

Bölüm 7

MAKİNE ÖĞRENİMİ (ML) VE TARIMDAKİ UYGULAMALARI

Ali ÇAYLI¹

GİRİŞ

Temel gıda kaynağı olan tarımsal üretim hem insanların beslenme gereksinimini karşılaması hem de sağladığı istihdam açısından ülke ekonomileri için oldukça önemlidir ve tarım ve gıda sektöründeki ilgili tüm işletmeler ile bir şekilde bağlantı kurar ve etkileşime girer. Nispeten geniş bir tarımsal temele sahip olan bir ülke, sosyal ve ekonomik olarak zengin olarak kabul edilmektedir. Aynı zamanda ekonomisi tarıma dayalı ülkelerde, tarım birincil istihdam kaynağıdır (1). Sürekli artan nüfus, tarım sistemi üzerinde daha fazla baskı oluşturmaktadır. Artık dijital tarım olarak da adlandırılan tarımsal teknoloji ve hassas tarım, en az çevresel etki ile tarımsal üretkenliği artırmak için veri yoğun yaklaşımları kullanan yeni bilimsel alanlar olarak ortaya çıkmıştır. Modern tarım sisteminde üretilen veriler, ortamın (bitki, toprak ve hava koşullarının etkileşimi) ve yapılan işlemin daha iyi anlaşılmasını sağlayan ve daha doğru sonuçlar elde edilmesini sağlayan çeşitli farklı sensörler tarafından sağlanmakta ve bu şekilde daha hızlı karar verme imkanı sağlamaktadır (2). Tarım sisteminde üretilen bu verilen işlenmesinde ise yapay zekâ uygulamaları öne çıkmaktadır. Yapay zekâ (AI), kendi kendine öğrenebilen, planlayabilen, algılayabilen veya işleyebilen insan beyninin yapay olarak yaratılmasını tanımlamak için kullanılmaktadır. AI'nın kullanımı ile görsel algılama, konuşma tanıma, karar verme ve dil çevirisi gibi insan zekasına ihtiyaç duyan görevleri yapabilen bilgisayar sistemlerinin geliştirilmesi mümkün olabilmektedir. Makine öğrenimi (ML) ve derin öğrenme (DL), en sık kullanılan yapay zekâ yaklaşımlarından ikisidir. Bireyler, işletmeler ve devlet kurumları, verileri tahmin etmek ve onlardan öğrenmek için bu modelleri kullanmaktadırlar. Gıda endüstrisindeki verilerin karmaşıklığı ve çeşitliliği için ML modelleri de geliştirilmekte ve bu alanda birçok bilimsel çalışmalar yürütülmektedir (3, 4). ML, çevredeki ortamdan öğrenerek insan zekasını tak-

¹ Doç. Dr. Kahramanmaraş Sütçü İmam Üniversitesi, Türkoğlu Meslek Yüksekokulu, alicayli@ksu.edu.tr

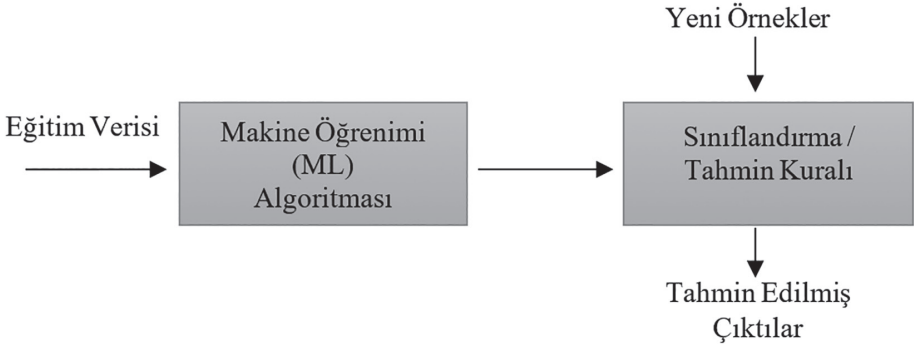
lit etmek için tasarlanmış, gelişen bir hesaplama algoritmasıdır. ML'ye dayalı teknikler, örüntü tanıma, bilgisayarla görme, uzay aracı mühendisliği, finans, eğlence ve hesaplamalı biyolojiden biyomedikal ve tıbbi uygulamalara kadar çeşitli alanlarda başarıyla uygulanmıştır (5). Bir ML modeli, araştırma problemine ve araştırma sorularına bağlı olarak tanımlayıcı veya tahmine dayalı olabilir. Betimleyici modeller, toplanan verilerden bilgi edinmek ve olup biteni açıklamak için kullanılırken, tahmine dayalı modeller geleceğe yönelik tahminlerde bulunmak için kullanılmaktadır (6). ML, tarımsal üretim ortamlarında veri yoğun süreçleri çözmek, ölçmek ve anlamak ve yeni fırsatlar yaratmak için büyük veri teknolojileri ve yüksek performanslı bilgi işlem araçları ile birlikte ortaya çıkmıştır. Diğer tanımların yanı sıra ML, makinelere sabit bir şekilde programlanmadan esnek bir şekilde öğrenme yeteneği kazandıran bilimsel alan olarak da tanımlanmaktadır (7). ML konusunda yapılan araştırmalar yıldan yıla artarak daha fazla alanda kullanılmasını sağlayacak bilimsel çalışmalara konu olmaktadır. Örneğin biyoinformatik, biyokimya, tıp, meteoroloji, ekonomik bilimler, robotik, su ürünleri yetiştiriciliği, gıda güvenliği ve klimatoloji dahil olmak üzere giderek daha fazla alanda başarı ile uygulanmaktadır.

Bu çalışmada öncelikle ML tanımlamaları, çeşitli algoritmalar, öğrenme modelleri üzerinde durulmuş ve literatürdeki tarımsal alanda yapılan çalışmalar ve bu çalışmaların bulguları incelenmiştir.

MAKİNE ÖĞRENİMİ

ML, laboratuvar merakından yaygın ticari kullanımda pratik bir teknolojiye kadar son yirmi yılda çarpıcı bir şekilde ilerlemiştir. AI içinde, ML, bilgisayarla görme, konuşma tanıma, doğal dil işleme, robot kontrolü ve diğer uygulamalar için pratik yazılım geliştirmede en çok tercih edilen yöntem olarak öne çıkmıştır. AI sistem geliştiricileri, istenen yanıtı tahmin etmek için geliştirdikleri uygulamalarda, sistemin gereksinim duyduğu tüm olası girdileri manuel olarak programlamaktansa, istenen girdi-çıkıtı davranışı örneklerini ve ilişkilerini uygulamaya göstererek, modeli eğitmekte ve ML yöntemiyle çok daha kolay bir şekilde tahmin modelleri geliştirmektedirler. ML'nin etkisi, bilgisayar bilimlerinde ve tüketici hizmetleri, karmaşık olmayan sistemlerin arızalarının teşhisi ve lojistik zincirlerinin kontrolü gibi veri yoğun konularla ilgilenen bir dizi endüstride de geniş çapta hissedilmektedir. Yüksek verimli deneysel verileri yeni yollarla analiz etmek için ML yöntemleri geliştirildiğinden, biyolojiden kozmolojiye ve sosyal bilimlere kadar ampirik bilimlerde benzer şekilde geniş bir etki yelpazesi oluşmuştur (8).

Tipik olarak, ML metodolojileri, bir görevi gerçekleştirmek için “deneyimden” (eğitim verileri) öğrenmek amacıyla bir öğrenme sürecini içermekte ve veriler bir dizi örnekten oluşmaktadır. Genellikle bu tekil örnek, özellikler veya değişkenler olarak da bilinen bir dizi nitelik tarafından tanımlanmaktadır. Bu tanımlamalar, nominal (numaralandırma), ikili (yani, 0 veya 1), sıralı (örneğin, A+ veya B-) veya sayısal (tamsayı, gerçek sayı, vb.) olabilir. ML modelinin belirli bir görevdeki performansı, zaman içinde deneyimle geliştirilmiş bir performans metriği ile ölçülmektedir. ML modellerinin ve algoritmalarının performansını hesaplamak için çeşitli istatistiksel ve matematiksel modeller kullanılmaktadır. Öğrenme sürecinin bitiminden sonra, eğitilen model, eğitim sürecinde elde edilen deneyim kullanılarak yeni örnekleri (test verileri) sınıflandırmak, tahmin etmek veya kümelemek için kullanılabilir. Şekil 1’de, tipik bir ML yaklaşımı gösterilmektedir (2).



Şekil 1. Tipik bir makine öğrenimi (ML) yaklaşımı

ML işlemleri tipik olarak öğrenme türüne (denetimli/denetimsiz), öğrenme modellerine (sınıflandırma, regresyon, kümeleme ve boyutluluk azaltma) veya seçilen görevi uygulamak için kullanılan öğrenme modellerine bağlı olarak farklı şekilde sınıflandırılabilir (2).

Boyut Azaltma Analizi

Verinin çok sayıda özelliğe sahip olduğu ortamlarda, boyutunun küçültülmesi veya bazı özelliklerini koruyan daha düşük boyutlu bir temsiline bulunması genellikle arzu edilmektedir. Boyut azaltma (veya çok yönlü öğrenme) teknikleri için temel argümanlar ise veriler üzerinde sonraki işlemleri hızlandırmak için ilk verileri bir ön işleme adımı olarak sıkıştırmak (hesaplamalı), girdi verilerini


iki veya üç boyutlu alanlara eşleyerek araştırmayla ilgili analiz için verileri görselleştirmek (görselleştirme) ve daha küçük ve daha etkili veya kullanışlı bir dizi özellik oluşturmaktır (özellik çıkarma) (9). En yaygın boyut küçültme algoritmalarından bazıları, temel bileşen analizi (10), kısmi en küçük kareler regresyonu (11) ve doğrusal ayırma (12) analizidir.

Öğrenme Modelleri ve Sınıflandırma Algoritmaları

Günümüzde birçok sınıflandırma algoritması mevcuttur. Ancak hangisinin diğerinden üstün olduğu sonucuna varmak mümkün değildir. Bu algoritmaların başarısı mevcut veri setinin yapısına ve uygulamasına bağlıdır. Örneğin, sınıflar doğrusal olarak ayrılabilirse, Fisher'ın doğrusal ayırıcısı gibi lojistik regresyon doğrusal sınıflandırıcılar karmaşık modellerden daha iyi performans gösterebilmektedir.

