüntü işleme ve makine öğrenme teknolojilerini kullandı. Deney, karar ağacı (J48) modelinin %98.12'lik en iyi doğruluğa sahip olduğunu göstermektedir. Bu sistem, hidroponik bir sistemde yetiştirilen mahsullerin hasat edilmesinde ve / veya sağlığının izlenmesi amacıyla da kullanılabilir (K.Wongpatikaseree, ve diğ., 2018).

Bir başka araştırmacı grubu, sistemin su seviyesini, pH'ını, elektriksel iletkenliğini, su sıcaklığını ve bağıl nemini ölçen bir sistem geliştirdi. Veriler bir veri tabanına gönderildi ve sistemdeki besin dengesizliği gibi olaylar çiftçilere bildirildi.

Sistem sadece hidroponik ortamı izlemek için tasarlandı. Bu nedenle, sistemin aktüatörü yoktur ve olayları yönetmek için çiftçiye güvenmiştir (P.Belhekar, ve diğ.,2018).

**Çizelge 2.1.** Kaynak araştırması özetleri

| Makale                            | İzleme | Kontrol | pH | EC | TDS | Su Seviyesi | Hava Sıcaklık ve Nemi | Işık | Su Sıcaklığı | Işık Yoğunluğu | Görüntü | Not   |
|-----------------------------------|--------|---------|----|----|-----|-------------|-----------------------|------|--------------|----------------|---------|---|
| C. J. G. Aliac, ve diğ., 2018     | X      | X       | X  |    |     | X           | X                     |      |              |                |         |   |
| Jumras P, ve diğ., 2016           | X      | X       |    |    |     |             | X                     | X    |              |                |         |   |
| D. Yolanda ve diğ., 2016          | X      | X       | X  | X  |     |             |                       |      |              |                |         | Bulanık Mantık ile Sulama Kontrolü            |
| T. Kaewwiset ve diğ., 2017        | X      | X       | X  | X  |     |             |                       |      |              |                |         | Lineer Regresyon ile besin solüsyonu kontrolü |
| Mehra M. Ve diğ., 2018            | X      | X       | X  | X  |     |             | X                     |      |              |                |         | Derin Sinir Ağları ile sistem kontrolü        |
| M. I. Alipio ve diğ., 2017        | X      | X       | X  | X  |     |             |                       |      |              | X              |         | Bayesian Network ile sınıflandırma            |
| Domingues ve diğ., 2012           | X      | X       | X  | X  |     |             |                       |      | X            |                |         |   |
| D. Eridani ve diğ., 2017          | X      | X       |    | X  | X   | X           |                       |      |              |                |         |   |
| Chanya P., ve diğ., 2016          | X      | X       | X  | X  |     |             | X                     |      | X            | X              |         |   |
| T. Namgyel ve diğ., 2018          | X      |         |    |    |     |             | X                     |      | X            | X              |         |   |
| S. Tagle ve diğ., 2018            | X      |         | X  |    |     | X           | X                     |      | X            | X              |         |   |
| Wongpatika seree, K ve diğ., 2018 | X      |         |    |    |     |             |                       |      |              |                | X       | Karar Ağacı, Naive Bayes                      |

### 3. MATERYAL VE YÖNTEM

#### 3.1. Hidroponik Tarım

Hidroponik, topraksız bitki yetiřtirmek için kullanılan oldukça yeni bir terim olsa da, yöntem çok daha eskilere dayanmaktadır. Babil'in asma bahçeleri, Meksika Azteklerin yüzen bahçeleri ve Çinlilerin bahçeleri, bu şekilde adlandırılmış olmasa da, bir tür “topraksız” kültür yöntemi idi. M.Ö. birkaç yüz yıllık Mısır hiyeroglif kayıtları bile bitkilerin suda büyümesini tanımlar. Theophrastus (M.Ö. 372-287) bitki beslenmesinde çeşitli deneyler yaptı. Dioskorides'in botanik çalışmaları M.Ö. birinci yüzyıla kadar uzanmaktadır.

Bitki bileşenlerini keşfetmeye yönelik kaydedilen en eski bilimsel yaklaşım 1600 yılında Belçikalı Jan van Helmont'un klasik deneyinde bitkilerin sudan madde elde ettiğini göstermesiydi. Tozu uzak tutmak için kaplanmış 90.7 kg kurutulmuş toprak içeren bir tüpe 2.2 kg söğüt filizi dikti. Yağmur suyuyla 5 yıllık düzenli sulamadan sonra, söğüt sürgününün ağırlığının 72.5 kg arttığını, toprağın ise 0.05 kg'dan daha az kaybettiğini buldu. Bitkilerin sudan büyümesi için madde elde ettiği sonucu doğrudur. Ancak, havadan karbondioksit ve oksijene de ihtiyaç duyduklarını fark edemedi. 1699'da bir İngiliz olan John Woodward, çeşitli toprak türlerini içeren suda bitkiler yetiřtirdi ve en büyük büyümenin en fazla toprağı içeren suda gerçekleştiğini buldu. Böylece, bitki büyümesinin, sadece sudan değil, topraktan elde edilen sudaki bazı maddelerin bir sonucu olduğu sonucuna vardı.

Bu maddelerin tanımlanmasında daha fazla ilerleme, daha karmaşık araştırma teknikleri geliştirilinceye ve kimya alanında ilerlemeler kayıt edilinceye kadar yavaştı. 1804'te De Saussure, bitkilerin su, toprak ve havadan elde edilen kimyasal elementlerden oluştuğunu öne sürdü. Bu önerme daha sonra 1851'de Fransız bir kimyager olan Boussingault tarafından bilinen kimyasal bileşimin çözeltilerinin eklendiğı kum, kuvars ve kömürde yetişen bitkilerle yaptığı deneylerde doğrulandı. Suyun hidrojen sağlamada bitki büyümesi için gerekli olduğu ve bitki kuru maddesinin havadan gelen hidrojen artı karbon ve oksijenden oluştuğı sonucuna vardı. Ayrıca bitkilerin azot ve diğer mineral elementleri içerdiğini belirtti.

Nispeten kısa bir sürede, yaklaşık 65 yıl boyunca, hidroponik, açık alan kültüründen ve kapalı sera kültüründen uzay programında son derece uzmanlaşmış kültüre kadar birçok duruma adapte oldu. Bu tarım türü bir uzay çağı bilimidir, ancak

aynı zamanda gelişmekte olan ülkelerin de sınırlı alanda yoğun gıda üretimini sağlamak için kullanılabilir. Sadece sınırlamalar tatlı su ve besin kaynaklarıdır. Tatlı suyun bulunmadığı alanlarda, hidroponik deniz suyunu tuzdan arındırma yoluyla kullanılabilir. Bu nedenle, çöller gibi ekilebilir olmayan geniş alanlara sahip bölgelerde gıda sağlamada potansiyel bir uygulamaya sahiptir. Hidroponik operasyonlar, kıyı bölgeleri boyunca, petrol yakıtlı, güneş veya atomik tuzdan arındırma üniteleri ile birlikte, bitkilerin yetiştirilmesi için ortam olarak plaj kumu kullanılarak yerleştirilebilir (Resh H.M., 2016).

### **3.1.1. Ortam**

Su, köpük, çakıl, taşıyünü, kum, talaş, turba, hindistan cevizi hindistan cevizi, perlit, pomza, yer fıstığı kabuğu, polyester keçeleşme veya vermikülit gibi topraksız bir ortam, oksijen, su, besin ve bitki kökleri için destek sağlamalıdır, tıpkı toprağın yaptığı gibi. Besin çözeltisi su, besin maddeleri ve bir dereceye kadar oksijen sağlayacaktır (Resh H.M., 2016).

#### **3.1.1.1. Taşıyünü**

Taşıyünü, bahçe endüstrisinde hidroponik ortamlar için yaygın olarak toprak yerine kullanılan ortamlardan biridir (Bhattarai, S., 2008). Taşıyünü kültürünün kullanımını ve bitki büyümesi süresince kapalı bir çözelti kültürü sistemini birleştirdiği için kolay, az bakım gerektiren bir hidroponik kültür yöntemidir. Taşıyünü için hidroponik kültürün en zor kısmı iyi bir kök sistemi oluşturmaktır, çünkü genç fideler su kütüğünden kaynaklanan hipoksik strese eğilimlidir. Taşıyünü, diğer ortamlara kıyasla güvenilir ve muntazam fide üretimi için mükemmel, iyi havalandırılmış bir köklenme ortamı sağlar. Taşıyünü, ısıtılmış ve paspaslara bükülmüş magmatik kaya ve kireçtaşı karışımıdır. Doymuş olsa bile, taşıyünü yaklaşık % 15 hava boşluğu tutar.


#### **3.1.1.2. Genleştirilmiş Kil**

Hafif genişletilmiş kil agregası veya genişletilmiş kil, döner bir fırında kilin yaklaşık 1.200 °C'ye (2.190 ° F) ısıtılmasıyla yapılan hafif bir agregadır. Verimli gazlar, ısıtma sırasında oluşan binlerce küçük kabarcık ile kili genişleterek bir petek yapısı oluşturur. Fırındaki dairesel hareket nedeniyle yaklaşık olarak yuvarlak veya patates

şeklinde ve farklı ebat ve yoğunluklarda mevcuttur. Hafif genişletilmiş kil agregası, hafif beton ürünleri ve diğer kullanımları yapmak için kullanılır (URL-1, 2002).

### 3.1.2. Damlama Sistemi

Damlama sistemleri ticari operasyonlarda son derece yaygındır, ancak eğlence bahçelerinde daha az yaygındır. Bunun nedeni, büyük ölçekli bahçeler için basit olmaları, ancak daha küçük bir bahçe için biraz fazla çalışmalarıdır.



Şekil 3.1. Hidroponik sistemde damlama tekniği örneği.

Bu sistemlerin faydaları arasında besleme ve sulama programı üzerinde yüksek düzeyde kontrol sağlama, kırılma olasılığı daha düşük ve nispeten ucuzdur.

Sistemin dezavantajları arasında ise daha küçük bir bahçe için fazla olabilir, dalgalanan pH ve besin seviyeleri (devridaim sistemi kullanılıyorsa) ve yüksek atık (atık sistemi kullanılıyorsa) gibi unsurlar bulunmaktadır (URL-2, 2002).

### 3.2. Nesnelerin İnterneti

Gelecek, gerçek dünya nesnelərini akıllı sanal nesnelere dönüştürecek nesnelərini interneti üzerinedir. Kısaca IoT olarak da bilinen “Nesnelerin İnterneti” ifadesi iki kelimeden türetilmiştir, yani ilk kelime “internet” ve ikinci kelime “nesne” dir. İnternet, dünya çapında milyonlarca kullanıcıya hizmet vermek için standart İnternet protokol

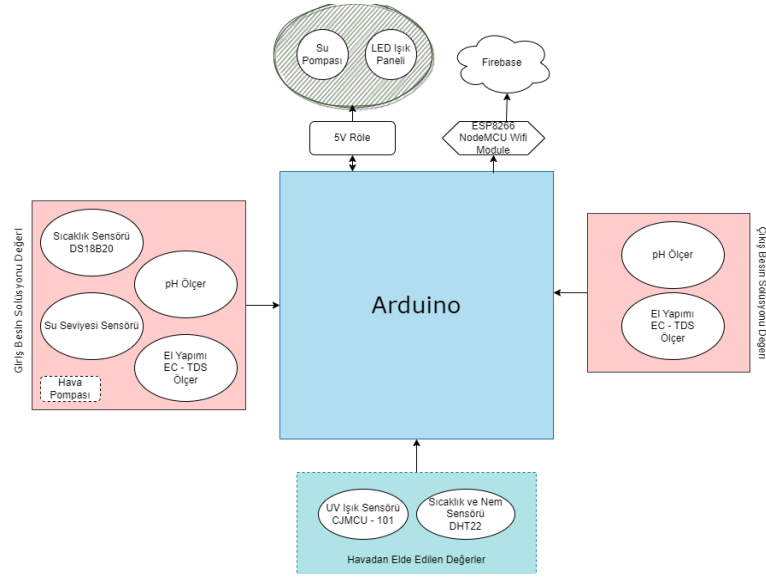
paketi'ni (TCP/IP) kullanan birbirine bağılı bilgisayar ağılarından oluşan küresel bir sistemdir. Çok çeşitli elektronik, kablosuz ve optik ağ teknolojileri ile bağlantılı, yerelden küresel kapsamdaki milyonlarca özel, kamu, akademik, işletme ve devlet ağından oluşan bir ağıdır (Nunberg, G., 2012).

