

(Geliş Tarihi / Received Date: 13.04.2022, Kabul Tarihi/ Accepted Date: 18.05.2022)

**(Derleme Makalesi)**

## **Şeker Pancarı Üretiminde Kullanılan Yapay Zekâ Teknikleri**

**Yasin ÇİÇEK<sup>\*1</sup>, Ahmet ULUDAĞ<sup>2</sup>, Eyyüp GÜLBANDILAR<sup>3</sup>**

<sup>1</sup>Afyon Kocatepe Üniversitesi, Sinanpaşa Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, 03850,  
Afyonkarahisar, ORCID No : <http://orcid.org/0000-0003-3151-5288>

<sup>2</sup>Çanakkale Onsekiz Mart Üniversitesi, Ziraat Fakültesi, Bitki Koruma Bölümü, 17100, Çanakkale, ORCID No :  
<http://orcid.org/0000-0002-7137-2616>

<sup>3</sup>Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Eskişehir,  
ORCID No : <http://orcid.org/0000-0001-5559-5281>

**Anahtar Kelimeler:**

Şeker Pancarı,  
Şeker Pancar Ürün  
Kalitesi,  
Şeker Pancarı Üretimi,  
Yabancıot,  
Yapay Zekâ

**Özet:** Endüstriyel devrim ile gıda sanayinin ve insan vücutunun gereklili duyuğu enerjinin ana kaynağı ve tatlandırıcı ihtiyaçlarını karşılamak amacıyla şeker üretimi başlamıştır. Şeker üretimi doğal yollarla şeker pancarı ve şeker kamışı bitkilerinden karşılanmaktadır. Şeker üretmek için bitkilerin ekiminden sükümüne kadar birçok zararlıyla da mücadele edilmekte şeker pancarı bitkisinin şeker üretimi yanında sağladığı bir sürü fayda vardır. Ülkemizde sıkılıkla şeker pancarı ekimi gerçekleştirilmekte olup şeker üretiminde verimin kaybolmaması için birçok araştırma ve çalışma yapılmaktadır. Biz de bu çalışmamızda bu ana kaynaklardan biri olan şeker pancarı üretiminin de yapay zekâ kullanımına yönelik bir literatür taraması yaparak, bu konuda çalışma yapacak araştırmacılara farklı bir bakış açısı kazandırmayı hedefledik.

**(Review Article)**

## **Artificial Intelligence Techniques in Sugar Beet Production**

**Keywords:**

Sugar Beet,  
Sugar Beet Product Quality,  
Sugar Beet Production,  
Weed,  
Artificial Intelligence

**Abstract:** Sugar production begins with the industrial revolution to meet the needs of the food industry and to provide their main energy source to humans. Main natural sources for sugar production are sugar beet and sugar cane. There is a struggle against weeds from the planting of the beets until the harvest. Sugar beets have several other benefits besides sugar production. Sugar beets are widely grown in our country, and as such researches and studies are carried out to achieve a stable efficiency. In this study, the authors aim to provide a perspective to potential researchers in "artificial intelligence applications in sugar beet production" with a literature review in said field.

## **1. GİRİŞ**

İnsan vücutunun temel fonksiyonları için gereklili olan şeker, yüksek kalori ve tadından dolayı beslenme açısından önemli bir besin kaynağıdır. Beslenmenin temel maddesi olmasının yanı sıra, tarım üretimi, tarıma dayalı sanayiye ve istihdama katkısından dolayı şeker, tüm dünyada stratejik öneme sahip bir ürün durumundadır. Dünyada 2019/20 sezonunda dünya şeker üretiminin 39,5 milyon tonu şeker pancarından, 126 milyon tonu da şeker kamışından olmak üzere toplam 165,5 milyon ton olarak gerçekleşmiştir [1].

Türkiye, iklim şartları dolayısıyla yalnızca şeker pancarından şeker üretimi yapabilen ülkeler arasındadır ve yıllık yaklaşık olarak 18,9 milyon ton şeker pancarı üretimi ile Rusya, Fransa, ABD ve Almanya gibi ülkelerden sonra beşinci ülke durumundadır. Şeker pancarı üretiminde ise yetişirildiği bölgelerde önemli bir ekonomik katma değer oluşturan şeker pancarı tarımının Türkiye tarımı ve ekonomisine sağladığı katkılar şu şekilde özetlemek mümkündür;

- Şeker pancarı, ekonomik değerinin yanında istihdam ve tarımda devamlılığı destekler.