Regresyon

Lojistik regresyon kökeni on dokuzuncu yüzyıla kadar dayanabilmesine rağmen, özellikle son yirmi yılda bilimsel araştırmalarda giderek daha fazla kullanılan bir istatistiksel araç haline gelmiştir. İkili bir sonucun ortaya çıkmasının bir veya daha fazla bağımsız değişkenden tahmin edileceği durumlar için tercih edilen istatistik olarak kabul edilmektedir. Şekil 2'de genel bir regresyon modeli verilmiştir (13).

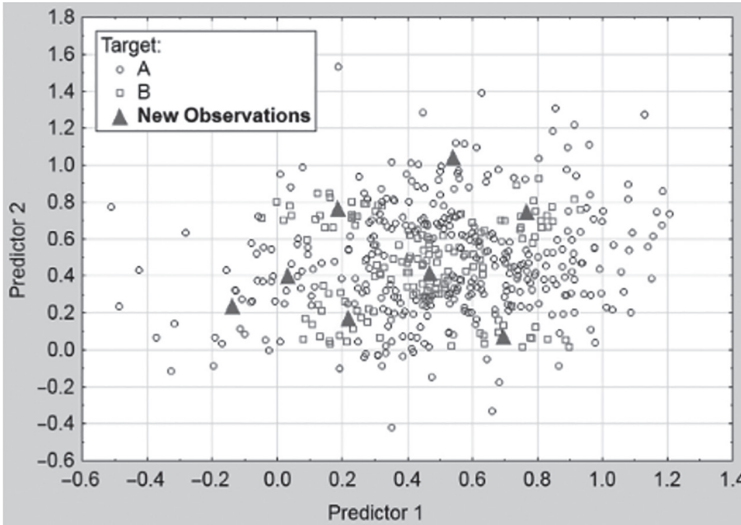


Şekil 2. Genelleştirilmiş doğrusal regresyon modeli ile tahmin

Regresyon, bilinen girdi değişkenlerine göre bir çıktı değişkeninin tahmini sağlamayı amaçlayan denetimli bir öğrenme modeli oluşturur. Bilinen algoritmaların çoğunda lineer regresyon ve lojistik regresyon (14) ile adım adım regresyon (15) kullanılmaktadır. Ayrıca, sıradan en küçük kareler regresyonu, çok değişkenli uyarlamalı regresyon eğrileri, çoklu doğrusal regresyon, kübist ve yerel olarak tahmin edilen dağılım grafiği yumuşatma gibi daha karmaşık regresyon algoritmaları da geliştirilmiştir (16-18).

Kümeleme

Kümeleme, tipik olarak doğal veri gruplamalarını (kümeleri) bulmak için kullanılan denetimsiz öğrenme modelinin tipik bir uygulamasıdır. İyi kurulmuş kümeleme teknikleri, k-ortalamlar tekniği, hiyerarşik teknik ve beklenti maksimizasyon tekniğidir (19, 20). K-En yakın komşu algoritması (K-Nearest Neighbors) ise, eğitim veri noktalarına karşılık gelen tüm örnekleri n-boyutlu uzayda saklayan tembel bir öğrenme algoritmasıdır. K-en yakın komşu algoritması aynı zamanda “bellek tabanlı öğrenici” olarak da bilinir. Şekil 3’te gösterilen modellemede genel yaklaşım verilmiştir. Bu yaklaşım, bir resmi görmek için bir oyun kartını ters çevirme ve daha sonra destede önceki resimlerin nerede bulunduğu dair hafızanıza dayanarak bir sonrakinde hangi kartların ortaya çıkacağına dair tahminler yapmaya çalışma oyununa benzer (21).



Şekil 3. Yeni gözlemlerin k-En Yakın Komşu yöntemi kullanılarak sınıflandırılması

Bilinmeyen bir ayırık veri alındığında, kaydedilen en yakın k örneğini (en yakın komşular) analiz eder ve tahmin olarak en yaygın sınıfı döndürür ve gerçek değerli veriler için k en yakın komşunun ortalamasını döndürür (22).

Bayes Modelleri

Bayes modelleri, niteliklerin koşullu olarak bağımsız olan, basit bir varsayım altında Bayes teoreminden esinlenen, olasılıksal bir sınıflandırıcıdır. Bayes, uygulanması çok kolay bir algoritmadır ve çoğu durumda iyi sonuçlar elde edilmektedir. Diğer birçok sınıflandırıcı türü için kullanılan zor ve karmaşık yinelemeli yaklaşım yerine doğrusal olduğundan daha büyük veri kümelerine kolayca ölçeklenebilmektedir (23).

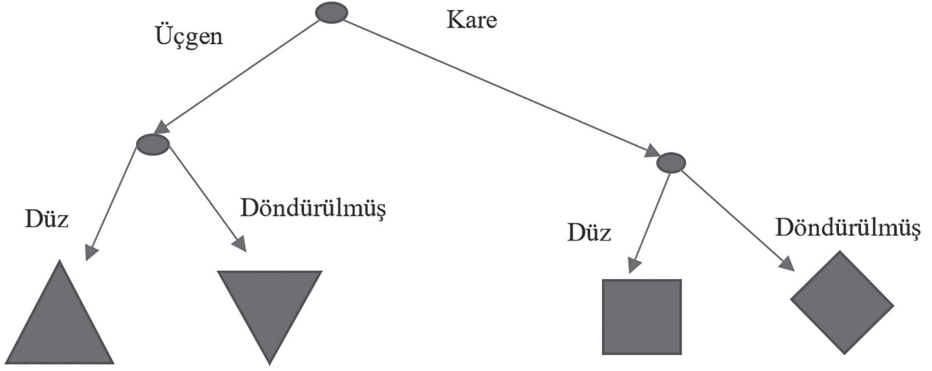
Örnek Tabanlı Modeller

Örnek tabanlı modeller (Instance Based Models), yeni örnekleri eğitim veri tabanındaki örneklerle karşılaştırarak öğrenen bellek tabanlı modellerdir. Bir dizi soyutlama tutmazken doğrudan mevcut verilerden hipotezler kurarlar ve yalnızca belirli örnekleri kullanarak sınıflandırma veya regresyon tahminleri üretirler. Bu modellerin dezavantajı, karmaşıklıklarının verilerle birlikte artmasıdır. Bu kategorideki en yaygın öğrenme algoritmaları k -en yakın komşu (24), yerel ağırlıklı öğrenme (25) ve öğrenme vektörü nicelemedir (26).

Karar Ağaçları

Karar ağaçları, sınıflandırma veya regresyon modelleri oluşturmak amacıyla kullanılan ağaç şeklinde yapılandırılan bir algoritmadır. Sınıflandırma için birbirini dışlayan ve kapsamlı olan bir if-then kural kümesini kullanır. Kurallar, eğitim verileri birer birer kullanılarak sırayla öğrenilir. Her kural öğrenildiğinde, kuralların kapsadığı demetler kaldırılır. Bu işleme eğitim setinde bir sınıflandırma koşulu sağlanıncaya kadar devam edilir. Örnek bir karar ağacı yapısı Şekil 4'de verilmiştir.

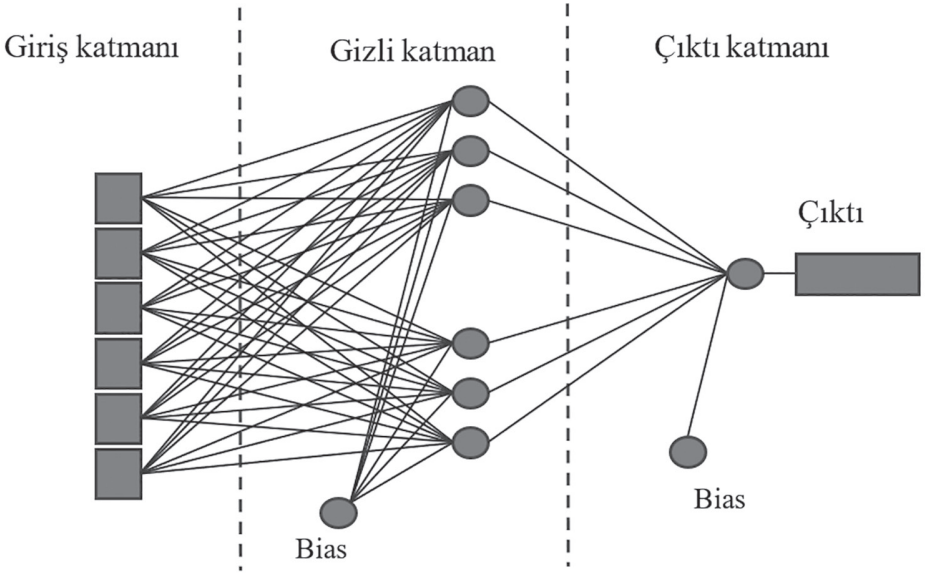
Bir karar ağacı, çok fazla dal oluşturarak gürültü veya aykırı değerler nedeniyle anormallikleri yansıtabilmektedir. Aşırı dallanmış bir model, eğitim verileri üzerinde etkileyici bir performans göstermesine rağmen, görünmeyen veriler üzerinde çok düşük bir performansa sahiptir. Bu, ağaç yapımını erken durduran ön budama veya tamamen büyümüş ağaçtan dalları kaldıran budama sonrası ile önlenmektedir (23).



Şekil 4. Bir karar ağacı yapısı

Yapay Sinir Ağları

Yapay sinir ağı (ANN), psikologlar ve nörobiyologlar tarafından nöronların hesaplamalı analoglarını geliştirmek ve test etmek için başlatılan, her bağlantının kendisiyle ilişkili bir ağırlığa sahip olduğu bir dizi bağlantılı giriş/çıkış birimidir (Şekil 5) (27). Öğrenme aşaması sırasında ağ, girdi demetlerinin doğru sınıf etiketini tahmin edebilmek için ağırlıkları ayarlayarak öğrenmektedir.