Nesnelerin İnterneti için en iyi tanım şöyle olacaktır: "Ortamdaki durumlar ve değişiklikler karşısında otomatik düzenleme, bilgi, veri ve kaynakları paylaşma, tepki verme ve harekete geçme kapasitesine sahip açık ve kapsamlı bir akıllı nesnelere ağı" tanımıdır. Son on yılda Nesnelerin İnterneti (IoT) terimi, ağa bağılı fiziksel nesnelerin küresel bir altyapısının vizyonunu yansıtarak, yalnızca herhangi biri için değil, herhangi bir şey için her zaman, her yerde bağlantı kurmayı mümkün kılarak dikkat çekti (Kosmatos, E.A., ve diğ., 2011).


### **3.2.1.Arduino**

Arduino her şeyden önce açık kaynaklı bir bilgisayar donanım ve yazılım şirkettir. Arduino topluluğu, mikrodenetleyici tabanlı geliştirme panoları tasarlayan ve kullanan proje ve kullanıcı topluluğunu ifade eder. Bu geliştirme panoları, açık kaynaklı prototipleme platformları olan Arduino modülleri olarak bilinir. Basitleştirilmiş mikrodenetleyici kartı çeşitli geliştirme kartı paketlerinde gelmektedir.

En yaygın programlama yaklaşımı, C programlama kullanan Arduino IDE'yi kullanmaktır. Bu, sürekli büyüyen muazzam bir Arduino Kütüphanesine erişmenizi sağlayan bir açık kaynak topluluğudur (Arduino, S. A., 2015).



Şekil 3.2. Arduino prototip sistem şeması.



Şekil 3.3. Arduino prototip sisteminden görüntüler.


### 3.2.1.1. Kullanılan Arduino Kartı

Arduino Uno, atmega328'e (veri sayfası) topraklanmış bir mikrodenetleyici kartıdır. 14 Dijital giriş/çıkış pimi, 6 analog giriş, 16 MHz seramik rezonatör, USB bağlantısı için bir kolaylaştırma, bir güç jakı, bir ICSP başlığı ve bir sıfırlama düğmesinden oluşur. Tasarımları, mikrodenetleyiciyi mümkün olan her şekilde destekleyen yardımlardan oluşmaktadır. Çalışmak için, bir USB kablosuyla bilgisayara bağlamanız veya bir AC-DC adaptörü veya pil ile çalıştırmanız yeterlidir.

“Uno” kelimesi İtalyanca bir atıfta bulunur ve Arduino 1.0'ın gelecek sürümünü işaretlemek için adlandırılmıştır. Uno ve sürüm 1.0, ileri sürümler için Arduino'nun referans sürümleridir. Uno, bir dizi USB Arduino kartının en yenisidir ve Arduino platformu için referans modeldir (N. S. Kumar, 2016).

### 3.2.1.2. Sensör ve Modüller

#### 3.2.1.2.1. Renk ve Işık Sensörleri



Şekil 3.4. Analog Işık Yoğunluğu Sensör Modülü - CJMCU-101 (URL-4, 2022)

Işık Sensörü, görünür ya da kızılötesi ışık enerjisini (fotonları) bir elektrik (elektron) sinyaline çeviren fotoelektrik cihazlardır. Bir ışık sensörü, temelde ışık olarak adlandırılan ve frekansları kızılötesi ve görünür arasında değişen ultraviyole ışık dalga aralığında çok dar bir frekans aralığında bulunan radyan enerjiyi ölçerek ışığın yoğunluğunu gösteren bir çıkış sinyali üretir (URL-3, 2022).

Işık sensörü ışığın yoğunluğunu ölçmek amacıyla özel bir fotodiyot ile opamp kullanır. Geniş bir algılama aralığına sahiptir. 300nm-1000nm aralığındaki kızılötesi ışınları görebilir (URL-4, 2022).

#### 3.2.1.2.2. Nem ve Sıcaklık Sensörü



Şekil 3.5. DHT22 ve DS18B20 Sıcaklık sensörleri (URL-5,6, 2022)

DHT22 Nem ve Sıcaklık Sensörüdür. Bu sensör, birçok ortamda nem ile sıcaklık değerinin ölçülmesini sağlamak amacıyla kullanılır. Bu sensör temel, düşük maliyetli dijital sıcaklık ile nem sensörüdür. Bir kapasitif nem sensörü ile etrafındaki havayı ölçmek amaçlı bir termistör kullanır. Veri pini, dijital bir sinyal oluşturur. Kullanımı oldukça basit olmak ile birlikte dikkatli zamanlama verileri yapmak ihtiyacındadır. Bu sensörün var olan tek dezavantajı kütüphane kullanırken, sensör okumaları 2 saniye kadar olabilir. Bir önceki sürümü ile karşılaştırıldığında, bu sensör daha doğru, daha hassas ve sıcaklık ile nem için daha büyük bir aralıkta çalışır. Tüm bu olumlu yönlerinin yanında daha büyük ve daha pahalıdır (URL-5, 2022).

DS18B20 bir sıcaklık sensör entegresidir. Bu sensörün hassas ölçüm yapması ile kalibreli olması sayesinde tüm profesyonel ve/veya amatör uygulamalarda güvenle kullanılabilir. Ayrıca sensör paslanmaz çelik başlık ve silikon dış gövde ile yalıtılmış olduğu için sudan etkilenmez. Seri data özelliğini kullanmak oldukça kolaydır. -55 ile +125°C arasındaki derecelerdeki ısıyı ölçer. Ölçüm değerini pininden seri data olarak oluşturulmuş şekilde gönderir (URL-6, 2022).

### 3.2.1.2.3. Kablosuz Haberleşme



Şekil 3.6. NodeMCU sensörü (URL-7, 2022)

NodeMCU, düşük maliyetli, açık kaynaklı bir IoT platformudur. Başlangıçta Espressif Systems'in ESP8266 WiFi Soc'sinde çalışan bellekimi ve ESP-12 modülünü temel alan donanımı içeriyordu. Daha sonra ESP32 32-bit MCU desteği eklendi.

NodeMCU, açık kaynak prototipleme kartı tasarımlarının mevcut olduğu açık kaynaklı bir bellekidir. "NodeMCU" adı "düğüm" ve "MCU" yu (mikrodenetleyici birimi) birleştirir. Kesinlikle "NodeMCU" terimi, ilgili geliştirme kitlerinden ziyade bellekimi ifade eder (URL-7, 2022).

### 3.2.1.2.4. Röle



Şekil 3.7. 5V Röle örneği (URL-8, 2022)

Röle, üzerinden akım geçtiği zaman çalışan elektromanyetik bir devre elemanıdır. Röleler küçük değerli bir akım ile yüksek güçlü bir alıcıyı anahtarla bilmek için kullanılır. Röleler, tek bir elemanda birden fazla anahtar kontağına sahip olabilir ve böylelikle birden fazla yükü aynı anda açıp kapatabilirler (URL-8, 2022).

### 3.2.1.2.5. Diğer



Şekil 3.8. DFRobot Gravity: Analog pH meter V2 (URL-9, 2022)

DFRobot Gravity: Analog pH ölçer V2, çözeltinin pH değerini ölçmek ve asitliği veya alkaliniteyi yansıtmak amacıyla tasarlanmıştır. DFRobot pH sensörü, akuaponik, su ürünleri yetiştiriciliği ve çevresel su testi gibi çeşitli uygulamalarda yaygın olarak kullanılır.

pH metre V1'in yükseltilmiş bir versiyonu olan bu ürün, hassasiyeti ve kullanıcı deneyimini büyük ölçüde geliştirir. Yerleşik voltaj regülatörü çipi, 5V ve 3.3V ana kontrol panoları ile uyumlu olan 3.3 ~ 5.5V geniş voltaj beslemesini destekler.

Bu ürün ile, ana kontrol panosu (Arduino gibi), ve yazılım kütüphanesi, hızlı bir şekilde pH metre inşa eder. DFRobot, çeşitli su kalitesi testlerinin ihtiyaçlarını karşılamakla kalmayıp aynı zamanda kendin yap çok parametrelili su kalitesi test cihazı

için de uygun olan çeşitli su kalitesi ph analog sensör ürünleri, tek tip boyut ve arayüz sağlar.

pH, çözeltinin asitliğini veya alkalinitesini ölçen bir değerdir. Ayrıca hidrojen iyonu konsantrasyon indeksi olarak da adlandırılır. pH, çözeltideki hidrojen iyonu aktivitesinin bir ölçөгüdür. pH, tıpta, kimyada ve tarımda geniş bir kullanım alanına sahiptir. Genellikle, pH 0 ila 14 arasında bir sayıdır. Termodinamik standart koşullar altında, çözeltinin nötr olduđu anlamına gelen pH = 7; Çözeltinin asidik olduđu anlamına gelen pH <7; Çözeltinin alkali olduđu anlamına gelen pH > 7 anlamına gelmektedir (URL-9, 2022).



Şekil 3.9. DFRobot Gravity:Arduino Uyumlu Fotoelektrik Su Seviyesi Sensörü (URL-10, 2022)

Bu, geleneksel optik prensipler kullanılarak çalışın bir fotoelektrik sıvı seviye sensörüdür. Bunun avantajları yüksek hassasiyet ve mekanik parçalara gerek olmamasıdır - yani daha az kalibrasyon demektir! Korozyona dayanıklı prob kolayca monte edilir ve yüksek sıcaklıklara ve yüksek basınçlara dayanabilir. Sensör, DFRobot "Gravity" arayüzü ile uyumluluk için bir arabirim adaptörü ile donatılmıştır.

EC-TDS ölçer bulunması zor bir sensör olduđu için evde var olan imkanlar ile üretilmiştir. PPM, bir akışkanın EC'sinden hesaplanır, EC, akışkanın elektriksel direncinin tersidir. Fiş, ilgilenilen sıvıya batırıldığında iki prob [fiş pimleri] arasındaki direnci ölçerek bir sıvının EC veya ppm'sini tahmin ediyoruz. Sıcaklığın sıvıların iletkenliđi üzerinde etkisi vardır, bu nedenle bu değeri bilmemiz çok önemlidir. Bunları eşdeğerlerine dönüştürmek için EC 25 \* C'de:

$$EC_{25} = EC / (1 + a (T - 25))$$

EC<sub>25</sub>: 25 derecede eşit EC

EC: Ölçülen EC

T: Sıcaklık ölçümü

a = 0.019 °C [Besin solüsyonları için genel kullanım]

Yukarıda belirtilen formül kullanılarak EC ölçer sistemi üretilmiştir.

### 3.3. Makine Öğrenmesi

Bilgisayarda bir problemi çözmek için algoritmalara ihtiyaç duyarız. Giriş değerinden çıkış değerine taşınan görev listesine algoritma denmektedir. Örneğin, sıralama için bir algoritma oluşturulabilir. Giriş değerleri numara setleridir ve çıkış değeri ise sıralanmış numara dizisidir. Bazı görevler için kullanılabilir birden fazla algoritma yöntemi olabilir. Bu tarz durumlarda bulmaya çalıştığımız şey bazı zamanlarda en etkili olanı, en az adım ya da bellek gerektireni veyahut her ikisine de ihtiyaç duyanı olabilir.

Bazı görevler için ise belli bir algoritma yöntemimiz yoktur. Örneğin spam mesajların tespiti gibi. Bu gibi durumlarda giriş değerini biliyoruz: karakterlerden oluşan bir email dokümanıdır. Olması gereken çıkış değeri ise: mesajın spam olup olmadığı karar veren evet/hayır sonucudur. Fakat giriş değerini çıkış değerine nasıl dönüştürebileceğinizi bilmiyoruz. Çünkü spam olarak değerlendirdiğimiz mesajlar zamana ve bireyden bireye göre değişiklik gösterebilmektedir.

Görevler için bilgide eksik olduğumuz yeri veri ile tamamlıyoruz. Kolaylıkla bazılarının spam olduğunu bildiğimiz yüzlerce örneği toplayabiliriz ve böylece “spam”ın ne olduğunu onlardan öğreniriz. Bir diğer deyişle, bilgisayarların bu görev için algoritmayı otomatik olarak oluşturmasını bekleriz. Pek çok uygulama için algoritma yöntemimiz bulunmasa da örnek verilerimiz bulunmaktadır (Alpaydın, E., 2010).

Beklentilerimizin çok fazla tecrübe tabanlı kararlardan oluştuğunu fark etmişizdir. Örneğin hafif esintili ve nispeten sıcak bir günden sonra neden yarın için güzel bir hava durumuna sahip olmayı bekleriz? Bu beklentinin sebebi tecrübelerimizdir. Çünkü bahsettiğimiz koşullardaki hava durumundan sonra çoğunlukla güzel bir hava durumuyla karşılaştığımız tecrübelerimiz olmuştur. Benzer bir şekilde çok çalıştığımız zaman iyi akademik notlar alacağımızı düşünmemiz sayılabilir. Beklentilerimize güveniriz çünkü tecrübelerimizden öğreniriz ve tecrübe tabanlı kararlar veririz.