\*İlgili yazar/Corresponding Author: ycicek@aku.edu.tr

- Kendinden sonra ekilen hububatta %20 verim artışı sağlamaktadır.
- Yaklaşık 350 bin çiftçi ailesi, 300 bin hektar üzerinde bir alanda şeker pancarı yetiştirmektedir.
- Bir dekarının fotosentez yoluyla havaya verdiği oksijen, 6 kişinin bir yılda tükettiği oksijene eşdeğer olup ve 1 dağlık orman alanından 3 kat daha fazla oksijen üretmektedir.
- Şeker pancarının işlenmesi sonucu oluşan melas ve küspe, hayvan yemi olarak kullanılmakta olup, ispirto üretimi ve içki sanayinin önemli bir hammaddesidir [2].

Şeker pancarı yetiştirmeyi etkileyen önemli etkenler arasında yabanciotlar ve bitki hastalıkları da vardır. Türkiye’de de şeker pancarı tarlalarında önemli türler arasında yer alan imam kavuğu (*Abutilon theophrasti*), kazayağı (*Chenopodium album*) gibi türlerin m<sup>2</sup>’de 1-2 tane bulunması durumunda %48’e ulaşan kayıplar olacağı belirlenmiştir [3]. Türkiye’de yabanciotlardan dolayı oluşabilecek üretim kaybı ile ilgili çalışma bulunmamaktadır ancak Kuzey Amerika’nın önemli pancar üretim bölgelerinde yabanciot mücadelesi yapılmazsa %70’lik bir kayıp ortaya çıkacağı hesaplanmıştır [4]. Bir parazit bitki olan küsküt de önemli bir yabanciot olarak dikkat çekmektedir.

Şeker pancarında yabancotsuz tutulma süresi çok önem arz etmektedir. Yapılan bir çalışmada üretim dönemi boyunca yabanciotlu bırakılan parsellerde verim kaybı %93’e kadar ulaşırken, pancar dört yapraklı dönemine kadar yabancotsuz bırakıldığında şeker pancarı kayıp oranı %28-54 seviyesine gerilemiştir. Fakat, şeker pancarının 8-10 yapraklı dönemine kadar yabancotsuz bırakılması ile bütün üretim mevsimi boyunca yabancotsuz tutulması arasında verimde bir farklılık ortaya çıkmamıştır [4].

Şeker pancarında bakteri, virus veya fungusların sebep olduğu çok sayıda hastalık vardır, ancak bunların içerisinde iktisadi ehemmiyeti haiz hastalık sayısı daha azdır [5, 6, 7, 8]. Bu hastalıklardan biri olan ve Dünya şeker pancarı üretim alanlarının yarısında görülen yaprak lekesi hastalığı (etmeni: *Cercospora beticola* Sacc.) mücadele edilmezse %1-26 kök verimi azalmasına ve %5-18 rafine şeker azalmasına sebep olabilmektedir [9].

Teknoloji ve yazılım sektöründeki derin öğrenme, yapay zekâ tekniklerindeki hızlı gelişme, birçok alanda olduğu gibi tarım alanında da önemli çalışmalar yapılmasını sağlamıştır. Yapılan bu çalışmada şeker pancarı üretiminde kullanılan yapay zekâ ile ilgili yapılan teknolojik değişimler hakkında bir literatür taraması ortaya konulması hedeflenmiştir.

## 2. ŞEKER PANCARI VE DERİN ÖĞRENME?

### 2.1 Şeker pancarı hastalıkları

Şeker pancarının en önemli hastalıklarından biri olan yaprak lekesi hastalığına karşı etkili mücadele yöntemleri olmasına rağmen mücadele gittikçe

zorlaşmaktadır [7, 10, 11]. Çünkü kimyasal yöntemlerin kullanılması hem çevre ve insan sağlığına olumsuz etki yaparken hem de hastalık etmeni, kullanılan ilaçlara karşı dayanıklılık kazanmaktadır [12].