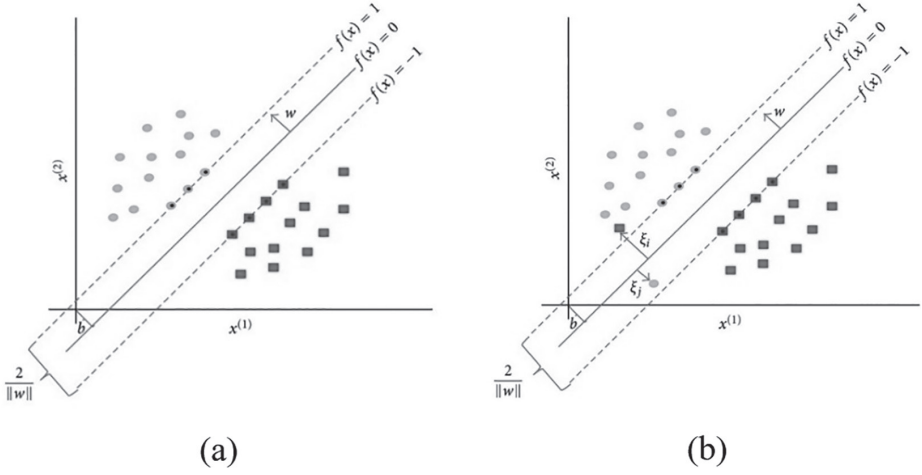
Şekil 5. İleri beslemeli bir yapay sinir ağı yapısı

ANN'de, ileri beslemeli, evrişimli, tekrarlayan vb. gibi birçok ağ mimarisi mevcuttur. Uygun mimari, modelin uygulanmasına bağlıdır ve çoğu durumda ileri beslemeli modeller oldukça doğru sonuçlar vermektedir (28). Özellikle görüntü işleme uygulamaları için evrişimli ağlar daha iyi performans göstermektedir (23). Bu modelde, model tarafından haritalanacak fonksiyonun karmaşıklığına bağlı olarak birden fazla gizli katman olabilir. Daha fazla gizli katmana sahip olmak, derin sinir ağları gibi karmaşık ilişkilerin modellenmesini sağlayacaktır. Ancak, birçok gizli katman olduğunda, ağırlıkları eğitmek ve ayarlamak çok zaman alır. Diğer dezavantajı, öğrenilen ağırlıkların ardındaki bilinmeyen sembolik anlam nedeniyle karar ağaçları gibi diğer modellere kıyasla modelin yorumlanabilirliğinin zayıf olmasıdır. Ancak ANN, gerçek dünya uygulamalarının çoğunda etkileyici bir performans sergilemektedir. Gürültülü verilere karşı yüksek toleranslıdır ve eğitilmemiş kalıpları sınıflandırabilir. Genellikle, ANN'ler yaygın olarak derin öğrenme (DL) veya derin sinir ağları (DNN) olarak da adlandırılmaktadır (29).

Destek Vektör Makineleri

Destek vektör makineleri (SVM), son yıllarda en başarılı makine öğrenme tekniklerinden biri olmuştur. Petrol ve madencilik dahil olmak üzere mühendislikle ilgili birçok uygulamaya başarıyla uyarlanmıştır. SVM'lerin eğitim için sınırlı sayıda veriye sahip olmanın ortaya çıkardığı sorunları çözmede çok iyi bir yaklaşım olmasına rağmen, büyük bir veri tabanına uygulandığında zaman alıcı bir yaklaşım olabilmektedir (30). SVM, günümüzde mevcut olan en yaygın kullanılan ML tabanlı örüntü sınıflandırma tekniğidir. İstatistiksel öğrenme teorisine dayalıdır ve Vapnik tarafından 1995 yılında geliştirilmiştir (31). Şekil 6'da SVM grafiksel olarak gösterilmiştir (32).

Bu tekniğin temel amacı, farklı tipte çekirdek fonksiyonlarını kullanarak doğrusal olmayan ayrılabilir örnekleri başka bir yüksek boyutlu uzaya yansıtmaktır. Son yıllarda, özellikle SVM'nin artan popüleritesi nedeniyle çekirdek yöntemleri büyük ilgi görmüştür. SVM'deki çekirdek işlevleri doğrudan doğrusal olmayana köprü oluşturmada önemli bir rol oynar. En küçük kare, SVM'de sınıflandırma görevi için uygulanabilecek önemli bir SVM tekniğidir. Ekstrem öğrenme makinesi ve bulanık SVM ve genetik algoritma ayarlı uzman modeli de sınıflandırma amacıyla uygulanabilmektedir (33).



Şekil 6. Destek vektör makinesi (SVM) doğrusal sınıflandırıcısının karar sınırının 2B uzay çizimi. (a) Hiçbir eğitim hatasına izin verilmeyen lineer olarak ayrılabilir örnekler üzerindeki kesin marj. (b) verileri doğrusal olmayan bir şekilde ayrılabilir hale getirmek için iki eğitim hatasının sunulduğu yumuşak marj. Noktalı örneklere destek vektörleri denir (iki sınıfın ayrıldığı marjı belirlerler) (32).

TARIMSAL UYGULAMALAR

AI'nın öğrenmeye odaklanan bir dalı olan ML, çeşitli özelliklere dayalı olarak daha iyi verim tahmini sağlayabilen pratik bir yaklaşımdır. ML, kalıpları ve korelasyonları belirleyebilmekte ve veri kümelerinden bilgi keşfedebilmektedir (34). ML yaklaşımlarının tarımsal alanda verim tahmini, hastalık tespiti, yabancı ot tespiti, mahsul tanıma, mahsul kalitesi, su yönetimi ve hayvan refahı gibi alanlarda kullanımı ile verimlilik ve dolayısıyla finansal gelirin artması mümkün olabilmektedir. Aynı zamanda bu hususlar hassas tarımın temel hedeflerini oluşturmaktadır (35).

Tür Seçimi

Tür seçimi, su ve besin kullanımının etkinliğini, iklim değişikliğine uyumu, hastalık direncini ve besin içeriğini veya daha iyi bir aromayı belirleyen belirli genleri arama sürecidir. ML, özellikle derin öğrenme algoritmaları, çeşitli iklimlerde mahsul performansını ve geliştirilen yeni özellikleri analiz etmek için onlarca yıllık alan verilerini alarak bu verilere dayalı olarak hangi genlerin bir bitkiye faydalı bir özelliğe katkıda bulunacağını tahmin edecek bir olasılık modeli oluşturabilmektedir (36, 37).

Bitki Tanıma ve Sınıflandırma

Bitki sınıflandırması için geleneksel yaklaşım, yaprakların rengini ve şeklini karşılaştırmak olsa da ML, yaprak özellikleri hakkında daha fazla bilgi taşıyan bitki morfolojik özelliklerini analiz ederek daha doğru ve daha hızlı sonuçlar sağlayabilmektedir. Ancak şu anda, bitki tanıma hala bitki taksonomistlerinin uzmanlığıdır. ML, bilgi işlem teknolojilerinin ilerlemesi sayesinde uzman olmayanlarında bitki sınıflandırmada bir alternatifi olacaktır. Günümüzde ML teknolojileri ile geliştirilmiş matematiksel modellerin bir yazılım programa eklenmesi ile yaprakların morfolojik özellikleri çıkarılabilmektedir. Bu, insan hatasından kaynaklanan yanlış pozitif sonuçları azaltabilecektir (38). Bu konuda yapılan çalışmalar geometrik olarak yaprak tanımlamanın (39) yanında, mesafe matrisi (40), renk, doku (41) ve damarlanma (42, 43) yapıları üzerine yoğunlaşmıştır. Örneğin Kumar ve ark. (44), Leafsnap adlı otomatik bir bitki türü tanımlama sistemi önermiştir. Bu sistem ile yaprak sınırlarındaki eğriliğin fonksiyonlarını hesaplamak için integral ölçümü kullanmış ve yaprakların eğriliğe dayalı şekil özelliklerine dayalı olarak bitkileri tanımlamıştır. Lee ve ark. (45) ise İngiltere’de yaptıkları çalışmada topladıkları 44 farklı bitki türü özelliklerini öğrenmek için derin öğrenmenin bir alt dalı olan ve genellikle görsel bilginin analiz edilmesinde kullanılan evrişimli sinir ağlarını (CNN) incelemişlerdir. CNN modelinden seçilen özellikler hakkında sezgi kazanmak için (“kara kutu” çözümünün aksine), evrişimsiz ağlara (DN) dayalı bir görselleştirme tekniği kullanmışlar ve CNN modelinin, manuel olarak girilen özniteliklere dayanan çözümlere kıyasla tutarlılık ve üstünlük gösterdiğini bulmuşlardır. Bir diğer çalışmada Arribas ve ark. (46), seçici herbisit uygulamalarında kullanılacak bir ANN modeli ile ayçiçeği bitkileri için otomatik yaprak görüntü sınıflandırma sistemi önermişlerdir. Deneysel sonuçlara göre önerdikleri sistem %85’lik bir ortalama doğruluk düzeyine ulaşmıştır. Belhumeur ve ark. (47) ise botanikçiler tarafından kullanılan ve bitki türlerinin tanımlanmasına yardımcı olan bir bilgisayarlı görüş sistemi geliştirmişlerdir.

Hesaplamalı morfometrik yöntemler, bir yaprağı geometrik olarak nicel olarak ölçebilir ve farklılıkları etkili, tekrarlanabilir, doğru ve istatistiksel olarak güçlü bir şekilde görselleştirebilmektedir. 2007 yılında bir grup araştırmacı, algoritmalarını ve veri setlerini diğer araştırmacılarla paylaşmak amacıyla Flavia veri seti (<http://flavia.sourceforge.net/>) olarak adlandırılan yaprak deseni veri seti çalışmalarını yayınlamışlardır. İlk çalışmalarında, 32 bitki türünü beş temel değişkenden 12 karaktere göre sınıflandırmışlardır. Sonraki yıllarda, bitki yaprak

tanıma sistemi için bir model geliştirmek için bu veri setini kullanan birçok çalışma yapılmıştır (48).