İnsanlar deneyimlerinden öğrenirlerken bilgisayarlar için de aynı durum söz konusu olabilir mi? Bu soruya cevabımız “evet”tir. Makine öğrenmesi de tam olarak ihtiyacımız olan bu durumdur. Makine öğrenmesi, bilgisayar metodları kullanılarak tecrübelerden öğrenmeyi ve bu sayede sistemi geliştirmeyi sağlayan bir tekniktir. Bilgisayar sistemlerinde, deneyim durumu veri şeklinde bulunmaktadır ve bu yöntemin temel amacı, var olan verilerden model oluşturan öğrenme algoritmaları geliştirmektir.

Bu amaç ile öğrenme algoritmalarını tecübeleri veriler vererek tahmin edebilecekleri bir model elde etmeye çalışırız. Geçtiğimiz 20 yılda verilerin toplanması, depolanması, paylaşımı ve işlenmesi daha hızlı ve belirgin bir şekilde artmıştır. İnsan yaşamının tüm yönlerini içerisine alan büyük miktarlarda veri biriktirdiğimiz göz önüne alındığında, verileri kullanmak için etkili ve verimli yöntemlere ihtiyaç duyulmaktadır. Bu nedenle, makine öğrenmesi yöntemlerinin büyük verilerde kullanılarak ve güçlü yönlerini göstererek çok fazla ilgi çekmesi şaşırtıcı değildir. Bu günlerde, makine öğrenmesi bilgisayar bilimlerinin pek çok farklı branşında kullanılmaktadır. Örneğin, grafik, ağ haberleşmesi, yazılım mühendisliği ve hatta mimarlıkta bile kullanılmaktadır (Zhou, Zhi-Hua, 2021).

Makine öğrenimi, makinelere verilerin nasıl daha verimli işleneceğini öğretmek için kullanılır. Bazen verileri görüntüledikten sonra, verilerden alınan bilgileri yorumlayamaz. Bu durumda, makine öğrenimini uyguluyoruz. Mevcut veri kümelerinin bolluğu ile makine öğrenimine olan talep artmaktadır. Birçok endüstri, ilgili verileri çıkarmak için makine öğrenimini uygular. Makine öğreniminin amacı verilerden öğrenmektir. Makinelerin açıkça programlanmadan kendi başlarına öğrenmelerini sağlamak için birçok çalışma yapılmıştır. Birçok matematikçi ve programcı, büyük veri kümelerine sahip olan bu sorunun çözümünü bulmak için çeşitli yaklaşımlar uygular (Mahesh, B., 2020).

Makine Öğrenmesi, eğilimleri öğrenmek ve kalıplara ile davranışlara ilişkin içgörüler oluşturmak için çeşitli gelişmiş istatistiksel algoritmalar kullanan veri analizi amacıyla kullanılan genel bir terimdir (URL-11, 2019). Algoritmaya verilen bilgilerden öğrenerek, daha önce görülmemiş verilere dayanarak tahmin yapabilir. Girdi verileri ile çıktı arasında çok sayıda ara (gizli) bağlantı katmanı oluşturarak, verilerin içinde bulunan soyut ve karmaşık kalıpları eşlemek mümkündür (Kennion, M. O., ve diğ., 2022).

Makine öğrenimi ayrıca disiplinler arası araştırmalarda destek olarak da kullanılır. Örneğin, biyoinformatik, biyolojik gözlemleri ve kalıpları anlamak için bilgi teknolojisini kullanmayı amaçlayan bir araştırma alanıdır. İnsanlar, insan genom projesi ve genomik tıp hakkında heyecan duymaktadır. Biyoinformatikte, biyolojik gözlemlerden örüntü keşfine kadar tüm süreç veri toplama, veri yönetimi, veri analizi ve simülasyonları içerir. Bu görevler arasında veri analitiği, makine öğreniminin parladığı yerdir ve araştırmacılar biyoinformatiğe çeşitli makine öğrenme tekniklerini başarıyla uygulamışlardır.

Günümüzde makine öğrenmesi günlük hayatımızı güçlü bir şekilde etkiler. Örnek verilecek olur ise uydu ve sensörlerden veri toplayıp analiz ederek hava durumu, enerji

arama ve çevresel izleme gibi etkinliklerde kullanılmaktadır. Ticari kullanımlarda ise satışları ve müşteri verilerini analiz etmede bizlere yardım etmektedir. Bunun yanında depolama giderlerinin azaltılması ya da belirli müşteri grupları için satış stratejisi dizayn etmede kullanılmaktadır.

Google gibi arama motorları insanların yaşam tarzlarına etki eder. Örneğin seyahat etmeden önce hedef bilgilerini aramak ya da uygun bir otel veyahut yemek mekanını aramak gibi işlemlerde kullanılır. İnternet araması, tüm ağdaki verileri analiz ederek istenen bilgileri bulur ve giriş sorgusundan çıktı sonuçlarına kadar arama işlemi, giriş ve çıkış arasındaki eşleşmeyi oluşturmak için makine öğrenme teknolojilerine dayanır. Aslında, makine öğrenimi, bugün keyif aldığımız internet aramasının gelişimine muazzam katkılarda bulundu ve ‘fotoğrafa göre arama’ gibi birçok gelişmiş işlev, en yeni makine öğrenme teknikleriyle etkinleştirildi. Google, Microsoft, Facebook ve Amazon gibi önde gelen tüm teknoloji şirketlerinin makine öğrenimi araştırma ekipleri ve hatta makine öğrenimi adını taşıyan araştırma merkezleri vardır. Bu dev şirketler tarafından alınan kararlar sadece makine öğreniminin hızlı gelişimini ve uygulamasını göstermekle kalmıyor, aynı zamanda internet endüstrisinin gelecekteki yönünü de etkilemektedir (Zhou, Zhi-Hua, 2021).

### 3.3.1. Model Seçimi ve Değerlendirilmesi

#### 3.3.1.1 Ampirik Hata ve Aşırı Uyum (Overfitting)

Genel olarak, yanlış sınıflanmış örneklerin toplam örneklere oranı hata oranını vermektedir. Eğer  $m$  kadar örnekten  $a$  kadarı hatalı ise  $E=a/m$  hata oranı olarak hesaplanır. Buna göre,  $1-a/m$  ise doğruluk oranını verir. Daha genel olarak, öğrencinin öngördüğü çıktı ile gerçek çıktısı arasındaki farka hata denir. Eğitim kümesinde hesaplanan hataya eğitim hatası veya ampirik hata, yeni örneklerde hesaplanan hataya genelleme hatası denir.

Aradığımız iyi öğrenciler, yeni örnekler üzerinde iyi performans gösterenlerdir. Bu nedenle, iyi öğrenenler, öğrenilen kuralların tüm potansiyel örneklere uygulanacağı şekilde eğitim örneklerinden genel kuralları öğrenmelidir. Bununla birlikte, öğrenci eğitim örneklerini ‘çok iyi’ öğrendiğinde, eğitim örneklerinin bazı özelliklerinin tüm potansiyel örneklerin sahip olacağı genel özellikler olarak alınması muhtemeldir ve bu da genelleme performansında bir azalmaya neden olur. Makine öğreniminde, bu fenomen

aşırı uyum olarak bilinir ve bunun tersi de yetersiz uyum olarak bilinir, yani öğrenci eğitim örneklerinin genel özelliklerini öğrenmemiştir (Zhou, Zhi-Hua, 2021).

### 3.3.1.2. Değerlendirme Yöntemleri

Genel olarak, genelleme hatasını test deneyleriyle değerlendirebiliriz. Bunu yapmak için, öğrencinin yeni örnekleri sınıflandırma yeteneğini tahmin etmek amacıyla bir test seti kullanıyoruz ve test hatasını genelleme hatasına bir yaklaşım olarak kullanıyoruz. Genel olarak, test örneklerinin bağımsız olduğunu ve temel gerçek örnek dağılımından aynı şekilde örneklendiğini varsayınız (Zhou, Zhi-Hua, 2021).

#### 3.3.1.2.1. Hold-Out

Bekletme yöntemi, veri kümesi D'yi iki ayrık alt kümeye böler: biri eğitim kümesi S, diğeri test kümesi T olarak, burada  $D = S \cup T$  ve  $S \cap T = \emptyset$ . Eğitim seti S üzerinde bir model eğitiyoruz ve daha sonra genelleme hatasının bir tahmini olarak test seti T'deki test hatasını hesaplıyoruz.

İkili sınıflandırma problemlerini örnek olarak, D'nin 1000 örneklili bir veri kümesi olduğunu varsayalım. Bu veri kümesini 700 örneklili bir eğitim seti ve 300 örneklili bir test setine bölmüş olalım. Model S ile eğitildikten sonra T kümesinde 90 örneği yanlış sınıflandırıldığını varsayalım, o zaman  $(90/300) \times 100\% = 30\%$  hata oranına sahibiz ve buna göre, doğruluk  $1 - 30\% = 70\%$  şeklinde hesaplanmaktadır (Zhou, Zhi-Hua, 2021).

#### 3.3.1.2.2. Çapraz Geçerlilik (Cross-Validation)

Çapraz doğrulama, veri kümesi D'yi benzer boyutlara sahip k ayrık alt kümelerine böler. Yani  $D = D_1 \cup D_2 \cup \dots \cup D_k$ ,  $D_i \cap D_j = \emptyset$  ( $i \neq j$ ). Tipik olarak, her  $D_i$  alt kümesi, tabakalı örnekleme yoluyla orijinal veri dağılımını korumaya çalışır. Her çapraz doğrulama denemesinde, bir modeli eğitmek için eğitim seti olarak  $k - 1$  alt kümelerinin birleşimini kullanırız ve ardından modeli değerlendirmek için kalan alt kümeyi test seti olarak kullanırız. Bu işlemi k kez tekrarlıyoruz ve her bir alt kümeyi tam olarak bir kez test kümesi olarak kullanıyoruz. Son olarak, değerlendirme sonucunu elde etmek için k denemelerinin ortalamasını alıyoruz. Çapraz doğrulamanın kararlılığı ve doğruluğu büyük ölçüde k değerine bağlı olduğundan, k-kat çapraz doğrulama olarak da bilinir. En

sık kullanılan  $k$  değeri 10'dur ve karşılık gelen yönteme 10 kat çapraz doğrulama denmektedir (Zhou, Zhi-Hua, 2021).

### 3.3.1.3 Performans Ölçüsü

Modellerin genelleme yeteneğini değerlendirmek için sadece pratik ve etkili tahmin yöntemlerine değil, aynı zamanda genelleme yeteneğini ölçebilecek bazı performans ölçümlerine de ihtiyacımız vardır. Farklı performans ölçütleri, görevlerin farklı taleplerini yansıtır ve farklı değerlendirme sonuçları üretir. Başka bir deyişle, bir modelin kalitesi, algoritmaya ve verilere ve görev gereksinimine bağlı olan göreceli bir kavramdır (Zhou, Zhi-Hua, 2021).

#### 3.3.1.3.1 Hata Oranı ve Doğruluk

Genel olarak, yanlış sınıflanmış örneklerin toplam örneklere oranı hata oranını vermektedir. Eğer  $m$  kadar örnekten  $a$  kadarı hatalı ise  $E=a/m$  hata oranı olarak hesaplanır. Buna göre,  $1-a/m$  ise doğruluk oranını verir. Daha genel olarak, öğrencinin öngördüğü çıktı ile gerçek çıktısı arasındaki farka hata denir. Eğitim kümesinde hesaplanan hataya eğitim hatası veya ampirik hata, yeni örneklerde hesaplanan hataya genelleme hatası denir (Zhou, Zhi-Hua, 2021).

#### 3.3.1.3.2 Kesinlik (Precision), Duyarlılık (Recall) ve F1 Skoru

Hata oranı ve doğruluk sıklıkla kullanılır, ancak tüm görevler için uygun değildir. Karpuz seçtiğimizi varsayarsak, yeni bir karpuz grubunu sınıflandırmak için öğrenilmiş bir model kullandığımızı varsayalım. Hata oranı bize yanlış sınıflandırılmış karpuzların bu partideki tüm karpuzlara oranını söyler. Ancak şunu bilmek isteyebiliriz: "Toplanan karpuzların yüzde kaçı olgunlaşmış?" veya "Tüm olgun karpuzların yüzde kaçı toplandı?" Ne yazık ki, hata oranı bu tür soruları cevaplayamıyor ve bu nedenle başka performans ölçümlerine ihtiyacımız var.