Özgüven ve Adem yaprak lekesi hastalığının otomatik olarak tanımlanması ve tespiti için “Bölgesel tabanlı konvolüsyonlu sinir ağları” (R-CNN) mimarisine dayalı bir model önermişlerdir. Görüntüleme tabanlı olan bu sistem 155 görüntü ile test edilmiş ve test sonuçlarına göre %95,48 lik doğrulama oranı ile başarı elde edilmiştir. Bu doğruluk oranları ile R-CNN mimarisi daha önceki yöntemlerden daha iyi sonuçları vermiştir [13].

Hallou ve arkadaşları, şeker pancarı üretiminde kaliteyi düşüren “Cercospora yaprak lekesi” ni (CLS) tanımlamak için akıllı telefon görüntülerinden elde ettikleri RGB görüntülerini kullanmışlardır. CLS ve birlikte 5 farklı yaprak lekesi hastalığını destek vektör makinesi yöntemini kullanarak sınıflandırmışlardır. Şeker pancarı uzmanlarının yaptığı hastalık sınıflandırması ile karşılaşıldığında destek vektör makinesi yönteminin %82 lik bir doğruluk oranına sahip olduğu bulunmuştur [14].

### 2.2 Şeker pancarı ve yabanciotlar

Şeker pancarı üretiminde yabanciotlar önemli bir kısıtlayıcı unsurdur. Verim ve kaliteyi etkilemelerinin yanı sıra yaprak yanıklığı gibi hastalıklara da konukçuluk etmektedir.

Bu türler arasında *Amaranthus retroflexus*, *Atriplex* sp., *Chenopodium album*, *Rumex crispus*, *Lactuca* asteraceae, *Taraxacum officinale*, *Malva parviflora*, *Convolvulus arvensis* ve *Plantago* sp. gibi türler sayılabilir [12]. Bunların bir kısmı şekerpancarı tarlalarındaki önemli yabanciot türleri arasında yer almaktadır [15, 16, 11, 17].

Lottes ve arkadaşları çalışmalarında şeker pancarı tarlalarında yabanciotları tanımlamak için bir sistem önermişlerdir. 2016 yılında yaptıkları çalışmada üzerinde kamera bulunan bir robot ile elde ettikleri resimleri işleyerek şeker pancarı ve yabanciotları doğru bir şekilde ayırt etmeye çalışmışlardır. Çalışmalarında rastgele orman ve Markov rastgele alanını kullanmışlar ve %90 doğruluk oranında başarı elde etmişlerdir [18].

Miloto ve arkadaşlarının 2017 yılında yaptığı bir çalışmada şeker pancarı ve yabanciot sınıflandırması için anlamsal bölümleme tabanlı “Konvolusyon sinir ağları” (CNN) geliştirmiştir. Çalışma için yaptıkları deneye 10.000’den fazla görüntü üzerinde test etmişler ve 48 saatte %94,74 doğruluk sağlamışlardır [19].

Chavan ve arkadaşları 2018 yılında yaptıkları çalışmada Vggnet ve Alexnet’ in hibrit bir

versiyonunu yapay zekâ modeli geliştirmiştirlerdir. Bu modelde 5544 görüntü test edilmiş ve %93,64 doğruluk oranı ile başarılı sonuçlar yakalanmıştır [20].

Kunz ve arkadaşlarının 2018 yılında yaptığı bir çalışmada kameralı yönlendirme sisteminin ve sıra arası çapaların otomatik yan kaydırma kontrolünün, şeker pancarı, mısır ve soya fasulyesinde mekanik ot ayıklamayı, yabanciot kontrol etkinliği ve mahsul hasarı açısından manuel yönlendirme sistemleriyle kıyaslanmıştır. Kamerayla yönlendirilen sıralar arası çapalama, parmaklı ot veya tırtıklı bıçak gibi sira içi ot ayıklama elemanları ile birleştirildiğinde, yabanciot bastırma, standart herbisit tedavilerine yaklaşık olarak eşit olduğu, mekanik ördek ayaklı çapa ve kimyasal bant püskürtmenin birlikte uygulanması, şeker pancarındaki yabanciotları tamamen ortadan kaldırırken ve herbisit girdisini %65 oranında azalttığı tespit edilmiştir. Mekanik ot temizleme sistemleri, herbisit tedavilerinin etkinliğini elde edememiş olsa da otomatik yönlendirme teknolojileri, mekanik ot ayıklamayı bütünlüşmiş yabanciot yönetimi için umut verici ve güçlü bir alternatif haline getirmiştir [21].