Verim Tahmini

Hassas tarımdaki en önemli ve popüler konulardan birisi ürün arzının taleple eşleşmesini sağlamak için kritik öneme sahip olan verim haritalaması ve tahminidir. Son teknolojik yaklaşımlar, tarihsel verilere dayanan basit tahminin çok ötesine geçmiştir. Özellikle hareket halindeyken veri sağlayabilen bilgisayarlı görme teknolojilerinin kullanılması ile verimden en iyi şekilde yararlanması mümkün olmakta ve mahsullerin, havanın ve ekonomik koşulların kapsamlı ve çok boyutlu analizleri yapılabilmektedir. İnternet, sensörler ve GPS teknolojisinin kullanılması ile günümüz tarımında büyük miktarda veri toplanabilmektedir. Bu verilerin bilgi teknolojileri aracılığıyla kullanılması, verimlilikte önemli gelişmeler sağlamaktadır. Ancak buradaki zorluk, toplanan ham verileri faydalı bilgilere dönüştürülmesidir (49). ML, bu ham verilerin işlenmesinde, hangi mahsulün yetiştirileceğine ve mahsullerin büyüme mevsimi boyunca ne yapılacağına dair destekleyici kararlar da dahil olmak üzere mahsul verimi tahmini için önemli bir karar destek aracı olabilir (34). Ancak bölgesel büyüme koşulları her zaman homojen değildir. Bu nedenle genel simülasyon modelleri yerine daha dar ölçekli toplanan verilerin ML algoritmaları kullanılarak modellenmesi daha gerçekçi ve doğru tahmin yapılmasını sağlayabilmektedir (27, 50). Verim tahmin modellerinin geliştirilmesinde genel olarak en çok kullanılan çevresel özellikler sıcaklık, yağış ve toprak tipidir. Ayrıca bu tür modellerde en çok uygulanan algoritmalar ise ANN ve en yaygın olarak kullanılan derin öğrenme algoritmaları ise evrişimli sinir ağları, uzun-kısa süreli bellek ve derin sinir ağıdır (34). Bu alanda birçok verim tahmini çalışması yürütülmüştür. Bunlardan birisinde Rahman ve ark. (51) homojen bir topografyaya sahip olmayan Himalaya kıyısında yer alan Bangladeş’de, ML modelleri kullanarak mahsul verimini tahmin etmek için yaptıkları çalışmada, geçmiş çevresel desenler ve mahsul üretim hızı arasındaki korelasyon konusunda modelleri eğiterek bu modelleri daha sonra bilinmeyen iklim değişkenleri üzerindeki etkinliklerini ölçmek için kullanmışlardır. Bir başka çalışmada Baral ve ark. (52), 10 yıllık geçmiş çeltik verimi, günlük sıcaklık (ortalama ve maksimum) ve yağış veri setlerine dayalı olarak farklı iklim bölgelerindeki 3 farklı ilçede çeltik verimi ANN teknolojisi ile tahmin etmişlerdir. Črtomir ve ark. (53) ise, elmada verimi tahmin etmek için görüntü analizine ve sinir ağına dayalı bir hibrit model geliştirmişlerdir. Bir diğer çalışmada Romero ve ark. (54), farklı makine öğrenme algoritmaları

aracılığıyla durum buğdayı verimini tahmin etmek yaptıkları çalışmada elde ettikleri modelden çıkarılan bilginin agronomik uygunluğunun oldukça sağlam olduğunu rapor etmişlerdir. Ananthara ve ark. (55) ise yaptıkları çalışmada, mahsul verimini tahmin etmek ve hassas tarımda karar vermeyi geliştirmek için dinamik olarak güncellenen geçmiş mahsul veri seti üzerinde uyarlanabilir bir küme yaklaşımı ile çalışan bir mahsul verimi tahmin modeli önermişlerdir. Bir başka çalışmada Shekoofa ve ark. (56), mısır tane verimini artırmak ve en uygun faktörleri seçmek için tarama, kümeleme ve karar ağacı modelleriyle çok sayıda fizyolojik ve tarımsal özelliği analiz etmişlerdir. Gonzalez-Sanchez ve ark. (57) ise, on farklı ürün veri setinde ürün verimi tahmini için makine öğrenmesi ve lineer regresyon tekniklerinin tahmin doğruluğunu karşılaştırmışlardır. M5-Prime regresyon tekniğinin en düşük hata ile en iyi mahsul verimi modelini elde ettiğinden, tarımsal planlamada büyük alanlarda mahsul verimi tahmini için çok uygun bir araç olduğunu bildirmişlerdir. Pantazi ve ark. (58) tarafından yürütülen bir başka çalışmada ise, buğday verimi davranışını karakterize etmek için ML algoritması kullanan bilgi tabanlı bir yaklaşım sunmuşlardır. Çakır ve ark. (59) ise, sıcaklık ve yağış kayıtları gibi meteorolojik verileri kullanarak buğday verimini etkin bir şekilde tahmin edebilecek çok parametrelili bir doğrusal regresyon modeli geliştirmiş ve yerleşik yapay sinir ağı için kullanılan aynı veri seti ile test etmişlerdir. Bir diğer çalışmada ise Matsumura ve ark. (60) mısır verimi tahmini için çoklu doğrusal regresyon (MLR) ve doğrusal olmayan ANN modelleri karşılaştırmışlardır. Hem çapraz doğrulama hem de geriye dönük doğrulama altında hesaplanan tahmin beceri puanları, ANN modellerinin MLR'den önemli ölçüde daha iyi performans göstermiştir.

Mahsul Kalitesi

Mahsul kalite özelliklerinin doğru tespiti ve sınıflandırılması, ürün fiyatını artırabilir ve israfı azaltabilir. İnsan tarafından yapılan sınıflandırma ile karşılaştırıldığında, makineler, ürün kalitesinde rol oynayan nitelikleri ortaya çıkarmak ve bunları tespit etmek için anlamsız gibi görünen verilerden ve ara bağlantılardan yararlanabilmektedir (2). Bu konuda yapılan çalışmalardan birisinde Li ve ark. (61) optimum hasat zamanı ve verim tahminine karar vermek için meyvelerin olgunluğunu belirleme üzerine bir inceleme çalışması yapmışlardır. Zhang ve ark. (62) ise, iletim modunu kullanarak kısa dalga yakın kızılötesi hiperspektral görüntüleme sistemi ile pamuk tiftiği içinde gizlenen yaygın yabancı madde türlerinin tespiti ve sınıflandırılması üzerine çalışma yapmışlar ve pamuk tiftiği içindeki botanik (tohum kabuğu, tohum eti, gövde ve yaprak) ve

botanik olmayan (kâğıt ve plastik paket) yabancı madde türlerini tespit etmenin mümkün olduğunu bildirmişlerdir. Bir başka çalışmada da paketleme aşamasında iki farklı armut türünü tahribatsız bir şekilde ayırt etmek ve paketleme standartlarını karşılamak için SVM ile birleştirilen ardışık projeksiyon algoritması ile oluşturulan bir modelin kullanıldığı hiperspektral görüntüleme yönteminin başarılı bir şekilde kullanılabileceği rapor edilmiştir (63). Maione ve ark. (64) ise pirinç numunelerinin kimyasal bileşenlerine dayalı olarak coğrafi kökenlerini tahmin edebilen sınıflandırma modeli geliştirmişlerdir.

Hastalık Tespiti

Hem açık hava hem de sera koşullarında, haşere ve hastalık kontrolünde en yaygın olarak kullanılan uygulama, mahsul alanı üzerine pestisitlerin eşit şekilde püskürtülmesidir. Etkili olması için, bu yaklaşımın yüksek finansal ve önemli çevresel maliyetle sonuçlanan önemli miktarlarda pestisit gerektirmektedir. ML, zaman, yer ve etkilenen bitkiler açısından tarım kimyasalları girdisinin hedeflendiği genel hassas tarım yönetiminin bir parçası olarak da kullanılmaktadır. Ancak bitki hastalıklarının tedavisi için aşırı pestisit kullanımı, maliyetleri artırmakta ve tarım ürünlerinde toksik kalıntı tehlikesini artırmaktadır. Pestisitler, tarla bitkilerinin üretim maliyetlerinde en yüksek bileşenler arasında yer aldığından ve yer altı sularının kirlenmesinde en büyük katkıya sahip olduğundan dolayı kullanımını en aza indirecek çözümlerin üretilmesi gerekmektedir (65).

Bu konuda yapılan çalışmalardan birisinde Mayuri ve ark. (66), tarım sektöründe görüntü işleme ve ML alanında ve özellikle hastalıkların tespitinde karşılaşılan zorlukları ve metodolojileri ele almışlardır. Bir diğer çalışmada da Rangarajan ve ark. (67), PlantVillage veri setinden elde edilen domates yapraklarının (6 hastalık ve sağlıklı bir sınıf) görüntüleri, AlexNet ve VGG16 net olmak üzere iki derin öğrenme tabanlı mimariye girdi olarak vermişler ve sınıflandırma doğruluğu ve yürütme süresinde görüntü sayısının rolü ile ağırlık ve yanlılık öğrenme hızı gibi hiper parametrelerin önemini analiz etmişlerdir. Pantazi ve ark. (68) ise, alan spektroskopisi ve hiyerarşik kendi kendini organize eden haritalar kullanarak sistemik olarak enfekte olmuş *silybum marianum* bitkilerinin tanımlanması için denetimli Kohonen ağı, sayaç yayımlı yapay sinir ağı ve XY-Füzyon ağı olmak üzere üç denetimli hiyerarşik model kullanmışlardır. Elde ettikleri sonuçlar, hiyerarşik kendi kendini organize eden haritaların yardımıyla vejetatif büyüme sırasında sistemik olarak enfekte olmuş bitkilerinin yüksek doğrulukta tanımlanma potansiyelini olduğunu göstermiştir. Bir diğer