Bu tür sorular genellikle bilgi alma ve web araması gibi uygulamalarda ortaya çıkar. Örneğin, bilgi almada, sık sık bilmek isteriz "Alınan bilgilerin yüzde kaçı kullanıcıların ilgisini çekiyor?" ve "Kullanıcının ilgilendiği bilgilerin ne kadarı alınır?" Bu tür sorular için doğruluk (precision) ve duyarlılık (Recall) daha iyi seçimlerdir.

İkili sınıflandırma problemlerinde, temel doğruluk sınıfı ve öngörülen sınıfın, yani doğru pozitif (TP), yanlış pozitif (FP), gerçek negatif (TN) ve yanlış negatif (FN) olmak üzere dört kombinasyonu vardır ve her durumda örnek sayısını sırasıyla TP, FP, TN ve FN olarak gösteririz. Daha sonra  $TP + FP + TN + FN =$  toplam örnek sayısı.

Dört kombinasyon, gösterildiği gibi bir karışıklık matrisi de görüntülenebilir. Tablo 3.1. Daha sonra, hassasiyet P ve duyarlılık R sırasıyla şu şekilde tanımlanır:

$$P = \frac{TP}{TP+FP} \quad (3.1)$$

$$R = \frac{TP}{TP+FN} \quad (3.2)$$

**Çizelge 3.1.** İkili Sınıflandırma karışıklık matrisi

| Yer Gerçeği Sınıfı | Öngörülen Sınıf |         |
|--------------------|-----------------|---------|
|                    | Pozitif         | Negatif |
| Pozitif            | TP              | FN      |
| Negatif            | FP              | TN      |

Doğruluk ve duyarlılık çelişkilidir. Genel olarak konuşursak, kesinlik yüksek olduğunda duyarlılık genellikle düşüktür ve duyarlılık yüksek olduğunda kesinlik genellikle düşüktür. Örneğin, daha olgun karpuz toplamak için, toplanan karpuz sayısını artırabiliriz, çünkü aşırı bir durumda, tüm karpuzları toplarsak, tüm olgun karpuzlar da toplanır. Ancak, bunu yaparak, kesinlik çok düşük olacaktır. Öte yandan, olgunlaşmış karpuzların oranının yüksek olmasını istiyorsak, o zaman sadece emin olduğumuz karpuzları seçmeliyiz. Bununla birlikte, bunu yapmak birçok olgun karpuzu kaçırabilir ve bu nedenle duyarlılık azalır. Tipik olarak, sadece basit problemlerde aynı anda yüksek kesinlik ve duyarlılık elde edebiliriz.

F1, kesinlik ve duyarlılığın harmonik ortalamasıdır:

$$\frac{1}{F1} = \frac{1}{2} \times \left( \frac{1}{P} + \frac{1}{R} \right)$$

$$F1 = \frac{2 \times P \times R}{P + R} = \frac{2 \times TP}{Total\ number\ of\ samples + TP - TN} \quad (3.3)$$

Bazı uygulamalarda kesinlik ve duyarlılık önemi farklıdır. Örneğin, tavsiye edilen içeriğin kullanıcının ilgisini çekmesi ve kullanıcıyı mümkün olduğunca az rahatsız etmesi daha çok arzu edildiğinden, tavsiye eden sistemlerde kesinlik daha kritiktir. Öte yandan, mümkün olduğunca az suçluyu kaçırmak istediğimizden, suç bilgi alma sistemlerinde duyarlılık daha kritik öneme sahiptir (Zhou, Zhi-Hua, 2021).

### 3.3.1. Denetimli Öğrenme

Makine öğrenimi yöntemlerinin en yaygın biçimi, derin olsun ya da olmasın, denetimli öğrenmedir. Görüntüleri bir ev, araba, insan veya evcil hayvan içeren olarak sınıflandırabilmek amacıyla bir sistem kurmak istediğimizi düşünelim. Öncelikle, her biri kendi kategorisiyle etiketlenmiş evlerin, arabaların, insanların ve evcil hayvanların görüntülerinden oluşan geniş bir veri kümesi topluyoruz. Eğitim sırasında, makineye bir görüntü gösterilir ve her kategori için bir tane olmak üzere bir puan vektörü şeklinde bir çıktı üretir. İstenilen kategorinin tüm kategorilerin en yüksek puanına sahip olmasını istiyoruz, ancak bunun eğitimden önce gerçekleşmesi olası değildir. Çıktı puanları ile istenen puan modeli arasındaki hatayı (veya mesafeyi) ölçen objektif bir işlevi hesaplıyoruz. Makine daha sonra bu hatayı azaltmak için dahili ayarlanabilir parametrelerini değiştirir. Genellikle ağırlık olarak adlandırılan bu ayarlanabilir parametreler, makinenin giriş-çıkış fonksiyonunu tanımlayan ‘topuzlar’ olarak görülebilen gerçek sayılardır. Tipik bir derin öğrenme sisteminde, bu ayarlanabilir ağırlıkların yüz milyonları ve makineyi eğitmek için yüz milyonlarca etiketli örnek olabilir (LeCun, Y.,2015).

#### 3.3.1.1. Sınıflandırma

##### 3.3.1.1.1. Naive Bayes

Naive Bayes, Bayes'in kuralını, özniteliklerin sınıf göz önüne alındığında şartlı olarak bağımsız olduğu güçlü bir varsayım ile birlikte kullanan basit bir öğrenme algoritmasıdır. Bu bağımsızlık varsayımı pratikte sıklıkla ihlal edilirken, naive Bayes yine de çoğu zaman rekabetçi sınıflandırma doğruluğu sağlar. Hesaplama verimliliği ve diğer birçok arzu edilen özelliği ile birleştiğinde, bu, naif Bayes'in pratikte yaygın olarak uygulanmasına yol açar.

Bayes kuralı ile posterior olasılık  $P(c | x)$  'i tahmin ederken bir zorluk vardır:  $P(x | c)$  tüm özniteliklerde ortak olasılık olduğundan, sonlu eğitim örneklerinden sınıf koşullu olasılık  $P(x | c)$  'yi hesaplamak kolay değildir. Bunu önlemek için, naive Bayes sınıflandırıcısı ‘öznitelik koşullu bağımsızlık varsayımını’ yapar: bilinen herhangi bir sınıf göz önüne alındığında, tüm özniteliklerin birbirinden bağımsız olduğunu varsayalım. Başka bir deyişle, her özneliğin tahmin sonucunu bağımsız olarak etkilediğini varsayılır (Zhou, Zhi-Hua, 2021).

### 3.3.1.1.2. Karar ağaçları

Karar ağaçları popüler bir makine öğrenme yöntemleri sınıfıdır. Adından da anlaşılacağı gibi, bir karar ağacı, aynı zamanda insanlar tarafından kullanılan ortak bir karar verme mekanizması olan ağaç yapılarına dayalı kararlar alır. Örneğin, "Bu karpuz olgunlaşmış mı?" genellikle bir dizi karar veya alt karardan geçiyoruz: önce ‘Renk nedir?’, yeşilse o zaman ‘Kökün şekli nedir?’, eğer kıvrıksa o zaman ‘Vurma sesi nedir?’. Son olarak, gözlemlere dayanarak, karpuzun olgun olup olmadığına karar verilir (Zhou, Zhi-Hua, 2021).

Karar sürecinin sonunda sonuçlar, örneğin olgunlaşmış ve olgunlaşmamış olası sınıflandırmalara karşılık gelir. Karar sürecinde sorulan her soru bir özellik üzerinde yapılan bir testtir, örneğin ‘Renk nedir?’ veya ‘Kök nedir?’. Her test, mevcut cevaba bağlı olarak sonuca veya ek bir teste yol açar. Örneğin, geçerli karar renk=yeşil ise, bir sonraki test ‘Kökü nedir?’ sorusu sadece yeşil karpuzları dikkate almaktadır (Zhou, Zhi-Hua, 2021).

Genellikle, bir karar ağacı bir kök düğüm, birden çok iç düğüm ve birden çok yaprak düğümünden oluşur. Yaprak düğümleri karar sonuçlarına karşılık gelir ve diğer her düğüm bir özellik testine karşılık gelir. Her düğümdeki örnekler, özelliklerin bölme sonuçlarına göre alt düğümlere ayrılır. Kök düğümünden yaprak düğüme giden her yol bir karar dizisidir. Amaç, görünmeyen örnekleri tahmin etmek için genelleşebilecek bir ağaç üretmektir. Karar ağaçlarının inşası böl ve fethet stratejisini izlemektedir (Zhou, Zhi-Hua, 2021).

Karar ağaçları, böl ve yönet stratejisini kullanan hiyerarşik bir veri yapısı modelidir. Bu parametrik olmayan yöntem hem sınıflandırma hem de regresyon için kullanılabilir.

Parametrik tahminde, tüm girdi uzayı üzerinden bir model tanımlarız ve tüm eğitim verilerinden onun parametrelerini öğreniriz. Daha sonra herhangi bir test girişi için aynı modeli ve aynı parametre setini kullanırız. Parametrik olmayan tahminde, girdi uzayını öklid normu gibi uzaklık ölçüsüyle tanımlanan yerel bölgelere böleriz ve her girdi için o bölgedeki eğitim verilerinden hesaplanan karşılık gelen yerel model kullanılır.

Karar ağacı, yerel bölgenin daha az sayıda adımda bir dizi özyinelemeli bölmede tanımlandığı, denetimli öğrenme için hiyerarşik bir modeldir. Bir karar ağacı, iç karar düğümlerinden ve terminal yapraklarından oluşur. Her karar düğümü  $m$ , dalları etiketleyen ayrık sonuçlarla bir test fonksiyonu  $f(x)$  uygular. Bir girdi verildiğinde, her düğümde bir test uygulanır ve sonuca göre dallardan biri alınır. Bu süreç kökte başlar ve bir yaprak düğüme ulaşana kadar özyinelemeli olarak tekrarlanır. Bu noktada yaprakta yazılan değer çıktıyı oluşturur (Alpaydın, E., 2010).

### 3.3.1.1.3. Destek Vektör Makinesi

Verilen bir eğitim seti  $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ , burada  $y_i \in \{-1, +1\}$ . Sınıflandırmanın temel fikri, farklı sınıfların örneklerini ayırabilen örnek uzayda bir ayırma hiper düzlemi bulmak için eğitim seti  $D$ 'yi kullanmaktır. Bununla birlikte, birden fazla nitelikli ayırma hiper düzlemi olabilir. Peki, hangisi seçilmelidir? (Zhou, Zhi-Hua, 2021).

Sezgisel olarak, iki sınıfın tam ortasındaki seçmeliyiz. Çünkü bu ayırma hiper düzlemi yerel veri pertürbasyonuna en iyi ‘toleransa’ sahiptir. Örneğin, eğitim setinde bulunmayan örnekler, eğitim setinin gürültüleri veya sınırlamaları nedeniyle karar sınırına daha yakın olabilir. Sonuç olarak, iyi eğitim seti gerçekleştirmek için pek çok ayıran aşırı düzlem kırmızı hiper düzlem etkilenen ihtimali az ise hata yapacaktır. Başka bir deyişle, bu ayırma hiper düzlemi en güçlü genelleme yeteneğine ve en sağlam sınıflandırma sonuçlarına sahiptir. Örnek uzayda aşırı düzlemin ayrılması aşağıdaki doğrusal fonksiyon olarak ifade edilebilir: (Zhou, Zhi-Hua, 2021).

$$w^T x + b = 0 \quad (3.4)$$

Burada  $w = (w_1; w_2; \dots; w_d)$ , hiper düzlemin yönünü kontrol eden normal vektördür ve  $b$ , hiper düzlem ile orijin arasındaki mesafeyi kontrol eden önyargıdır. Normal vektör  $w$  ve önyargı  $b$ ,  $(w, b)$  ile gösterilen ayırma hiper düzlemini belirler. Örnek

uzayındaki herhangi bir  $x$  noktasından hiper düzlemine  $(w, b)$  olan uzaklık şu şekilde yazılabilir:

$$r = \frac{|w^T x + b|}{\|w\|} \quad (3.5)$$

#### 3.3.1.1.4. K-En Yakın Komşu

k-En Yakın Komşu (kNN), basit bir mekanizmaya sahip yaygın olarak kullanılan denetimli bir öğrenme yöntemidir: bir test örneği verildiğinde, bazı mesafe metriklerine göre en yakın  $k$  eğitim örneklerini bulur ve ardından tahminlerde bulunmak için bu  $k$  ‘komşuları’ kullanır. Tipik olarak, sınıflandırma problemleri için oylama, test örneğini  $k$  komşularında en sık görülen sınıf etiketi olarak tahmin etmek için kullanılabilir; regresyon problemleri için, test örneğini  $k$  gerçek değerli çıktılarının ortalaması olarak tahmin etmek için ortalama kullanılabilir. Ayrıca, numuneler, daha yakın bir numuneye daha yüksek bir ağırlık atanacak şekilde mesafelere göre ağırlık uygulanır. (Zhou, Zhi-Hua, 2021).