Mink ve arkadaşlarının 2018 yılında yaptıkları çalışmada, mısır ve şeker pancarı tarlalarında insansız hava aracı kullanarak kıvrılmış rıhtım ile sürünen devedikeni yabanciotlarının öbeklerini tespit ederek bu yabanciotların tarlalardaki haritalamasını çıkarmışlar ve sahaya özel ilaçlama için bu haritaları kullanarak ilaçlama yapmışlardır. Mısırda %96, şeker pancarında %80 başarı elde edilmiştir [22].

Kun ve arkadaşlarının 2020 yılında yaptığı bir çalışmada resimler grafiksel bir ağ ile işlenerek bir RNN ile grafik temsilleri özetlenmiştir. Çalışmada DeepWeeds (Kuzey Avustralya'daki yabanciot veri seti) üzerinde bir çalışma yapılmıştır. Herhangi bir ürün arası değil tamamen yabanciotlar üzerinde olan bir veri setidir. 17509 görüntü ve 8 adet yabanciot türü mevcuttur. "Graph Weeds Net" (GWN) isimli grafik tabanlı yeni bir derin öğrenme mimarisi önermişlerdir. Sonuçlar farklı yöntemler ile değerlendirilmiş ve %95,2 doğruluk elde edilmiştir [23].

Gao ve arkadaşları 2020 yılında şeker pancarı tarlasında sadece yabanciot olarak *Convolvulus sepium* (Çit sarmaşığı) bitkisi üzerinde görüntü alarak çalışma yapmışlardır. Aldıkları 452 adet görüntü ile 2271 adet sentetik görüntü oluşturarak CNN ile bir model oluşturmuşlardır. Yüz adet görüntüyü modelin testi için kullanılırken 100 görüntüyü de modelin doğruluğu için kullanmışlar ve %82,9 doğruluk elde etmişlerdir [24].

Jabir ve arkadaşlarının 2021 yılında yaptığı çalışmada CNN algoritmaları ile Tensorflow Api'leri üzerine inşa edilen Kerası kullanarak Beni Mellal bölgesinde bulunan en popüler yabanciot türlerini ve yüzdesinin yüksek doğrulukta tespit edip tanımlayabilen bir model oluşturmuş ve bu modeli en iyileştirmeye çalışmışlardır. Çalışma sonucunda %82 doğruluk elde etmişlerdir [25].

Masouleh ve Akhoondzadeh, şeker pancarı tarlalarındaki yabanciotları tanımlamak için DeepMultiFuse isimli öz nitelik tabanlı bir derin öğrenme yöntemi geliştirmiştir. Görüntüler Multi spektral İha ile toplanan resimler uçtan uca eğitilebilen 5 temel kavramdan oluşan özellik tabanlı bir derin öğrenme mimarisi kurmuşlardır. Kurulan mimari son teknoloji ağlarından çok daha iyi sonuçlar vermiştir [26].

Bah ve arkadaşları çalışmalarında CNN kullanarak; ispanak, şeker pancarı ve fasulye gibi sebze tarlalarında bulunan yabanciotları tanımlamışlardır. Tarlalardan 20m yükseklikte İha uçurarak alınan görüntülerini kullanarak ürün ve yabanciot ayrimi üzerine çalışmışlardır. Şeker pancarı için %93, ispanak için %81 ve fasulye için hassasiyet %69 olarak hesaplanmıştır [27].

Moazzam ve arkadaşları Pakistan'da şeker pancarı tarlalarından multispektral kamera sensörleri kullanarak aldığıları görüntüler ile yabanciotların tespitini yapmışlardır. Yapılan bu çalışmada, 3 sınıfı piksel sınıflandırma problemini sırayla mahsul ve yabani ot sınıflandırma doğruluğunu artıran 2 sınıfı bir mahsul-yabani yama sınıflandırma problemine dönüştürmüştür. Sınıflandırma için, 11 katmanlı CNN modeline dayanan bir VGG-Beet CNN geliştirmiştirlerdir. Eğitim ve test için 3 farklı veri seti kullanılmış olup ilk veri setini proje için İHA görüntülerile oluşturmuş, diğer veri setleri ise kamuya açık veri setlerinden alınmıştır. Yama tabanlı yöntemin farklı aydınlatma koşullarına daha dayanıklı olduğunu gözlemlenmiştir. U-Net ve Deeplab tabanlı semantik segmentasyona kıyasla yama tabanlı yaklaşımım için daha yüksek mahsul – yabanciot doğruluğu ve daha düşük test süresi gözlemlenmiştir [28].