çalışmada Sujatha ve ark. (69), narenciyede hastalık tespiti amacıyla bazı makine öğrenmesi algoritmalarının performansını karşılaştırmışlar ve derin öğrenme yöntemlerinin, makine öğrenmesi yöntemlerinden daha iyi performans gösterdiğini ve deneme yoluyla elde ettikleri hastalık sınıflandırma doğruluğunun oldukça etkileyici olduğunu bildirmişlerdir. Ramesh ve ark. (70) ise, oluşturdukları veri seti ile sağlıklı ve hastalıklı yaprak arasında ayırım yapmak için çoklu karar ağacı (Random Forest) yönteminden yararlanmışlar ve bu tür büyük veri setlerini eğitmek için ML'nin, bitkilerde bulunan hastalığı geniş ölçekte tespit etmek için önemli bir araç olduğunu bildirmişlerdir. Zhang ve ark. (71) ise, tarla koşullarında salatalık yaprağından hastalıklarının tanınmasını yürütmek için küçük örneklem boyutuna ve derin evrişimli sinir ağına dayanan bir yaklaşım önermişlerdir. Bir başka çalışmada ise Anagnostis ve ark. (72), ceviz ağaçlarındaki antraknozlu yaprakları tanımlayabilen doğru ve hızlı bir nesne algılama sistemi çalışma yürütmüşlerdir. Çalışmalarında meyve bahçesi ilk olarak uzmanlar tarafından denetlenerek enfekte ağaçlar belirmiştir. Daha sonra meyve bahçesinin 379 ağacından 100'ü nesne dedektörünü eğitmek için rastgele seçilmiştir. Kalan 279 ağaç ise uzmanlar tarafından sistemde öngörülen sınıflarla karşılaştırılarak sınıflandırılmış ve dedektörün etkinliğini belirlemek için kullanılmıştır. Eğitilen modelin, doğrulama veri kümesinin %87'sini doğru bir şekilde sınıflandırdığını ve elde edilen sonuçların, ticari bahçelerde doğrudan uygulama, gerçek saha koşullarında ağaç seviyesinde enfekteli yaprakları tespit etme ve ağaçları gerçek zamanlı olarak enfekte veya sağlıklı olarak sınıflandırma konusunda büyük potansiyel gösterdiğini bildirmişlerdir. Ebrahimi ve ark. (73) ise, çilek bitkilerinde bulunabilecek parazitleri gerçek zamanlı olarak tespit etmek için SVM sınıflandırma ve görüntü işleme tekniğini kullanmışlardır. Chung ve ark. (74) tarafından yürütülen çalışmada da, tohum kaynaklı bir çeltik hastalığı olan Bakanae'yi 3 haftalıkken tahribatsız bir şekilde ayırt etmek için SVM sınıflandırıcıları geliştirilmiştir. Geliştirilen yaklaşım, enfekte olmuş ve sağlıklı fideleri %87.9 doğruluk ve %91.8 pozitif tahmin değeri ile ayırt etmiştir. Bir diğer çalışmada Pantazi ve ark. (75), bitkinin ihtiyaçlarına göre fungusit ve gübrelerin daha etkin kullanımı amacıyla, hiyerarşik kendi kendini organize eden sınıflandırıcı ve hiperspektral yansıma görüntüleme verilerine dayalı olarak nitrojen stresli ve sarı pas bulaşmış ve sağlıklı olan kışkık buğday bitkilerinin tespiti için yeni bir sistem geliştirmişlerdir. Moshou ve ark. (76) ise, sağlıklı ve su stresindeki buğday bitkileri arasında optik olarak ayırım yapmak amacıyla en küçük kareler destek vektörleri makinesinin sensör füzyonu ile kombinasyonuna dayalı olarak stres tipi algılama algoritmaları kullanarak biyotik ve abiyotik

stresleri tespit edebilen ve tanımlayabilen bir optik çoklu sensör sistemi geliştirilmişler ve sınıflandırma performansında %99 başarı elde etmişlerdir. Ferentinos (77) tarafından yürütülen araştırmada ise sağlıklı ve hastalıklı bitkilerin basit yaprak görüntülerini kullanarak bitki hastalık tespiti ve teşhisini derin öğrenme metodolojileri yoluyla gerçekleştirmek için evrimsel sinir ağı modelleri geliştirilmiştir. Modellerin eğitimi, sağlıklı bitkiler de dahil olmak üzere 58 farklı (bitki, hastalık) kombinasyon sınıfında 25 farklı bitki içeren 87,848 görüntüden oluşan açık bir veri tabanının kullanılmasıyla gerçekleştirilmiştir. Bulgularında yüksek başarı sağladıklarını ve modelin erken uyarı aracı olarak bitki hastalığı tanımlama sistemine entegre edilebileceğini bildirmişlerdir.

Yabancı Ot Tespiti

Hastalıkların yanı sıra yabancı otlar da bitkisel üretim için en önemli tehdittir. Yabancı otlarla mücadelede en büyük sorun, bunların tespit edilmesinin ve ekinlerden ayırt edilmesinin zor olmasıdır. Bitki özellikleri ve koşullarının incelenmesinde ve izlenmesinde hiperspektral görüntüleme sistemlerinin kullanılması son zamanlarda popüler olmuştur. Bu popülerite, bu tür sistemlerin hem finansal hem de çevresel avantajlarından kaynaklanmaktadır. Bilgisayarlı görü ve ML algoritmaları, yabancı otların tespitini ve ayrımını düşük maliyetle ve hiçbir çevresel sorun ve yan etki olmaksızın iyileştirebilmektedir. Gelecekte, bu teknolojiler yabancı otları yok edecek robotları çalıştırarak herbisit ihtiyacını en aza indirebilecektir. Otomatik ot-bitki ayrımı üzerine yürütülen araştırmaların çoğu, görüntü tanıma tekniklerinin kullanımına dayanmaktadır. Bu konuda yapılan çalışmalardan bazıları bu bölümde verilmiştir. Pantazi ve ark. (78) tarafından yürütülen çalışmada, hiyerarşik, kendi kendini organize eden bir harita kullanılarak yabancı ot tespiti ve haritalanması için sabit kanatlı bir insansız hava aracı sistemi üzerine monte edilmiş multispektral bir kamera (yeşil-kırmızı-NIR) kullanmışlardır. Denetimli Kohonen ağı, karşı yayımlı yapay sinir ağı ve XY-Fusion ağı ile bir alandaki farklı bitki örtüsü arasından, yabancı otlar başarılı bir şekilde tanımlanabilmiştir. Bir başka çalışmada Binch ve ark. (79), yabancı otları tespit etmek için kullanılan yapay görme yöntemlerini karşılaştırmışlardır. Bulgularında en doğru yöntemin, bir SVM ile birlikte doğrusal ikili desenleri kullanmak olduğunu rapor etmişlerdir. Ahmad ve ark. (80) ise, yabancı otları içeren görüntülerin artırılmış görsel özelliklerinden yararlanarak, gerçek zamanlı seçici herbisit püskürtücü sistemleri için etkili bir yabancı ot sınıflandırma çerçevesi sunmuşlardır. Önerdikleri bu yöntemde genişletilmiş veri seti ile %94.72 doğruluk elde etmişlerdir. Bir diğer çalışmada ise Jurado-Expósito ve

ark. (81), yedi geniş yapraklı yabancı ot türü, ayçiçeği ve buğday anız arasında ayırım yapmak için yakın kızılötesi yansıma spektroskopisi kullanma potansiyeli değerlendirmişlerdir. Bulgularında, yakın kızıl ötesi dalga boyuna karşılık gelen 750 ile 950 nm arasındaki spektrumun, toprak işlenmiş ayçiçeğinde, buğday anız, ayçiçeği ve en sorunlu “kontrol edilmesi zor” yabancı otlar arasında ayırım yapabildiğini rapor etmiştir. Søgaard (82) ise, aktif şekil modellerine dayalı görüntü işleme yoluyla yabancı ot türlerinin sınıflandırılması için yaptıkları çalışmada, en fazla iki gerçek yaprağı olan ve diğer yapraklarla örtüşmeyen genç yabancı ot fidelerini belirlemeyi amaçlamışlardır. Bu amaçla Danimarka tarım alanlarındaki en önemli ot türlerinin 19’unun görüntü örneklerinden bir veri tabanı oluşturmuşlar ve bu görüntüleri, aktif bir şekil modelinin oluşturulması için eğitim verisi olarak kullanmışlardır. Geliştirdikleri algoritma, yabancı ot türüne bağlı olarak %65 ila %90’ın arasında başarı göstermiştir.

Hayvansal Üretim

Hayvancılık üretim sistemlerinin hayvan başına verimlilik bağlamında yoğunlaştığı yaygın olarak kabul edilmektedir. Bu yoğunlaşma, hayvan refahı ve insan sağlığına dayalı olarak tüketicinin gıda güvenliği ve sürdürülebilirlik algısını etkileyebilecek sosyal kaygıları içermektedir (35). Özellikle hem hayvanların refahının hem de genel üretimin izlenmesi, üretim sistemlerini iyileştirmek için kilit bir unsurdur (83). Tüm bu konular, hayvan sağlığını gerçek zamanlı olarak izlemek ve uyarı mesajlarını tanımak için mühendislik tekniklerini uygulamayı ve aynı zamanda ilk aşamalarda üretimi iyileştirmeyi amaçlayan hassas hayvancılık çerçevesinde yer almaktadır. Hassas hayvancılığın rolü, hayvan sahiplerinin karar verme süreçlerini destekleyerek ve rollerini değiştirerek giderek daha fazla önem kazanmaktadır. Politika yapıcılarının, gerektirdiği şekilde hayvanların yaşam koşullarını ve yaşam kalitelerini izlemenin yanı sıra ürünlerin de izlenebilirliğini de kolaylaştırabilmektedir (84). Hassas hayvancılık, kameralar, ivmeölçerler, jiroskoplar, radyo frekansı tanımlama sistemleri, pedometreler, optik ve sıcaklık sensörleri gibi araçlara dayanmaktadır (85). IoT sensörleri, sıcaklık, ses, nem vb. algılamanın bir aracı olarak değişken fiziksel niceliklerden yararlanır. Örneğin, bir değişkenin normal sınırların dışına çıkması durumunda IoT sensörleri, her bir hayvanla ilgili değerli bilgiler vererek uyarabilir. Sonuç olarak, her bir hayvanı tekrar tekrar ve zahmetli bir şekilde kontrol etmenin maliyeti azaltılabilir (86). ML metodolojileri bu teknolojiler ile üretilen büyük miktardaki veriden yararlanmak, sığır, tavuk ve yumurta üretimi gibi hayvancılık üretim sistemlerinin ekonomik verimliliğini optimize etmek için çiftçilik

parametrelerinin doğru tahmin edilmesinde önemli bir unsur haline gelmiştir. Bu bölümde ML uygulamalarının hayvansal üretim alanındaki bazı örnekleri incelenmiştir.