Daha önce tanıtilen diğer yöntemlerle karşılaştırıldığında, k-En Yakın Komşunun kendine özgü bir şeyi var: açık bir eğitim süreci yoktur. Aslında, örnekleri eğitim aşamasında saklayan ve test örnekleri alınana kadar hiçbir şey yapmayan tembel öğrenmenin bir temsilcisidir. Buna karşılık, istekli öğrenme, eğitim aşamasındaki örneklerden öğrenen yöntemleri ifade eder (Zhou, Zhi-Hua, 2021).

Farklı  $k$  değerleri çok farklı sınıflandırma sonuçlarına yol açabileceği için  $k$  parametresinin önemli bir rol oynadığını görebiliriz. Ek olarak, farklı mesafe hesaplamaları da önemli ölçüde farklı ‘mahalle’ye ve dolayısıyla farklı sınıflandırma sonuçlarına yol açabilir (Zhou, Zhi-Hua, 2021).

#### 3.3.1.1. Regresyon

##### 3.3.1.1.1. Doğrusal Regresyon

Verilen bir veri setinde  $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ , burada  $x_i = (x_{i1}; x_{i2}; \dots; x_{id})$  ve  $y_i \in \mathbb{R}$ . Doğrusal regresyon, reel değerli çıktı etiketlerini doğru tahmin edebilen doğrusal bir modeli öğrenmeyi amaçlar. (Zhou, Zhi-Hua, 2021).

### 3.4. Derin Öğrenme


Derin öğrenme, birden çok işlem katmanından oluşan hesaplama modellerinin, verilerin temsillerini birden çok soyutlama düzeyiyle öğrenmesini sağlar. Bu yöntemler, konuşma tanıma, görsel nesne tanıma, nesne algılama ve ilaç keşfi ve genomik gibi diğer birçok alanda en son teknolojiyi önemli ölçüde geliştirmiştir.

Derin öğrenme, bir makinenin her katmandaki gösterimi önceki katmandaki gösterimden hesaplamak için kullanılan iç parametrelerini nasıl değiştirmesi gerektiğini belirtmek için geri yayılım algoritmasını kullanarak büyük veri kümelerindeki karmaşık yapıyı keşfeder. Derin kıvrımlı ağlar görüntü, video, konuşma ve ses işlemede atılımlara yol açarken, tekrarlayan ağlar metin ve konuşma gibi sıralı verilere ışık tutmuştur (LeCun, Y.,2015).

#### 3.4.1.Sigmoid

Doğrusal regresyondaki lojistik fonksiyon, aynı spesifik özelliklere sahip bir fonksiyon sınıfı olan bir sigmoid türüdür. Sigmoid, herhangi bir gerçek sayıyı alan ve onu 1 ile 0 arasında bir olasılıkla eşleştiren matematiksel bir işlemdir. Sigmoid fonksiyonun formülü şöyledir:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.6)$$



Şekil 3.7. Sigmoid fonksiyonu.

Sigmoid fonksiyon S şeklinde bir grafik oluşturur, yani  $x$  sonsuzluğa yaklaştıkça olasılık 1 olur ve  $x$  negatif sonsuzluğa yaklaştıkça olasılık 0 olmaktadır. Model, hangi olasılık aralığının hangi ikili değişkene eşitlendiğine karar veren bir eşik belirler.

Doğru ve yanlış olmak üzere iki olası sonucumuz olduğunu ve eşiği 0,5 olarak belirlediğimizi varsayalım. 0,5'ten küçük bir olasılık yanlış sonucuna eşlenir ve 0,5'ten büyük veya ona eşit bir olasılık doğru sonucuna eşlenir (URL-12, 2022).

### 3.4.2. Softmax

Softmax, bir sayı vektörünü, her bir değer için olasılıklarının vektördeki her bir değerin göreceli ölçeği ile orantılı olduğu bir olasılık vektörüne dönüştüren matematiksel bir işlemdir.

Softmax fonksiyonunun uygulamalı makine öğreniminde en yaygın kullanımı, bir sinir ağı modelinde bir aktivasyon fonksiyonu olarak kullanılmasıdır. Özellikle, ağ, sınıflandırma görevindeki her sınıf için bir tane olmak üzere  $N$  değerleri verecek şekilde yapılandırılır ve çıktıları normalleştirmek için softmax işlevi kullanılır ve bunları ağırlıklı toplam değerlerden toplam olasılıklara dönüştürür. Softmax işlevinin çıktısındaki her değer, her sınıf için üyelik olasılığı olarak yorumlanır (URL-13, 2022). Softmax formülü aşağıdaki gibidir:

$$\sigma(\vec{Z})_i = \frac{e^{Z_i}}{\sum_{j=1}^K e^{Z_j}} \quad (3.7) \text{ (URL-14, 2022)}$$

### 3.4.3. Adamax Optimizasyon Algoritması

AdaMax algoritması, Uyarlamalı Hareket Tahmini (Adam) Optimizasyon algoritmasının bir uzantısıdır. Daha geniş anlamda, Gradyan İniş Optimizasyon algoritmasının bir uzantısıdır.

Adam, geçmiş gradyanların ölçeklendirilmiş L2 normu (kare) ile ters orantılı ağırlıkların güncellenmesi olarak anlaşılabilir. AdaMax bunu geçmiş degradelerin sonsuz normuna (maksimum) genişletir.

Genel olarak, AdaMax optimizasyon problemindeki her parametre için ayrı bir adım boyutunu (öğrenme hızı) otomatik olarak uyarlar (URL-15, 2022).

### 3.4.4. Kayıp Oranı Hesaplanması

#### 3.4.4.1. Categorical Crossentropy Sınıfı

Etiketler ve tahminler arasındaki çapraz entropi kaybını hesaplamaktadır. İki veya daha fazla etiket sınıfı olduğunda bu çapraz entropi kaybı işlevi kullanılır.

Kategorik çapraz entropi, çok sınıflı sınıflandırma görevlerinde kullanılan bir kayıp fonksiyonudur. Bunlar, bir örneğin birçok olası kategoriden yalnızca birine ait olabileceği ve modelin hangisi olduğuna karar vermesi gereken görevlerdir. Biçimsel olarak, iki olasılık dağılımı arasındaki farkı ölçmek için tasarlanmıştır.

Kategorik çapraz entropi kaybı fonksiyonu, aşağıdaki toplamı hesaplayarak bir örneğin kaybını hesaplar:

$$Kayıp (Loss) = - \sum_{i=1}^{çıkıti\ boyutu} y_i \times \log \hat{y}_i \quad (3.8)$$

Burada  $y_i$ , model çıktısında gösterilen  $i$ . skaler değerdir.  $y_i$  ifadesine karşılık gelen hedef değerdir. Çıktı boyutu ise model çıktısındaki skaler değerlerin sayısıdır.

Bu kayıp, iki ayrık olasılık dağılımının birbirinden ne kadar ayırt edilebileceğini sağlayan çok iyi bir ölçüdür. Bu bağlamda  $y_i$ ,  $i$  olayının meydana gelme olasılığıdır ve tüm  $y_i$ 'nin toplamı 1'dir. Yani tam olarak bir olay meydana gelebilir demektir. Eksi işareti ise dağılımlar birbirine yaklaştığında kaybın azalmasını sağlar (URL-16).

### 3.5. SMOTE

SMOTE (Synthetic Minority Over-Sampling Technique), sentetik veri üretilmesini sağlayan bir aşırı örnekleme sürecidir. Veri bilimi projelerinden en sık kullanılan yöntemlerden biridir. Yöntemin ana fikri, azınlık sınıfının örnekleri arasında belirli işlemler yaparak yeni azınlık sınıfı örnekleri yaratmaktır. Sentetik örnekler şu şekilde üretilir:

1. İncelenen öznitelik vektörü( $E_i$ ) ile en yakın komşusu arasındaki farkı alınır,
2. Bu farkı 0 ile 1 arasında rastgele bir sayı( $\delta$ ) ile çarpılır,
3. Çıkan sonuç incelenen özellik vektörüne eklenir ve yeni örnek oluşur.

$$E_{yeni} = E_i + (E_i - E_j) \delta \quad (3.9)$$

Gereken aşırı örnekleme miktarına bağlı olarak, en yakın k komşudan komşular rastgele seçilir. Bu işlem, aşırı öğrenme sorununun önüne geçer ve iyi bir sınıflandırma performansı sunar.

SMOTE yöntemi, en yaygın kullanılan ve çoğu zaman en başarılı örnekleme yöntemi olarak bilinmektedir. 2002 yılında geliştirilen algoritma birçok dengesiz veri kümesi problemine uygulanmıştır (Chawla ve ark., 2002). Rassal örnekleme yöntemlerinden farkı, azınlık sınıfı verileri kopyalamak yerine, incelenen örneklerin en yakın k komşusunu baz almak suretiyle yapay örnekler üretilmesidir. Algoritmanın çalışma adımları aşağıda belirtilen şekilde özetlenebilir:

Adım-1: Azınlık sınıfına ait her gözlemin k yakın komşusu aranır,

Adım-2: Azınlık sınıfına ait gözlem ile k yakın komşusu (kNN) olan gözlem arasındaki fark alınır,

Adım-3: (0,1) arasında rastgele bir sayı ( $\alpha$ ) seçilir, Adım 2'de bulunan fark ile bu sayı çarpılır,

Adım-4: Eşitlik 1 kullanılarak yeni sentetik gözlem elde edilir.

$$x_{yeni} = x_i + (x_j - x_i) * \alpha \quad (3.10)$$

Adım-5: İstenen sayıda sentetik gözlem oluşturmak için Adım 1-4 yenilenir (Yavaş, M., 2022).

### 3.6. Veri Seti

Bu çalışmada kullanılan veri seti bilimsel bilgiler ışığında araştırmacı tarafından oluşturulan prototip hidroponik sistemden elde edilmiştir. Prototip sistemden oluşturulan örnek veri tabanında 18 farklı veri için 417 adet veri bilgisi bulunmaktadır.

Prototip sistem, kaynak araştırmasından elde edilen bilgilerin yanında sektörde domates yetiştiriciliği yapan bir firmanın ziraat mühendisi ile görüşme yapılarak oluşturulmuştur. Bu görüşmeler sonucunda sistemin en önemli değerinin EC değeri olduğu öğrenilmiştir. Sistemin sağlık durumu ve besin kullanımı hakkındaki bilgileri giriş solüsyonundaki EC değeri ile çıkış solüsyonundaki EC değeri karşılaştırılarak bulunduğu tespit edilmiştir. Çalışmada kullanılan prototip hidroponik sistemi bu bilgiler ışığında dizayn edilmiştir ve veriler toplanmıştır.



Şekil 3.8. Deneyde kullanılan hidroponik sistem.

Veri setinde hidroponik sistemlerde kullanılan cihazlar yardımıyla elde edilen veriler giriş ve çıkış solüsyonundaki pH, EC, ppm değerlerinin yanında su sıcaklığı, hava sıcaklığı ve nemi, UV ışık değeri olmaktadır. pH ve EC değerlerinin giriş değerleri ile birlikte bu değerlerin birbirlerinden farkı ve bu fark sonucuna göre 3 farklı sınıfa ayrılmış değerleri de veri olarak tutulmuştur. Bu sınıfların nasıl belirlendiği ve tanımları aşağıdaki tabloda açıklanmıştır.

Çizelge 3.2. pH and EC sınıflandırılması.

|                       |                   |   |                      |
|-----------------------|-------------------|---|----------------------|
| $pH_{In}-pH_{Out}=pH$ | $-0.5 < pH < 0.5$ | 0 | Saf                  |
|                       | $pH < -0.5$       | 1 | Bazik                |
|                       | $pH > 0.5$        | 2 | Asidik               |
| $EC_{In}-EC_{Out}=EC$ | $-1 < EC < 1$     | 0 | Dengede              |
|                       | $EC < -1$         | 1 | Solüsyona Besin Ekle |
|                       | $EC > 1$          | 2 | Solüsyona Su Ekle    |

Besin çözeltilisinin bitki tarafından kullanımının anlaşılabilmesi için öncelikle bitkinin kullanımından sonra elde edilen atık besin çözeltilisi ile bitkiye verilen besin çözeltilisi arasındaki farka bakılması gerekir. Birçok çalışmada domates yetiştiriciliği için çok farklı pH ve EC değerleri verilmektedir. Genel olarak kabul edilen pH değerleri 5.0 ile 7.0 aralığındadır. EC değeri için bu 0,5 ile 1,8 arasındadır. Bu değerler bitki türlerine göre değişmektedir. Bu sistem için denge noktaları sadece sıfır olarak değil, sistemin hata oranı da dikkate alınarak sıfıra en yakın yerler olarak seçilmiştir.