### 2.3 Ürün kaybı

Şeker pancarı bitkisi yetiştiirdikten sonra mekanik olarak hasat edilmektedir. Mekanik hasat sırasında pancarda gelen kök yaralanmaları şeker pancarının kalitesini olumsuz yönde etkilemektedir [29]. Hasat sırasında mekanik hasarı tespit etmek için birçok yöntem kullanılmaktadır. Genel olarak kullanılan, hasat makinesi operatörünün değerlendirmesi olup bu da sürekli olarak gerçekleşmemektedir. Mekanik hasar, ürün kalitesinde önemli rol oynadığından bunun tespit edilip mekanik hasadın hasarsız bir şekilde yapılması gerekmektedir.

Nasirahmedi ve arkadaşları şeker pancarı hasadı sırasında pancarda gelen hasarı tespit etmek için CNN tabanlı bir sistem geliştirmiştir. Sistem için görüntüler şeker pancarı hasadı sırasında farklı biçerdöverlerden alınmıştır. Araştırma için CNN tabanlı YOLO V4, R-FCN ve R-CNN gibi farklı detektör modelleri geliştirilmiştir. Sonuçlara göre

YOLO V4, şeker pancarındaki hasarı daha iyi bir performansla tespit etmiştir [30].

#### 2.4 Pancar fidelerinin ve ekim alanlarının sınıflandırılması

Şeker pancarı tohumu tarlaya ekildikten sonra verimin yüksek olması için seyreltilmelidir [31]. Bu yüzden seyreltme işleminin sağlıklı gerçekleştirilebilmesi için pancar fidelerinin ve ekim alanlarının yoğunluklarının bilinmesi önem arz etmektedir.

David ve arkadaşları aycıçeği, mısır ve şekerpancarı tarlalarından aldıkları drone görüntülerini ile tarlaların bitki yoğunluklarını incelemiş ve bu yöntemler ile klasik el yöntemleri karşılaştırılmıştır. Tarım arazisindeki 16247 bitki etkileşimli olarak etiketlenmiş olup her bitki ayrı bir R-CNN mimarisi ile modellenmiştir. Mısırda ve aycıçeginde derin öğrenme mimarisinin, el yapımından daha iyi olduğunu ortaya çıkarmışlardır. Fakat yüksek ot istilasında derin öğrenme performansının biraz daha geride kaldığı gözlemlenmiştir [32].

Kussul ve arkadaşları, uyu görüntülerini ve derin öğrenme mimarisini kullanarak şeker pancarı, mısır, aycıçegi, soya ve buğday ekim alanlarını tespit etmeye çalışmışlardır. İki farklı uyu görüntülerden aldıkları resimleri CNN mimarisi ile sınıflandırmışlar mısır ve soya tahmininde yüksek oranda başarı sağlamışlardır [33].

Ashqar ve arkadaşları bitki fidelerini sınıflandırmak için CNN algoritmalarını kullanmışlardır. Oniki türde ait 960 benzersiz bitki ile yaklaşık 5000 görüntü içeren bir veri seti ile sistemi modellemişlerdir. Şeker pancarı fidesinin de bulunduğu 12 farklı fide sınıflandırmasında %99,48 lik bir başarı elde etmişlerdir [34].

Alimboyong ve arkadaşları, Güney Danimarka da 4234 bitki görüntüsünün kullanarak 12 bitki türünün tanımlamışlardır. CNN mimarisi üzerine kurulan sistem ile, şeker pancarı, kara çim, yabani hardal, yoğurtotu, kuş otu, buğday, yabapazı, mısır, yosun, küçük çiçekli kızılıcık gibi bitkilerin bulunduğu sınıflandırmada tüm bitkilerde %99 un üzerinde bir başarı elde etmişlerdir. Test sonuçlarına göre adı buğday, mısır, küçük çiçekli kızılıcık ve şeker pancarı sınıflandırmasında % 100 lük bir performans elde edilmiştir [35].