Bu alanda yapılan çalışmalardan birisinde Dutta ve ark. (87), sığırlarda östrus ve diyet değişikliklerinin tanınması gibi olayların tahmin edilmesi amacıyla yönelik olarak, manyetometreler ve üç eksenli ivmeölçerler ile sensörler tarafından toplanan veriler kullanılarak ML modellerine dayalı sığır davranışlarının sınıflandırılması için bir yöntem önermişlerdir. Pegorini ve ark. (88) ise, buzağılarda çiğneme kalıplarının otomatik olarak tanımlanması ve sınıflandırılması için bir sistem sunmuşlardır. Çalışmada, saman ve çavdar otu gibi diyet takviyelerinin çiğneme sinyallerinden optik FBG sensörleri tarafından elde edilen veriler, geviş getirme ve tembellik gibi davranış verileriyle birleştirilerek ML'ye dayalı bir sistem oluşturulmuştur. Başka bir çalışmada ise Matthews ve ark. (89), hayvanın çeşitli aktivitelerini (ayakta durma, hareket etme, besleme ve içme) izlemek için video kameraları ile hayvan davranışlarının izlenmesi için ML'ye dayalı otomatik bir izleme sistemi önermişlerdir. Alonso ve ark. (90) ise, üreticiler için çok önemli bir konu olan besi sığırlarının ağırlığını tahmin etmek için bir yöntem sunmuşlardır. Youssef ve ark. (91) tarafından yürütülen bir diğer çalışmada, çevresel parametrelerin kontrol edildiği bir ortamda tavukların aktivite seviyesini ve pozisyonunu kontrol etme olasılığı incelenmiştir. Havalandırmalı küçük bir test odasında, giriş sıcaklığındaki ve havalandırma hızındaki değişimlere bağlı olarak piliçlerin dinamik aktivite indeksini tahmin etmek için gerçek zamanlı modelleme kullanmışlardır. Bu modeller ile tavukların mikro-çevre sıcaklığındaki değişikliklere verdiği dinamik tepkileri tanımlamışlardır. Elde ettikleri modellerin, tavukların aktivitesinin model tabanlı bir tahmine dayalı kontrol sisteminin matematiksel temelini oluşturabileceğini rapor etmişlerdir. Bir diğer çalışmada Craninx ve ark. (92), bir makine öğrenme tekniği olan ANN kullanarak süt yağ asitlerinden rumen fermantasyon modelini tahmin etmek ve ortaya çıkan modelin tahmin doğruluğunu karşılaştırmayı amaçlamışlardır. Çalışmada farklı ANN mimarileri ve eğitim algoritmaları değerlendirilmiştir. Sonuçlar, doğrusal bir regresyon modeliyle karşılaştırıldığında ANN'nin, önemli ölçüde daha iyi performans göstermediğini ancak süt yağ asitlerinin midedeki tek tek uçucu yağ asitlerinin molar oranlarını tahmin etmede büyük potansiyele sahip olduğunu göstermiştir. Tavuk üretimi ile ilgili bir başka çalışmada ise Morales ve ark. (93), spesifik olarak yumurtaların ticari üretimindeki sorunların erken tespiti ve uyarılması için SVM modeline dayalı bir yöntem önermişlerdir.

Su Yönetimi

Bitki büyümesi büyük ölçüde su mevcudiyetine bağlı olduğundan, tarım sektörü küresel ölçekte mevcut tatlı suyun ana tüketicisi konumundadır. Birçok yeraltı su kaynağının da hızla tükendiği dikkate alındığında, sürdürülebilir bir bitkisel üretim hedefine ulaşmak açısından suyun daha iyi korunması amacıyla daha etkili su yönetimine ihtiyaç vardır (94, 95). Tarımsal üretimde su yönetimi, önemli çabalar gerektirir ve hidrolojik, klimatolojik ve tarımsal dengede önemli bir rol oynar. Bu alanda yapılan çalışmalar çoğunlukla günlük, haftalık veya aylık evapotranspirasyon (ET) tahmini için geliştirilmiş tahmin modellerinden oluşmaktadır. ET'nin doğru tahmini karmaşık bir süreçtir ve bitkisel üretimde su kaynağı, sulama sistemlerinin tasarımı ve işletilmesi ve bunların yönetilmesi büyük önem taşımaktadır.

Bu konuda yürütülen çalışmalardan birisinde Mehdizadeh ve ark. (96) İranda aylık ortalama referans evapotranspirasyon (ET_0) tahmini için iki farklı tür SVM olan SVM-polinom ve SVM-radyal temel fonksiyonun yanı sıra çok değişkenli uyarlamalı regresyon eğrileri (MARS) olmak üzere gen ekspresyon programlamasını da içeren deneysel denklemlerin ve esnek hesaplama yaklaşımlarının performansını araştırmışlardır. Genel olarak, MARS ve SVM-radyal'ın performansı, kullanılan ampirik denklemlerden daha iyi sonuç verdiğini bulmuşlardır. Bir başka çalışmada Feng ve ark. (97), güneybatı Çin'deki Sichuan havzasının 6 meteoroloji istasyonunda aşırı öğrenme makinesi (ELM) ve genelleştirilmiş regresyon sinir ağı (GRNN) dahil olmak üzere yalnızca sıcaklık verileriyle günlük ET_0 tahmini için iki yapay zeka modeli geliştirmişler ve önerilen ELM ve GRNN modellerini sıcaklığa dayalı Hargreaves modeli ve ET_0 'ı kıyaslama olarak dikkate alan kalibre edilmiş FAO-56 Penman-Monteith versiyonuyla karşılaştırmışlardır. Önerdikleri modellerin diğer yöntemlere göre çok daha iyi performans gösterdiğini, çiftçiler veya sulama sistemi operatörleri için sulama programlarını iyileştirmelerinde önemli bir araç olabileceğini rapor etmişlerdir. Yassin ve ark. (98) tarafından yapılan benzer bir çalışmada da kurak koşullar altında günlük ET_0 tahmin etmek için ANN ve gen ekspresyon programlaması karşılaştırılmıştır. Bulgularında ANN modelinin GEP'e göre daha iyi performans gösterdiğini bildirmişlerdir. ET'nin kesin tahmini, doğru ürün-su tahmini için çok önemlidir. Son zamanlarda ANN gibi ML teknikleri, ET sürecini modellemek için yaygın olarak kullanılmaktadır. Ancak ANN, yerel minimumlarda yakalama, yavaş öğrenme ve meta-parametrelerin ayarlanması gibi sorunlarla karşı karşıyadır. Bu nedenle aşırı öğrenme makinesi (ELM) algoritması kullanılması tavsiye edilmektedir. Patil ve ark. (99) yaptıkları ça-

lişmada ELM'nin daha iyi performans sergileyen basit ama etkili bir algoritma olduğunu bu nedenle haftalık ET_0 'ı tahmin etmek için güvenle kullanılabileceğini, ayrıca sınırlı veri senaryolarında ML modellerinin verimliliğini artırmaya yardımcı olabileceğini de rapor etmişlerdir. Bununla birlikte çiğlenme noktası sıcaklığı, özellikle hidrolojik, klimatolojik ve agronomik araştırmalarda gerekli olan önemli bir parametredir. Bu amaçla Mohammadi ve ark. (100), günlük çiğlenme noktası sıcaklığının tahmini için ELM tabanlı bir model önermişlerdir. Çalışmada ELM modelinin değeri, SVM ve ANN tekniklerine göre değerlendirilmiştir. Elde edilen bulgular, önerilen ELM modelinin SVM ve ANN modellerinden çok daha iyi tahmin kabiliyetine sahip olduğunu, böylece günlük çiğlenme noktası sıcaklığını çok uygun bir doğrulukla tahmin edebildiğini göstermiştir. Son zamanlarda yapılan bazı araştırmalarda ise, değişken oranlı sulamanın su tasarrufu sağlamak için bir potansiyele sahip olduğu yönündeki görüşleri desteklemektedir. Bu konuda yapılan bir araştırmada ise Lu ve ark. (101), tüm tarlada tek tip bir sulama rejimi uygulamak yerine, ayrı yönetim bölgelerinin belirli su gereksinimleri temelinde tarla özelliklerine göre değişen oranlarda sulama yapılabileceğini, ayrıca değişken oranlı sulama yaklaşımının etkinliği ve fizibilitesinin, hem su tasarrufu hem de verim optimizasyonunu gerçekleştirmek için topografya, toprak özellikleri ve bunların toprak suyu üzerindeki etkisi gibi tarımsal faktörlere bağlı olduğunun da dikkate alınması gerektiğini bildirmektedir.

Büyük veri ve ML teknolojileri, çevre ve su yönetimini birçok yönden etkileme potansiyeline sahiptir. Büyük veri, yüksek hacim, hız, çeşitlilik ve doğruluk ile karakterize edilen bilgi varlıklarıdır. Yüksek çözünürlüklü uzaktan algılama teknikleri, akıllı bilgi ve iletişim teknolojileri ve sosyal medyadaki hızlı gelişmeler, hava tahmini, afet yönetimi, akıllı su ve enerji yönetim sistemleri ve uzaktan algılama gibi çevre ve su yönetimi alanında büyük verinin kullanımının yaygınlaşmasına katkıda bulunmaktadır (102).

SONUÇ

ML teknolojileri ile desteklenmiş yeni yöntemler, veriye dayalı tarımsal uygulamalar için yeni fırsatlar sunmaktadır. Ancak bu fırsatların yanında yoğun veri işleme gereksiniminden dolayı halihazırda kullanılan veri toplama ve depolama gibi teknolojilerinde geliştirilmesi gerekmektedir. Yapay zekanın bir alt alanı olan ML, genel olarak verilerden otomatik olarak öğrenebilen bilgisayar algoritmalarını ifade etmektedir. ML, veri analitiğiyle, yani verilerdeki anlamlı

kalıpların keşfi ve yorumlanması ile doğru bir şekilde entegre edilirse, büyük verinin gücünden tam olarak yararlanılması mümkün olabilecektir. Yapay zekâ ve bilgi işlem altyapısındaki son gelişmeler, daha iyi tahmin performansı ve daha az insan müdahalesi ile verilerden hiyerarşik özellikleri çıkarabilen güçlü derin öğrenme algoritmalarının hızla geliştirilmesine yol açmıştır. Bu teknolojik ilerlemeler, büyük miktarda veriden bağımsız bir şekilde ve gerçek zamanlı olarak yararlı bilgiler çıkarma kabiliyetini de gerektirmektedir. Büyük veri ve ML teknikleri, veriye dayalı karar verme, bilimsel keşif ve süreç optimizasyonu için büyük potansiyele sahiptir.

KAYNAKLAR

1. Gupta, R. A survey on machine learning approaches and its techniques. in *2020 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECs)*. 2020. Bhopal, India: IEEE.
2. Liakos, K.G., P. Busato, D. Moshou, et al., Machine learning in agriculture: A review. *Sensors*, 2018. 18(8): 2674.
3. Patil, G.G. and R.K. Banyal. Techniques of deep learning for image recognition. in *2019 IEEE 5th International Conference for Convergence in Technology (I2CT)*. 2019. Pune, India: IEEE.
4. Khan, R., M. Abbas, R. Anjum, et al. Evaluating Machine Learning Techniques on Human Activity Recognition Using Accelerometer Data. in *2020 International Conference on UK-China Emerging Technologies (UCET)*. 2020. IEEE.
5. El Naqa, I. and M.J. Murphy, What Is Machine Learning?, in *Machine Learning in Radiation Oncology: Theory and Applications*, I. El Naqa, R. Li, and M.J. Murphy, Editors. 2015, Springer International Publishing: Cham. p. 3-11.doi: 10.1007/978-3-319-18305-3_1.
6. Alpaydin, E., Introduction to machine learning. 2020: MIT press.
7. Samuel, A.L., Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 2000. 44(1.2): 206-226.
8. Jalil, N.A., H.J. Hwang, and N.M. Dawi. Machines learning trends, perspectives and prospects in education sector. in *Proceedings of the 2019 3rd International Conference on Education and Multimedia Technology*. 2019.
9. Mohri, M., A. Rostamizadeh, and A. Talwalkar, Foundations of machine learning. 2018: MIT press.
10. Pearson, K., LIII. On lines and planes of closest fit to systems of points in space. *The London, Edinburgh, and Dublin philosophical magazine and journal of science*, 1901. 2(11): 559-572.
11. Wold, H., Partial least squares. *Encyclopedia of statistical sciences*, 2004. 9.
12. Fisher, R.A., The use of multiple measurements in taxonomic problems. *Annals of eugenics*, 1936. 7(2): 179-188.