Bu verilerin yanında EC ve ppm değerlerinin hesaplanması için gerekli olan cihaz gerilim değeri Rc olarak kayıt edilmiştir. Sistemi takip edebilmek için giriş solüsyonunda yeterli suyu olup olmadığı su seviyesi değeri ile kontrol edilirken, ışık ile sulama pompası cihazlarının aktif olup olmadığı röle değerleri ile veri tabanına eklenmiştir. Sistemde kullanılan röle sadece değerleri tutmak için kullanılmamış aynı zamanda ışık ve sulama pompası değerlerinin belirli zaman aralıklarında çalışmalarını için de kullanılmıştır. Sistemin durumu takip edilmek amacı ile Tablo 3.3 de gösterilen sınıflandırma kuralları kullanılmıştır.

**Tablo 3.3.** Sistem durumu ve durumlara karşılık gelen veri sayısı.

| Sulama Pompası Durumu | Işık Durumu | Sistem Durumu | Veri Sayısı |
|-----------------------|-------------|---------------|-------------|
| Kapalı                | Kapalı      | 0             | 115         |
| Kapalı                | Açık        | 1             | 220         |
| Açık                  | Kapalı      | 2             | 29          |
| Açık                  | Açık        | 3             | 53          |

Sistemde sulama pompasının çalışma sıklığı bitkiler büyüdükçe sulama döngülerinin ayarlanması gerekliliği göz önüne alınarak kararlaştırılmıştır. Yaprak alanları arttıkça ve meyve oluşumu devam ettikçe bitkiler daha fazla su talep edecek, bu nedenle sulama döngülerini kısaltacaktır. Tamamen olgun domates bitkileri günde 2 litre kadar su kullanabilir. İç mekan yetiştiriciliğinde, bu asma bitkilerinin olgunlaşma aşamasında en az 2 saatte bir sulaması önerilmektedir (Resh H., 2013). Bununla birlikte deneysel sistemimiz kapalı ve kontrollü bir alanda gerçekleştiği için 4 saatte bir sulanmıştır.

Işık durumu ise bitkiler yapay ışık altında yetiştiği için günde 14 ila 16 saatlik bir süre boyunca ışıklar açık kalmıştır. Bitkilerin alacağı ışık değerinin 5500 lüks (510 fit mum) olması ile bitkilerin üst kısmındaki yaprak yüzeyinde minimum yoğunluk istendiği için UV sensör ile ışık değeri ölçülmüştür (Resh H., 2013).

Sistemde kullanılan suyun sıcaklığı 27 ile 30 °C aralığında olmalıdır. Ortam sıcaklığı konusunda ise gece ve gündüz sıcaklıkları 5 ° F ila 10 ° F (3 ° C ila 5 ° C) arasında değişmeli ve gece sıcaklığı daha düşük olmalıdır. Domates, patlıcan, biber ve salatalık gibi çoğu ılık mevsim mahsulü için gece 60 ° F (16 ° C) ve gündüz 75 ° F (24 ° C) sıcaklık aralığı uygundur (Resh H., 2013).

Bu değerlerin yanında besin solüsyonu içindeki en önemli değerler olan pH ve EC değerleri bulunmaktadır. Hidroponik besin çözeltisi için optimum pH aralığı 5,8 ila 6,5 arasındadır ve hidroponik için ideal Ec aralığı 1,5 ila 2,5 dS / m arasındadır. EC sensörü tarafından bakım değerler öngörülen aralıkta değilse, bunu korumak için birlikte besin çözeltisine su eklenmelidir (Nalwade R., 2017). Sistemin bu giriş değerleri dikkati alınarak bitki sulaması gerçekleştirildikten sonra çıkış değerleri de ölçülmüş aradaki fark alınmıştır. Böylece bitkinin ne kadar besin kullandığı sulanmaya daha çok ihtiyacı olup olmadığı gibi bilgiler bilinmektedir.

Sistemde yeterli su bulunup bulunmadığı su seviyesi sensörü ile kontrol edilmiştir. Aynı zamanda sistemin bulunduğu ortamdaki nem miktarı da ölçülmüştür.

## 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu çalışmada, makine öğrenmesi ve derin öğrenme yöntemleri veri seti üzerinde uygulanmıştır. Uygulama için programlama dili python kullanılmıştır. Algoritma yöntemleri 3 farklı değer üzerinde çalıştırılmıştır. Düzensiz dağılan veri seti sınıflarında eşit dağılım sağlanması amacıyla SMOTE veri artırımı yöntemi kullanılmıştır. Bu yöntem azınlık veri kümelerini bazı matematiksel işlemler kullanarak çoğaltmaktadır. Amaç eşit örnekli veri sınıfları üretmektir. Eşit dağılımı sağlanan veri seti derin öğrenme modeliyle tekrar çalıştırılmıştır. Elde edilen tüm bu yöntemlerin sonuçları bu bölümde paylaşılmıştır.

### 4.1. Eğitim, Doğrulama ve Test

#### 4.1.1. Hold - Out Yöntemi

Veri seti, eğitim ve test olarak iki bölüme ayrılmıştır. Bu ayırım genellikle 80/20 ya da 70/30 şeklinde ayarlanmaktadır. Bu bölümlerden eğitim için toplam veri setinin %80'i, test için ise kalan %20'lik kısmı kullanılmıştır. Bu kullanımın amacı model üzerine denendiğinde 80/20 ayırımının daha yüksek doğruluk elde ettiğinin görülmesidir.

#### 4.1.2. Cross -Validation Yöntemi

Bu yöntem, veri setinin k ile belirtilen kadar alt veri seti grubuna ayrılması ile oluşturulur. Veri setinin kaç gruba ayrıldığını belirtmek için k-fold terimi kullanılır. Bu yöntemde, model alt gruplardan birini test için seçer ve diğer tüm grupları eğitim için kullanır. Model değerlendirme sonucu kayıt edilir. Tüm alt gruplar için bu işlem tekrarlanır. Bu çalışmada, veri seti hem 5-fold hem de 10-fold olarak iki şekilde uygulanmıştır. Sonuçları aşağıda paylaşılmıştır.

### 4.2. Performans Ölçütleri

Yapılan deneylerin performanslarının karşılaştırılması için gerçek pozitif (True Positive - TP), yanlış pozitif (False Positive - FP), gerçek negatif (True Negative - FN)

ve yanlış negatif (False Negative - FP) verileri kullanılarak hesaplanan performans ölçütleri aşağıda Çizelge 4.3'te gösterilmektedir.

**Çizelge 4.1.** Performans Ölçütleri

| Performans Ölçütü    | Denklemi  |
|----------------------|---|
| Doğruluk (Accuracy)  | $TN + TP / \text{Test Verisi Toplamı}$                                  |
| Kesinlik (Precision) | $TP/(FP+TP)$  |
| Duyarlılık (Recall)  | $TP / (FN+TP)$  |
| F1- Score            | $2*((\text{precision}*\text{recall})/(\text{precision}+\text{recall}))$ |

SMOTE öncesi temel halde olan veri seti, üç farklı değer türünde farklı algoritma yöntemleri kullanarak elde edilen sonuçları Çizelge 4.2. de paylaşılmıştır.

**Çizelge 4.2.** Algoritma Başarım Sonuçları

| Değer | Yöntem                 | Sonuç  |
|-------|------------------------|--------|
| Stat  | Lineer Regresyon       | %94,78 |
|       | Lojistik Regresyon     | %50    |
|       | Destek Vektör Makinesi | %96    |
|       | Gaussian Naive Bayes   | %99    |
|       | Karar ağaçları         | %100   |
|       | K-En Yakın Komşu       | %61    |
| pHCl  | Lineer Regression      | %45    |
|       | Lojistik Regresyon     | %83    |
|       | Destek Vektör Makinesi | %94    |
|       | Gaussian Naive Bayes   | %85    |
|       | Karar ağaçları         | %100   |
|       | K-En Yakın Komşu       | %87    |
| ECcl  | Lineer Regression      | %98,14 |
|       | Lojistik Regresyon     | %98    |
|       | Destek Vektör Makinesi | %100   |
|       | Gaussian Naive Bayes   | %100   |
|       | Karar ağaçları         | %100   |
|       | K-En Yakın Komşu       | %95    |

Elde edilen sonuçlar göz önüne alındığında ECcl sınıfının daima %95 ve üstü oranında başarımlar elde ettiği görülmüştür. Kullanılan tüm sınıflar ve yöntemler içerisinde karar ağaçları yöntemi daima %100 başarımlar oranı sağlamıştır. Karar ağaçları iyi bir sınıflandırma yöntemidir. Bunun ile birlikte veri setimizin kesin kurallı sınıflandırması modelin daha iyi sonuç vermesinde etkili olduğu varsayılabilir. Kaynak araştırması göz önüne alındığında karar ağaçlarının yüksek doğruluk sonucu vermesi beklenmektedir.

Tüm algoritma yöntemlerinin üç farklı türdeki sınıfların hepsinde kesinlik, duyarlılık gibi diğer performans ölçütlerinden elde edilen sonuçlar Çizelge 4.3.'te gösterilmiştir.

**Çizelge 4.3.** Stat değeri için farklı performans türlerinde tüm algoritmalar için sonuçlar.

| Lojistik Regresyon | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|--------------------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro              | 0.50                 | 0.50                | 0.50      | 80 / 20     | %50                 |
| Macro              | 0.13                 | 0.24                | 0.17      | 5-Fold      | %55                 |
| Weighted           | 0.26                 | 0.50                | 0.34      | 10-Fold     | %55                 |

| SVM      | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro    | 0.96                 | 0.96                | 0.96      | 80 / 20     | %96                 |
| Macro    | 0.96                 | 0.92                | 0.94      | 5-Fold      | %98                 |
| Weighted | 0.97                 | 0.96                | 0.96      | 10-Fold     | %98                 |

| Gaussian Naive Bayes | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------------------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro                | 0.99                 | 0.99                | 0.99      | 80 / 20     | %99                 |
| Macro                | 0.98                 | 0.99                | 0.99      | 5-Fold      | %99                 |
| Weighted             | 0.99                 | 0.99                | 0.99      | 10-Fold     | %99                 |

| Karar ağaçları | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro          | 1.00                 | 1.00                | 1.00      | 80 / 20     | % 100               |
| Macro          | 1.00                 | 1.00                | 1.00      | 5-Fold      | % 100               |
| Weighted       | 1.00                 | 1.00                | 1.00      | 10-Fold     | % 100               |

| KNN      | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro    | 0.61                 | 0.61                | 0.61      | 80 / 20     | %61                 |
| Macro    | 0.30                 | 0.37                | 0.33      | 5-Fold      | %61                 |
| Weighted | 0.48                 | 0.61                | 0.54      | 10-Fold     | %61                 |

**Çizelge 4.4.** pHCl değeri için farklı performans türlerinde tüm sonuçlar.

| Lojistik Regresyon | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|--------------------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro              | 0.83                 | 0.83                | 0.83      | 80 / 20     | %83                 |
| Macro              | 0.70                 | 0.61                | 0.65      | 5-Fold      | %83                 |
| Weighted           | 0.82                 | 0.83                | 0.82      | 10-Fold     | %83                 |

| SVM      | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro    | 0.94                 | 0.94                | 0.94      | 80 / 20     | %96                 |
| Macro    | 0.67                 | 0.64                | 0.63      | 5-Fold      | %98                 |
| Weighted | 0.97                 | 0.94                | 0.94      | 10-Fold     | %98                 |

| Gaussian Naive Bayes | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------------------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro                | 0.85                 | 0.85                | 0.85      | 80 / 20     | %85                 |
| Macro                | 0.59                 | 0.63                | 0.60      | 5-Fold      | %99                 |
| Weighted             | 0.93                 | 0.85                | 0.88      | 10-Fold     | %99                 |

| Karar ağaçları | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro          | 1.00                 | 1.00                | 1.00      | 80 / 20     | 1.00                |
| Macro          | 1.00                 | 1.00                | 1.00      | 5-Fold      | 1.00                |
| Weighted       | 1.00                 | 1.00                | 1.00      | 10-Fold     | 1.00                |

| KNN      | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro    | 0.87                 | 0.87                | 0.87      | 80 / 20     | %87                 |
| Macro    | 0.71                 | 0.75                | 0.72      | 5-Fold      | %87                 |
| Weighted | 0.89                 | 0.87                | 0.87      | 10-Fold     | %87                 |

**Çizelge 4.5.** ECcl değeri için farklı performans türlerinde tüm sonuçlar.

| Lojistik Regresyon | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|--------------------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro              | 0.98                 | 0.98                | 0.98      | 80 / 20     | %98                 |
| Macro              | 0.97                 | 0.98                | 0.98      | 5-Fold      | %83                 |
| Weighted           | 0.98                 | 0.98                | 0.98      | 10-Fold     | %83                 |

| SVM      | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro    | 1.00                 | 1.00                | 1.00      | 80 / 20     | %100                |
| Macro    | 1.00                 | 1.00                | 1.00      | 5-Fold      | %94                 |
| Weighted | 1.00                 | 1.00                | 1.00      | 10-Fold     | %94                 |

| Gaussian Naive Bayes | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------------------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro                | 1.00                 | 1.00                | 1.00      | 80 / 20     | %100                |
| Macro                | 1.00                 | 1.00                | 1.00      | 5-Fold      | %85                 |
| Weighted             | 1.00                 | 1.00                | 1.00      | 10-Fold     | %85                 |

| Karar ağaçları | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro          | 1.00                 | 1.00                | 1.00      | 80 / 20     | % 100               |
| Macro          | 1.00                 | 1.00                | 1.00      | 5-Fold      | % 100               |
| Weighted       | 1.00                 | 1.00                | 1.00      | 10-Fold     | % 100               |

| KNN      | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro    | 0.95                 | 0.95                | 0.95      | 80 / 20     | %95                 |
| Macro    | 0.96                 | 0.94                | 0.95      | 5-Fold      | %87                 |
| Weighted | 0.95                 | 0.95                | 0.95      | 10-Fold     | %87                 |

Çizelge 4.3.'de verilen bilgiler ışığında makine öğrenmesi yöntemlerinin Stat verisini tahmin etmedeki olasılıklarının SVM, Gaussian Naive Bayes ve karar ağaçları yöntemlerinde %95'den fazla olduğu görülmüştür.

Ancak hidroponik sistemlerde, sistemin tek başına makine öğrenimi ile kontrol edilmesi yeterli değildir. Daha önceden de bahsedildiği üzere sistemin gelişimini ve uzun ömürlülüğünü belirleyecek olan EC ve pH değerleri sağlıklı çalışması için en önemli değerlerdir.

Hidroponik sistemlerde EC ve pH değerleri sürekli izlenmelidir. Bu değerlerdeki değişimler sistemin bir bütün olarak sağlıklı olup olmadığını gösterir. Bu, bu kişinin tarım yönetimi konusundaki uzmanlığına en çok ihtiyaç duyulan alandır. Bu nedenle, bu alanları otomatik olarak kontrol etmek için makine öğrenimi yöntemleri kullanılabilir mi? Çizelge 4.4. ve 4.5. çeşitli makine öğrenimi algoritmalarının bu sorunun yanıt değerlerini tahmin etme becerilerine göre değerlendirilmesinin sonuçlarını göstermektedir.

Yukarıdaki tablolarda görüldüğü gibi, makine öğreniminin sonuçları artık %80'i aşıyor. Bu durumla karşılaştırıldığında makine öğrenmesi yöntemleri kullanıldığında tahmin edilen EC ve pH değerleri diğer tüm yöntemlere göre üstün sonuçlar vermiştir.

Veri setinin tüm sınıflarda eşit örnek dağılımına sahip olmaması üzerine, veri seti dağılımının sonuçlara etkisinin araştırılması amacıyla SMOTE yöntemi kullanılarak veri

artırma yöntemi izlenmiştir. Aşağıdaki Çizelge 4.7. de gösterildiği üzere veri setindeki sınıf örnekleri eşitlenmiştir.

**Çizelge 4.6.** Stat değeri için SMOTE sonucu.

| Class | SMOTE Öncesi | SMOTE Sonrası |
|-------|--------------|---------------|
| 0     | 41           | 117           |
| 1     | 24           | 117           |
| 2     | 117          | 117           |
| 3     | 91           | 117           |

**Çizelge 4.7.** Stat değeri için SMOTE ile veri artırımı sonrası farklı performans türlerinde tüm sonuçlar.

| Lojistik Regresyon | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|--------------------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro              | 0.30                 | 0.30                | 0.30      | 80 / 20     | %30                 |
| Macro              | 0.35                 | 0.30                | 0.28      | 5-Fold      | %32                 |
| Weighted           | 0.36                 | 0.30                | 0.28      | 10-Fold     | %32                 |

| SVM      | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro    | 0.99                 | 0.99                | 0.99      | 80 / 20     | %99                 |
| Macro    | 0.99                 | 0.99                | 0.99      | 5-Fold      | %99                 |
| Weighted | 0.99                 | 0.99                | 0.99      | 10-Fold     | %99                 |

| Karar ağaçları | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro          | 1.00                 | 1.00                | 1.00      | 80 / 20     | %100                |
| Macro          | 1.00                 | 1.00                | 1.00      | 5-Fold      | %100                |
| Weighted       | 1.00                 | 1.00                | 1.00      | 10-Fold     | %100                |

| KNN      | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro    | 0.54                 | 0.54                | 0.54      | 80 / 20     | %54                 |
| Macro    | 0.54                 | 0.54                | 0.53      | 5-Fold      | %54                 |
| Weighted | 0.54                 | 0.54                | 0.53      | 10-Fold     | %54                 |


SMOTE veri analizi sürecinden sonra, artırılmış verilere derin öğrenme uygulandı. Bu çalışmada yedi katman kullanılmıştır. Son katmana kadar sigmoid aktivasyonu kullanıldı. Son katmanda Softmax kullanılır. Optimizasyon için Adamax kullanıldı. Kategorik çapraz entropi, çok sınıflı sınıflandırma görevlerinde kullanılan bir kayıp işlevidir. Bunlar, bir örneğin birçok olası kategoriden yalnızca birine ait olabileceği ve modelin bunlardan birine karar vermesi gereken görevlerde kullanılır. Biçimsel olarak, iki olasılık dağılımı arasındaki farkı ölçmek için kararlı bir şekilde tasarlanmıştır.

**Çizelge 4.8.** Stat değeri için SMOTE ile veri artırımı sonrası DNN sonucu.

| DNN      | Kesinlik (Precision) | Duyarlılık (Recall) | F1- Score | Eğitim/Test | Doğruluk (Accuracy) |
|----------|----------------------|---------------------|-----------|-------------|---------------------|
| Micro    | 0.997                | 0.997               | 0.997     | 80 / 20     | %99,7               |
| Macro    | 0.997                | 0.997               | 0.997     |             |                     |
| Weighted | 0.997                | 0.997               | 0.997     |             |                     |

Sonuçlar göstermektedir ki SMOTE ile veri artırımı sonrası DNN en yüksek veri sonuçlarını elde etmektedir. Fakat doğrusal regresyon ve KNN artan veriler ile birlikte performans da düşüş yaşamaktadırlar. SVM ve karar ağaçları ise doğruluk değerleri oranını yükselttikleri görülmüştür.

Ayrıca çalışmamızda kullanılan veri setindeki özellik önemi araştırılmıştır. Yapılan çalışma sonucunda en önemli değerlerin EC ve pH değerleri olduğu tezimiz kanıtlanmıştır. Zira giriş solüsyondaki EC ve pH değerleri en önemli ilk iki özellik olarak tespit edilmiştir. Aşağıdaki şekilde özellik sıralaması görülmektedir.



Şekil 4.1. Veri setindeki özellik önem sırası şekilde gösterilmiştir.

## 5. SONUÇLAR VE ÖNERİLER

### 5.1 Sonuçlar

Hızla gelişen teknoloji, tarım alanlarının sanayileşme ve şehirleşme de kullanılması ve hızla artan nüfus gibi etkenler nüfusun hızla çoğalmasını sağlarken nüfusun ihtiyaçlarını karşılayacak besin maddelerinin azalmasına neden olmaktadır. Bu durum farklı tarım yöntemlerine yoğunlaşma ve o yöntemleri geliştirme gibi sonuçlara sebebiyet vermiştir. Bu araştırmalardan biri olan hidroponik tarım yöntemleri son yıllarda popülerlik kazanmıştır.

Hidroponik tarım yöntemlerini geliştirmek için çeşitli yöntemler denendi. Fakat hidroponik tarımın en çok ihtiyaç duyduğu şey bu tarım türünde bilgi sahibi olan kişiler olmaktadır. Bu araştırmanın temel amacı, hidroponik tarım teknikleri için gerekli nitelikli bireylerin makinelerle değiştirilip değiştirilemeyeceğini araştırmaktır.

Araştırmamızdaki prototipi geliştirmek ve sistemin düzgün çalışmasından emin olmak için öncelikle kaynak araştırması yapılmıştır. Kaynak araştırmasından edindiğimiz bilgiler ile sektörde bu konu üzerine çalışma yapılan mühendis ile görüşülmüştür. Teorik ve pratik çalışan araştırmacılardan elde edilen bilgilerin toplamında prototip bir sistem tasarlanmış ve veriler elde edilmiştir.

Bu makalenin bulguları, makine öğrenimi algoritmalarının hidroponik tarımdaki insanları potansiyel olarak % 80'in üzerinde bir doğrulukla değiştirdiğini göstermektedir. Ayrıca, derin sinir ağları (DNN) kalifiye personelin değiştirilmesinde % 99 gibi başarılı bir orana sahiptir. Bir prototip sistemden elde edilen veriler kullanılarak yapılan araştırmanın sonuçları, makinelerin, özellikle EC ve pH değerlerini tahmin etmede profesyonellerin yerini daha hassas bir şekilde alabileceğini göstermektedir.

### 5.2 Öneriler

Bu çalışmada, deneyler için kullanılmak üzere prototip bir hidroponik tarım sistemi kurulmuştur. Kurulan prototip sistemde elde edilen veriler bulut sistemi üzerinde toplanmıştır. Toplanan veriler SVM, KNN, Naive Bayes, Karar ağaçları ve doğrusal regresyon gibi makine öğrenmesi yöntemlerinin yanında derin öğrenme yöntemi kullanılarak çalıştırılmış ve elde edilen sonuçlar incelenmiştir.

Çalışmada elde edilen sonuçlara göre, daha sonraki arařtırmalarda hibrit algoritmik yaklaşımlarının kullanılabilceęi görülmüřtür. Dięer bir yaklaşıml, farklı DNN katmanları ve optimizasyonları kullanmaktır. Öte yandan, sistemin güvenilirlięi, iyi hazırlanmış ve iyi topraklanmış bir sistemi ile karşılaştırılabilir.



## KAYNAKLAR

- A. Munandar et al., "Design and development of an IoT-based smart hydroponic system," 2018 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI), 2018, pp. 582-586, doi: 10.1109/ISRITI.2018.8864340.
- A. Phutthisathian, N. Pantasen, and N. Maneerat, "Ontology-based nutrient solution control system for hydroponics," in 2011 First International Conference on Instrumentation, Measurement, Computer, Communication and Control. IEEE, 2011, pp. 258–261.
- Alpaydin, Ethem. *Introduction to Machine Learning*. MIT Press, 2010. Accessed 12 August 2022.
- Arduino, S. A. (2015). Arduino. Arduino LLC, 1.
- Bhattacharai, Surya; Salvaudon, Clemence; Midmore, David (2008): Oxygation of the rockwool substrate for hydroponics. CQUniversity. Journal contribution. <https://hdl.handle.net/10018/30887>
- Brandt CA (2017) Sustainability standards and sustainable development –synergies and trade-offs of transnational governance. *Sustain Dev* 25:25–34. <https://doi.org/10.1002/sd.1639>
- Chanya Peuchpanngarm, Pantita Srinitiworawong, Wannisa Samerjai and Thanwadee Sunetnanta, "DIY Sensor-Based Automatic Control Mobile Application for Hydroponics," Fifth ICT International Student Project (ICT-ISPC), IEEE Publication, 2016.
- C. J. G. Aliac and E. Maravillas, "IOT Hydroponics Management System," 2018 IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM), 2018, pp. 1-5, doi: 10.1109/HNICEM.2018.8666372.
- G. D. Britto and S. Hamdare, "An AI-based system design to develop and monitor a hydroponic farm," in 2018 International Conference on Smart City and Emerging Technology (ICSCET), Jan 2018, pp. 1–5.