13. Zhao, Y., Chapter 5 - Regression, in *R and Data Mining*, Y. Zhao, Editor. 2013, Academic Press. p. 41-50.doi: <https://doi.org/10.1016/B978-0-12-396963-7.00005-2>.
14. Cox, D.R., The regression analysis of binary sequences. *Journal of the Royal Statistical Society: Series B (Methodological)*, 1958. 20(2): 215-232.
15. Efron, M.A., Multiple regression analysis. *Mathematical methods for digital computers*, 1960: 191-203.
16. Friedman, J.H., Multivariate adaptive regression splines. *The annals of statistics*, 1991. 19(1): 1-67.
17. Cleveland, W.S., Robust locally weighted regression and smoothing scatterplots. *Journal of the American statistical association*, 1979. 74(368): 829-836.
18. Quinlan, J.R. Learning with continuous classes. in *5th Australian joint conference on artificial intelligence*. 1992. Hobart, Tasmania: World Scientific.
19. Dempster, A.P., N.M. Laird, and D.B. Rubin, Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society: Series B (Methodological)*, 1977. 39(1): 1-22.
20. Johnson, S.C., Hierarchical clustering schemes. *Psychometrika*, 1967. 32(3): 241-254.
21. Winters-Miner, L.A., P. Bolding, T. Hill, et al., Chapter 15 - Prediction in Medicine – The Data Mining Algorithms of Predictive Analytics, in *Practical Predictive Analytics and Decisioning Systems for Medicine*, L.A. Winters-Miner, et al., Editors. 2015, Academic Press. p. 239-259.doi: <https://doi.org/10.1016/B978-0-12-411643-6.00015-6>.
22. Lloyd, S., Least squares quantization in PCM. *IEEE transactions on information theory*, 1982. 28(2): 129-137.
23. Asiri, S. Machine Learning Classifiers. 2022 (cited 2022 01.01.2022); Available from: <https://towardsdatascience.com/machine-learning-classifiers-a5cc4e1b0623>.
24. Fix, E. and J.L. Hodges, Discriminatory analysis: nonparametric discrimination: consistency properties. Report. 4. *T. USAF School of Aviation Medicine*, 1951.
25. Atkeson, C.G., A.W. Moore, and S. Schaal, Locally weighted learning. *Lazy learning*, 1997: 11-73.
26. Kohonen, T., Learning vector quantization, in *Self-organizing maps*. 1995, Springer. p. 175-189.
27. Çaylı, A., An Artificial Neural Network Model For Predicting The Greenhouse Heat Requirement in Adana Climate Conditions. *Fresenius Environmental Bulletin*, 2019. 28(9): 6537-6548.
28. Küçükönder, H., S. Boyacı, and A. Akyüz, A modeling study with an artificial neural network: developing estimation models for the tomato plant leaf area. *Turkish Journal of Agriculture and Forestry*, 2016. 40(2): 203-212.
29. LeCun, Y., Y. Bengio, and G. Hinton, Deep learning. *nature*, 2015. 521(7553): 436-444.
30. Pisner, D.A. and D.M. Schnyer, Chapter 6 - Support vector machine, in *Machine Learning*, A. Mechelli and S. Vieira, Editors. 2020, Academic Press. p. 101-121.doi: <https://doi.org/10.1016/B978-0-12-815739-8.00006-7>.

31. Vapnik, V., I. Guyon, and T. Hastie, Support vector machines. *Mach. Learn.*, 1995. 20(3): 273-297.
32. Mahmoudi, A., S. Takerkart, F. Regragui, et al., Multivoxel pattern analysis for FMRI data: a review. *Computational and mathematical methods in medicine*, 2012. 2012.
33. Satapathy, S.K., S. Dehuri, A.K. Jagadev, et al., Chapter 1 - Introduction, in *EEG Brain Signal Classification for Epileptic Seizure Disorder Detection*, S.K. Satapathy, et al., Editors. 2019, Academic Press. p. 1-25.doi: <https://doi.org/10.1016/B978-0-12-817426-5.00001-6>.
34. van Klompenburg, T., A. Kassahun, and C. Catal, Crop yield prediction using machine learning: A systematic literature review. *Computers and Electronics in Agriculture*, 2020. 177: 105709.doi: <https://doi.org/10.1016/j.compag.2020.105709>.
35. Benos, L., A.C. Tagarakis, G. Dolias, et al., Machine learning in agriculture: A comprehensive updated review. *Sensors*, 2021. 21(11): 3758.
36. MacKenzie, W.H. and C.R. Mahony, An ecological approach to climate change-informed tree species selection for reforestation. *Forest Ecology and Management*, 2021. 481: 118705.doi: <https://doi.org/10.1016/j.foreco.2020.118705>.
37. Liu, J., B. Dong, Y. Cui, et al., An exploration of plant characteristics for plant species selection in wetlands. *Ecological Engineering*, 2020. 143: 105674.doi: <https://doi.org/10.1016/j.ecoleng.2019.105674>.
38. Sabu, A. and K. Sreekumar. Literature review of image features and classifiers used in leaf based plant recognition through image analysis approach. in *2017 International Conference on Inventive Communication and Computational Technologies (ICICCT)*. 2017. IEEE.
39. Kalyoncu, C. and Ö. Toygar, Geometric leaf classification. *Computer Vision and Image Understanding*, 2015. 133: 102-109.
40. Hall, D., C. McCool, F. Dayoub, et al. Evaluation of features for leaf classification in challenging conditions. in *2015 IEEE Winter Conference on Applications of Computer Vision*. 2015. IEEE.
41. Kadir, A., L.E. Nugroho, A. Susanto, et al., Leaf classification using shape, color, and texture features. *arXiv preprint arXiv:1401.4447*, 2013.
42. Charters, J., Z. Wang, Z. Chi, et al. EAGLE: A novel descriptor for identifying plant species using leaf lamina vascular features. 2014. IEEE.
43. Gu, X., J.-X. Du, and X.-F. Wang. Leaf Recognition Based on the Combination of Wavelet Transform and Gaussian Interpolation. 2005. Berlin, Heidelberg: Springer Berlin Heidelberg.
44. Kumar, N., P.N. Belhumeur, A. Biswas, et al. Leafsnap: A computer vision system for automatic plant species identification. in *European conference on computer vision*. 2012. Springer.
45. Lee, S.H., C.S. Chan, P. Wilkin, et al. Deep-plant: Plant identification with convolutional neural networks. in *2015 IEEE international conference on image processing (ICIP)*. 2015. IEEE.
46. Arribas, J.I., G.V. Sánchez-Ferrero, G. Ruiz-Ruiz, et al., Leaf classification in sunflower crops by computer vision and neural networks. *Computers and Electronics in Agriculture*, 2011. 78(1): 9-18.doi: <https://doi.org/10.1016/j.compag.2011.05.007>.

47. Belhumeur, P.N., D. Chen, S. Feiner, et al. Searching the World's Herbaria: A System for Visual Identification of Plant Species. in *Computer Vision – ECCV 2008*. 2008. Berlin, Heidelberg: Springer Berlin Heidelberg.
48. Azlah, M.A., L.S. Chua, F.R. Rahmad, et al., Review on Techniques for Plant Leaf Classification and Recognition. *Computers*, 2019. 8(4).doi: 10.3390/computers8040077.
49. Ruß, G., R. Kruse, M. Schneider, et al. Data mining with neural networks for wheat yield prediction. in *Industrial Conference on Data Mining*. 2008. New York, NY, USA: Springer.
50. Everingham, Y.L., C.W. Smyth, and N.G. Inman-Bamber, Ensemble data mining approaches to forecast regional sugarcane crop production. *Agricultural and forest meteorology*, 2009. 149(3-4): 689-696.
51. Rahman, M.M., N. Haq, and R.M. Rahman. Machine learning facilitated rice prediction in Bangladesh. in *2014 Annual Global Online Conference on Information and Computer Technology*. 2014. IEEE.
52. Baral, S., A. Kumar Tripathy, and P. Bijayasingh. Yield prediction using artificial neural networks. in *International Conference on Advances in Communication, Network, and Computing*. 2011. Springer.
53. Črtomir, R., C. Urška, T. Stanislav, et al., Application of neural networks and image visualization for early forecast of apple yield. *Erwerbs-obstbau*, 2012. 54(2): 69-76.
54. Romero, J.R., P.F. Roncallo, P.C. Akkiraju, et al., Using classification algorithms for predicting durum wheat yield in the province of Buenos Aires. *Computers and electronics in agriculture*, 2013. 96: 173-179.
55. Ananthara, M.G., T. Arunkumar, and R. Hemavathy. CRY—an improved crop yield prediction model using bee hive clustering approach for agricultural data sets. in *2013 International Conference on Pattern Recognition, Informatics and Mobile Engineering*. 2013. IEEE.
56. Shekoofa, A., Y. Emam, N. Shekoufa, et al., Determining the most important physiological and agronomic traits contributing to maize grain yield through machine learning algorithms: a new avenue in intelligent agriculture. *PloS one*, 2014. 9(5): e97288.
57. Gonzalez-Sanchez, A., J. Frausto-Solis, and W. Ojeda-Bustamante, Predictive ability of machine learning methods for massive crop yield prediction. *Spanish Journal of Agricultural Research*, 2014. 12(2): 313-328.
58. Pantazi, X.E., D. Moshou, A.M. Mouazen, et al. Application of supervised self organising models for wheat yield prediction. in *IFIP International Conference on Artificial Intelligence Applications and Innovations*. 2014. Springer.
59. Çakır, Y., M. Kırıcı, and E.O. Güneş. Yield prediction of wheat in south-east region of Turkey by using artificial neural networks. in *2014 The Third International Conference on Agro-Geoinformatics*. 2014. IEEE.
60. Matsumura, K., C.F. Gaitan, K. Sugimoto, et al., Maize yield forecasting by linear regression and artificial neural networks in Jilin, China. *The Journal of Agricultural Science*, 2015. 153(3): 399-410.

61. Li, B., J. Lecourt, and G. Bishop, Advances in non-destructive early assessment of fruit ripeness towards defining optimal time of harvest and yield prediction—a review. *Plants*, 2018. 7(1): 3.
62. Zhang, M., C. Li, and F. Yang, Classification of foreign matter embedded inside cotton lint using short wave infrared (SWIR) hyperspectral transmittance imaging. *Computers and Electronics in Agriculture*, 2017. 139: 75-90.
63. Hu, H., L. Pan, K. Sun, et al., Differentiation of deciduous-calyx and persistent-calyx pears using hyperspectral reflectance imaging and multivariate analysis. *Computers and Electronics in Agriculture*, 2017. 137: 150-156.doi: <https://doi.org/10.1016/j.compag.2017.04.002>.
64. Maione, C., B.L. Batista, A.D. Campiglia, et al., Classification of geographic origin of rice by data mining and inductively coupled plasma mass spectrometry. *Computers and Electronics in Agriculture*, 2016. 121: 101-107.doi: <https://doi.org/10.1016/j.compag.2015.11.009>.
65. Moshou, D., C. Bravo, J. West, et al., Automatic detection of 'yellow rust' in wheat using reflectance measurements and neural networks. *Computers and electronics in agriculture*, 2004. 44(3): 173-188.
66. Mayuri, K.P. and C.H. Priya, Role of image processing and machine learning techniques in disease recognition, diagnosis and yield prediction of crops: A Review. *International Journal of Advanced Research in Computer Science*, 2018. 9(2).
67. Rangarajan, A.K., R. Purushothaman, and A. Ramesh, Tomato crop disease classification using pre-trained deep learning algorithm. *Procedia Computer Science*, 2018. 133: 1040-1047.doi: <https://doi.org/10.1016/j.procs.2018.07.070>.
68. Pantazi, X.E., A.A. Tamouridou, T.K. Alexandridis, et al., Detection of *Silybum marianum* infection with *Microbotryum silybum* using VNIR field spectroscopy. *Computers and Electronics in Agriculture*, 2017. 137: 130-137.doi: <https://doi.org/10.1016/j.compag.2017.03.017>.
69. Sujatha, R., J.M. Chatterjee, N.Z. Jhanjhi, et al., Performance of deep learning vs machine learning in plant leaf disease detection. *Microprocessors and Microsystems*, 2021. 80: 103615.doi: <https://doi.org/10.1016/j.micpro.2020.103615>.
70. Ramesh, S., R. Hebbar, M. N, et al. Plant Disease Detection Using Machine Learning. in *2018 International Conference on Design Innovations for 3Cs Compute Communicate Control (ICDI3C)*. 2018.doi: 10.1109/ICDI3C.2018.00017.
71. Zhang, J., Y. Rao, C. Man, et al., Identification of cucumber leaf diseases using deep learning and small sample size for agricultural Internet of Things. *International Journal of Distributed Sensor Networks*, 2021. 17(4): 15501477211007407.
72. Anagnostis, A., A.C. Tagarakis, G. Asiminari, et al., A deep learning approach for anthracnose infected trees classification in walnut orchards. *Computers and Electronics in Agriculture*, 2021. 182: 105998.
73. Ebrahimi, M.A., M.-H. Khoshtaghaza, S. Minaei, et al., Vision-based pest detection based on SVM classification method. *Computers and Electronics in Agriculture*, 2017. 137: 52-58.
74. Chung, C.-L., K.-J. Huang, S.-Y. Chen, et al., Detecting *Bakanae* disease in rice seedlings by machine vision. *Computers and electronics in agriculture*, 2016. 121: 404-411.

75. Pantazi, X.E., D. Moshou, R. Oberti, et al., Detection of biotic and abiotic stresses in crops by using hierarchical self organizing classifiers. *Precision Agriculture*, 2017. 18(3): 383-393.
76. Moshou, D., X.-E. Pantazi, D. Kateris, et al., Water stress detection based on optical multisensor fusion with a least squares support vector machine classifier. *Biosystems Engineering*, 2014. 117: 15-22.
77. Ferentinos, K.P., Deep learning models for plant disease detection and diagnosis. *Computers and electronics in agriculture*, 2018. 145: 311-318.
78. Pantazi, X.E., A.A. Tamouridou, T.K. Alexandridis, et al., Evaluation of hierarchical self-organising maps for weed mapping using UAS multispectral imagery. *Computers and Electronics in Agriculture*, 2017. 139: 224-230.
79. Binch, A. and C.W. Fox, Controlled comparison of machine vision algorithms for Rumex and Urtica detection in grassland. *Computers and Electronics in Agriculture*, 2017. 140: 123-138.
80. Ahmad, J., K. Muhammad, I. Ahmad, et al., Visual features based boosted classification of weeds for real-time selective herbicide sprayer systems. *Computers in Industry*, 2018. 98: 23-33.doi: <https://doi.org/10.1016/j.compind.2018.02.005>.
81. Jurado-Expósito, M., F. López-Granados, S. Atenciano, et al., Discrimination of weed seedlings, wheat (*Triticum aestivum*) stubble and sunflower (*Helianthus annuus*) by near-infrared reflectance spectroscopy (NIRS). *Crop Protection*, 2003. 22(10): 1177-1180.doi: [https://doi.org/10.1016/S0261-2194\(03\)00159-5](https://doi.org/10.1016/S0261-2194(03)00159-5).
82. Søgaard, H.T., Weed Classification by Active Shape Models. *Biosystems Engineering*, 2005. 91(3): 271-281.doi: <https://doi.org/10.1016/j.biosystemseng.2005.04.011>.
83. Fournel, S., A.N. Rousseau, and B. Laberge, Rethinking environment control strategy of confined animal housing systems through precision livestock farming. *Biosystems Engineering*, 2017. 155: 96-123.doi: <https://doi.org/10.1016/j.biosystemeng.2016.12.005>.
84. Salina, A.B., L. Hassan, A.A. Saharee, et al., Assessment of knowledge, attitude, and practice on livestock traceability among cattle farmers and cattle traders in peninsular Malaysia and its impact on disease control. *Tropical animal health and production*, 2021. 53(1): 1-10.
85. Li, N., Z. Ren, D. Li, et al., Automated techniques for monitoring the behaviour and welfare of broilers and laying hens: towards the goal of precision livestock farming. *animal*, 2020. 14(3): 617-625.
86. Akhigbe, B.I., K. Munir, O. Akinade, et al., IoT technologies for livestock management: a review of present status, opportunities, and future trends. *Big Data and Cognitive Computing*, 2021. 5(1): 10.
87. Dutta, R., D. Smith, R. Rawnsley, et al., Dynamic cattle behavioural classification using supervised ensemble classifiers. *Computers and electronics in agriculture*, 2015. 111: 18-28.
88. Pegorini, V., L. Zen Karam, C.S.R. Pitta, et al., In vivo pattern classification of ingestive behavior in ruminants using FBG sensors and machine learning. *Sensors*, 2015. 15(11): 28456-28471.

89. Matthews, S.G., A.L. Miller, T. Plötz, et al., Automated tracking to measure behavioural changes in pigs for health and welfare monitoring. *Scientific reports*, 2017. 7(1): 1-12.
90. Alonso, J., A. Villa, and A. Bahamonde, Improved estimation of bovine weight trajectories using Support Vector Machine Classification. *Computers and electronics in agriculture*, 2015. 110: 36-41.
91. Youssef, A., V. Exadaktylos, and D.A.J.B.E. Berckmans, Towards real-time control of chicken activity in a ventilated chamber. 2015. 135: 31-43.
92. Craninx, M., V. Fievez, B. Vlaeminck, et al., Artificial neural network models of the rumen fermentation pattern in dairy cattle. *Computers and electronics in agriculture*, 2008. 60(2): 226-238.
93. Morales, I.R., D.R. Cebrián, E.F. Blanco, et al., Early warning in egg production curves from commercial hens: A SVM approach. 2016. 121: 169-179.
94. Neupane, J. and W. Guo, Agronomic basis and strategies for precision water management: a review. *Agronomy*, 2019. 9(2): 87.
95. Değirmenci, H. and M. Keten, Kısıntılı sulama koşullarında ikinci ürün silajlık sorgum ve mısır bitkisinin su-verim ilişkisi ve light bar tekniği kullanarak fotosentetik aktif radyasyonla kanopinin belirlenmesi. 2020.
96. Mehdizadeh, S., J. Behmanesh, and K. Khalili, Using MARS, SVM, GEP and empirical equations for estimation of monthly mean reference evapotranspiration. *Computers and electronics in agriculture*, 2017. 139: 103-114.
97. Feng, Y., Y. Peng, N. Cui, et al., Modeling reference evapotranspiration using extreme learning machine and generalized regression neural network only with temperature data. *Computers and Electronics in Agriculture*, 2017. 136: 71-78.
98. Yassin, M.A., A.A. Alazba, and M.A. Mattar, Artificial neural networks versus gene expression programming for estimating reference evapotranspiration in arid climate. *Agricultural Water Management*, 2016. 163: 110-124.doi: <https://doi.org/10.1016/j.agwat.2015.09.009>.
99. Patil, A.P. and P.C. Deka, An extreme learning machine approach for modeling evapotranspiration using extrinsic inputs. *Computers and Electronics in Agriculture*, 2016. 121: 385-392.doi: <https://doi.org/10.1016/j.compag.2016.01.016>.
100. Mohammadi, K., S. Shamshirband, S. Motamedi, et al., Extreme learning machine based prediction of daily dew point temperature. *Computers and Electronics in Agriculture*, 2015. 117: 214-225.doi: <https://doi.org/10.1016/j.compag.2015.08.008>.
101. Lu, Y.-C., E.J. Sadler, and C.R. Camp, Economic feasibility study of variable irrigation of corn production in southeast coastal plain. *Journal of Sustainable Agriculture*, 2005. 26(3): 69-81.
102. Sun, A.Y. and B.R. Scanlon, How can Big Data and machine learning benefit environment and water management: a survey of methods, applications, and future directions. *Environmental Research Letters*, 2019. 14(7): 073001.doi: [10.1088/1748-9326/ab1b7d](https://doi.org/10.1088/1748-9326/ab1b7d).