- D. Eridani, O. Wardhani and E. D. Widiyanto, "Designing and implementing the arduino-based nutrition feeding automation system of a prototype scaled nutrient film technique (NFT) hydroponics using total dissolved solids (TDS) sensor," 2017 4th International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE), Semarang, Indonesia, 2017, pp. 170-175, doi: 10.1109/ICITACEE.2017.8257697.
- Domingues, D. S., Takahashi, H. W., Camara, C. A., & Nixdorf, S. L. (2012). Automated system developed to control pH and concentration of nutrient solution evaluated in hydroponic lettuce production. *Computers and electronics in agriculture*, 84, 53-61.
- dos Santos MJPL (2016) Smart cities and urban areas–aquaponics as innovative urban agriculture. *Urban For Urban Green* 20:402. <https://doi.org/10.1016/j.ufug.2016.10.004>
- D. Yolanda, H. Hindersah, F. Hadiatna and M. A. Triawan, "Implementation of Real-Time Fuzzy logic control for NFT-based hydroponic system on Internet of Things environment," 2016 6th International Conference on System Engineering and Technology (ICSET), Bandung, Indonesia, 2016, pp. 153-159, doi: 10.1109/ICSEngT.2016.7849641.
- D. Savvas, "SW–soil and water: Automated replenishment of re- cycled greenhouse effluents with individual nutrients in hydropon- ics by means of two alternative models," *Biosystems Engineer- ing*, vol. 83, no. 2, pp. 225 – 236, 2002. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S1537511002901066>
- D.S.Domingues,H.W.Takahashi,C.A.Camara,andS.L.Nixdorf,"Auto- mated system developed to control ph and concentration of nutrient solution evaluated in hydroponic lettuce production," *Computers and electronics in agriculture*, vol. 84, pp. 53–61, 2012.
- El Naqa, I., Murphy, M.J. (2015). What Is Machine Learning?. In: El Naqa, I., Li, R., Murphy, M. (eds) *Machine Learning in Radiation Oncology*. Springer, Cham. [https://doi.org/10.1007/978-3-319-18305-3\\_1](https://doi.org/10.1007/978-3-319-18305-3_1)

- FAO (2017) Food and Agriculture Organization of the United Nations. *The State of Food and Agriculture 2017: Leveraging Food Systems for Inclusive Rural Transformation*. Edited by Food and Agriculture Organization, FAO, 2017.
- Foley JA, Ramankutty N, Brauman KA, Cassidy ES, Gerber JS, Johnston M, Mueller ND, O'Connell C, Ray DK, West PC, Balzer C, Bennett EM, Carpenter SR, Hill J, Monfreda C, Polasky S, Rockström J, Sheehan J, Siebert S, Tilman D, Zaks DPM (2011) Solutions for a cultivated planet. *Nature* 478:337–342. <https://doi.org/10.1038/nature10452>
- Gibeaut DM, Hulett J, Cramer GR, Seemann JR. Maximal biomass of *Arabidopsis thaliana* using a simple, low-maintenance hydroponic method and favorable environmental conditions. *Plant Physiol.* 1997 Oct;115(2):317-9. doi: 10.1104/pp.115.2.317. PMID: 9342857; PMCID: PMC158488.
- Goddek, S., Joyce A., Kotzen B., Burnell G.M., 2019, Aquaponics Food Production Systems: Combined Aquaculture and Hydroponic Production Technologies for the Future. Springer International Publishing, 3. [https://doi.org/10.1007/978-3-030-15943-6\\_1](https://doi.org/10.1007/978-3-030-15943-6_1)
- Godfray HCJ, Beddington JR, Crute IR, Haddad L, Lawrence D, Muir JF, Pretty J, Robinson S, Thomas SM, Toulmin C (2010) Food security: the challenge of feeding 9 billion people. *Science* 327:812–818. <https://doi.org/10.1126/science.1185383>
- Kennion, M. O., Maitland, S., & Brady, M. R. (2022). Machine learning as a new horizon for colorectal cancer risk prediction? A Systematic Review. *Health Sciences Review*, 100041.
- K.Wongpatikaseree,N.Hnoohom,andS.Yuenyong,“Machinelearningmeth- ods for assessing freshness in hydroponic produce,” in 2018 International Joint Symposium on Artificial Intelligence and Natural Language Processing (iSAI-NLP). IEEE, 2018, pp. 1–4.
- Kosmatos, E.A., Tselikas, N.D. and Boucouvalas, A.C. (2011) Integrating RFIDs and Smart Ob-jects into a Unified Internet of Things Architecture. *Advances in Internet of Things: Scientific Research*, 1, 5-12. <http://dx.doi.org/10.4236/ait.2011.11002>

- LeCun, Y., Bengio, Y. & Hinton, G. Deep learning. *Nature* 521, 436–444 (2015).  
<https://doi.org/10.1038/nature14539>
- M. I. Alipio, A. E. M. Dela Cruz, J. D. A. Doria and R. M. S. Fruto, "A smart hydroponics farming system using exact inference in Bayesian network," 2017 IEEE 6th Global Conference on Consumer Electronics (GCCE), Nagoya, Japan, 2017, pp. 1-5, doi: 10.1109/GCCE.2017.8229470.
- Mehra, M., Saxena, S., Sankaranarayanan, S., Tom, R. J., & Veeramanikandan, M. (2018). IoT based hydroponics system using Deep Neural Networks. *Computers and electronics in agriculture*, 155, 473-486.
- Mohmed, G., Grundy, S., Lotfi, A., Lu, C. (2022). Using AI Approaches for Predicting Tomato Growth in Hydroponic Systems. In: Jansen, T., Jensen, R., Mac Parthaláin, N., Lin, CM. (eds) *Advances in Computational Intelligence Systems. UKCI 2021. Advances in Intelligent Systems and Computing*, vol 1409. Springer, Cham. [https://doi.org/10.1007/978-3-030-87094-2\\_24](https://doi.org/10.1007/978-3-030-87094-2_24)
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR).[Internet]*, 9, 381-386.
- Nunberg, G. (2012) *The Advent of the Internet: 12th April, Courses.*
- N. S. Kumar, B. Vuayalakshmi, R. J. Prarthana and A. Shankar, "IOT based smart garbage alert system using Arduino UNO," 2016 IEEE Region 10 Conference (TENCON), 2016, pp. 1028-1034, doi: 10.1109/TENCON.2016.7848162.
- Nalwade, R., & Mote, T. (2017, May). Hydroponics farming. In *2017 International Conference on Trends in Electronics and Informatics (ICEI)* (pp. 645-650). IEEE.
- P. Belhekar, A. Thakare, P. Budhe, U. Shinde and V. Waghmode, "Automated System for Farming with Hydroponic Style," 2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA), 2018, pp. 1-4, doi: 10.1109/ICCUBEA.2018.8697884.
- P.Belhekar,A.Thakare,P.Budhe,U.Shinde,andV.Waghmode,“Automated system for farming with hydroponic style,” in 2018 Fourth International Conference on

- Computing Communication Control and Automation (ICCUBEA), Aug 2018, pp. 1–4.
- R. Nalwade and T. Mote, "Hydroponics farming," 2017 International Conference on Trends in Electronics and Informatics (ICEI), 2017, pp. 645-650, doi: 10.1109/ICOEI.2017.8300782.
- Resh, Howard M. *Hydroponic Food Production: A Definitive Guidebook for the Advanced Home Gardener and the Commercial Hydroponic Grower, Seventh Edition*. CRC Press, 2016, 1-8.
- Resh, Howard. *Hobby Hydroponics*. Second Edition ed., CRC Press, 2013. (Resh 22)
- S. Tagle et al., "Development of an Automated Data Acquisition System for Hydroponic Farming," 2018 IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM), Baguio City, Philippines, 2018, pp. 1-5, doi: 10.1109/HNICEM.2018.8666373.
- S. YAMAGUCHI, Y. TAKAHASHI, and T. HAYASHI, "Small indoor hydroponic system with renewable energy," in 2018 18th International Conference on Control, Automation and Systems (ICCAS). IEEE, 2018, pp. 313–318.
- S. Ruengittinun, S. Phongsamsuan and P. Sureeratanakorn, "Applied internet of thing for smart hydroponic farming ecosystem (HFE)," 2017 10th International Conference on Ubi-media Computing and Workshops (Ubi-Media), 2017, pp. 1-4, doi: 10.1109/UMEDIA.2017.8074148.
- T. Kaewwiset and T. Yooyativong, "Electrical conductivity and pH adjusting system for hydroponics by using linear regression," 2017 14th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON), Phuket, Thailand, 2017, pp. 761-764, doi: 10.1109/ECTICon.2017.8096350.
- T. Asao. *Hydroponics: A Standard Methodology for Plant Biological Researches*. IntechOpen, ISBN: 9789535103868, 2012, 1-16.

T. Namgyel et al., "IoT based hydroponic system with supplementary LED light for smart home farming of lettuce," 2018 15th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON), 2018, pp. 221-224, doi: 10.1109/ECTICon.2018.8619983.

UN (2014) World's population increasingly urban with more than half living in urban areas | UN DESA | United Nations Department of Economic and Social Affairs [WWW Document]. URL <http://www.un.org/en/development/desa/news/population/world-urbanization-prospects-2014.html> . [Ziyaret Tarihi: 18 Temmuz 2022].

UN (2017) The sustainable development goals report. UN, New York

URL-1, [https://en.wikipedia.org/wiki/Expanded\\_clay\\_aggregate](https://en.wikipedia.org/wiki/Expanded_clay_aggregate). Erişim Tarihi: 16.07.2022

URL-2,<https://www.epicgardening.com/hydroponic-systems/>. Erişim Tarihi:18.07.2022.

URL-3, <https://devreyakan.com/isik-sensoru/>. Erişim Tarihi:18.07.2022.

URL-4,<https://www.direnc.net/analog-isik-yogunlugu-sensor-modulu>. Erişim Tarihi:18.07.2022

URL-5, <https://www.direnc.net/dht22-sicaklik-ve-nem-sensoru>, Erişim Tarihi:25.07.2022.

URL-6,<https://www.direnc.net/ds18b20-sicaklik-sensoru-su-gecirmez>,Erişim Tarihi:25.07.2022.

URL-7, <https://en.wikipedia.org/wiki/NodeMCU>, Erişim Tarihi:25.07.2022.

URL-8,<https://www.direnc.net/5v-2-kanal-role-karti>, Erişim Tarihi:25.07.2022.

URL-9,<https://www.dfrobot.com/product-1782.html>,Erişim Tarihi:26.07.2022.

URL-10,[https://wiki.dfrobot.com/Liquid\\_Level\\_Sensor-FS-IR02\\_SKU\\_SEN0205](https://wiki.dfrobot.com/Liquid_Level_Sensor-FS-IR02_SKU_SEN0205),Erişim Tarihi:29.07.2022.

URL-11,<https://topol.hee.nhs.uk/>, Erişim Tarihi: 30.07.2022.

- URL-12,<https://www.educative.io/answers/what-is-sigmoid-and-its-role-in-logistic-regression>, Erişim Tarihi: 02.08.2022.
- URL-13,<https://machinelearningmastery.com/softmax-activation-function-with-python/>, Erişim Tarihi: 02.08.2022.
- URL-14,<https://deeptai.org/machine-learning-glossary-and-terms/softmax-layer>, Erişim Tarihi: 02.08.2022.
- URL-15,<https://machinelearningmastery.com/gradient-descent-optimization-with-adamax-from-scratch/#:~:text=AdaMax%20algorithm%20is%20an%20extension,A%20Method%20for%20Stochastic%20Optimization.%E2%80%9D>, Erişim Tarihi: 02.08.2022.
- URL-16,[https://keras.io/api/losses/probabilistic\\_losses/#categorical\\_crossentropy\\_class](https://keras.io/api/losses/probabilistic_losses/#categorical_crossentropy_class), Erişim Tarihi: 02.08.2022.
- Van Vuuren DP, Bouwman AF, Beusen AHW (2010) Phosphorus demand for the 1970–2100 period: a scenario analysis of resource depletion. *Glob Environ Chang* 20:428–439. <https://doi.org/10.1016/J.GLOENVCHA.2010.04.004>
- Yavaş, Mustafa, et al. “Covid-19 Veri Kümesinin SMOTE Tabanlı Örnekleme Yöntemi Uygulanarak Sınıflandırılması.” *Avrupa Bilim ve Teknoloji Dergisi*, vol. Özel Sayı, Ağustos 2020, pp. 258-264. 1238335, <https://dergipark.org.tr/tr/download/article-file/1238335>. Accessed 10 Ağustos 2022.
- Zhou, Zhi-Hua. *Machine Learning*. Translated by Shaowu Liu, Springer Nature Singapore, 2021.
- Jumras P, Nathaphon B, Siriwan W., et.al, “Internet of Things for Planting in Smart Farm Hydroponics Style,” International Computer Science and Engineering Conference (ICSEC), IEEE Publication, 2016.
- Wongpatikaseree, K., Hnoohom, N., & Yuenyong, S. (2018, November). Machine learning methods for assessing freshness in hydroponic produce. In 2018 International Joint Symposium on Artificial Intelligence and Natural Language Processing (Isai-NLP) (pp. 1-4). IEEE.