Barreto ve arkadaşları tarlalardaki bitki sayımı için bir derin öğrenme modeli geliştirmiştir. Şeker Pancarı, mısır ve çilek tarlalarındaki fide sayıları İHA tabanlı kamera sistemlerinden alınan görüntülerle tam eşişimli bir ağ ve pipeline (boru hattı) kullanılarak tahmin yapabilen bir çalışma gerçekleştirmiştir. Yapılan tahminler, manuel sayım ile karşılaştırıldığında şeker pancarından hata oranı % 4,6 iken mısır ve çilekten %4 den az çıkmıştır [36].

#### 2.5 Ürün kalitesi

Bitkilerin büyümesi için su ve güneş kadar toprakta bulunan minerallerinde önemi büyüktür. Bitkiler büyümek için toplamda 14 temel minerale ihtiyaç duyarlar [37]. Bitkilerin besin eksikliğinin erken tespiti, verim kaybının önüne geçmek için oldukça önemlidir.

Yi ve arkadaşları çalışmalarında şeker pancarı görüntülerini kullanarak, pancardaki besin (Azot, Potasyum ve Fosfor) eksikliklerini tespit etmişlerdir. Uzun süreli gübre ortamında yetişen 5648 şeker pancarı görüntüsünü 5 katmanlı CNN ile tespit etmeye çalışmışlardır. Beş katmanlı CNN modeli eğitim sırasında besin eksikliklerinin yüksek doğrulukta tanımlayabilmıştır [38].

### 3. SONUÇ

Temel ihtiyaç kaynağımız olan şekeri elde etmek için şeker üretiminin miktarını ve kalitesinin artırılması gereklidir. Modern tarım teknolojilerindeki gelişmeler takiben şeker pancarı üretimi arttırlılmıştır. Ayrıca son yıllarda bilgisayar ve bilişim sistemlerinde yaşanan hızlı gelişmeler sonucu bilgisayarlar, çok çeşitli alanlarda kullanılmaya başlanmıştır. Bu bilgisayar teknolojisindeki gelişmelerin sonucu olan yapay zekanın tarım alanında ve şeker pancarı üretiminde kullanılması artmıştır. Çalışmamız, yapay zekâ kullanımının şeker pancarı üretim miktarın da ve ürün kalitesinde artış olduğunu ortaya koymuştur.

#### Finansman

Yazarlar, araştırmalarının kamu, ticari veya kar amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe almamışlardır.

#### Çıkar çatışması

Çalışma ile ilgili olarak, herhangi bir kişi veya kurumla çıkar çatışmasının bulunmadığını yazarlar olarak onaylıyoruz.

#### KAYNAKÇA

- [1] Şentürk Ö, Şeker Pancarı Ürün Raporu, 2020, Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü (TEPGE), Ankara, 21s.
- [2] Eştürk, Ö. (2018). Türkiye'de şeker sektörünün önemi ve geleceği üzerine bir değerlendirme. Anadolu İktisat ve İşletme Dergisi, 2(1), 67-81.
- [3] Soltani, N., Dille, J. A., Robinson, D. E., Sprague, C. L., Morishita, D. W., Lawrence, N. C., ... & Sikkema, P. H. (2018). Potential yield loss in sugar beet due to weed interference in the United States and Canada. Weed Technology, 32(6), 749-753.

- [4] Jursík, M., Holec, J., Soukup, J., & Venclová, V. (2008). Competitive relationships between sugar beet and weeds in dependence on time of weed control. *Plant Soil and Environment*, 54(3), 108.
- [5] Özgür, O. E. (2003). *Türkiye Şeker Pancarı Hastalıkları*. Türkiye Şeker Fabrikaları.
- [6] Yardimci, N., ÇULAL-KILIÇ, H., & Ürgen, G. (2012). Eskişehir ili şeker pancarı üretim alanlarında görülen bazı virüs hastalıklarının DAS-ELISA yöntemiyle belirlenmesi. *Ziraat Fakültesi Dergisi*, 7(1), 42-50.
- [7] Ozgur, O. E. (2014). *Şeker Pancarı (The Sugar Beet Crop)*. Filiz Matbaacılık San. Ve Tic. Ltd. Sti., Ankara, 228 s.
- [8] Arif, S. A. R. I., & BOYRAZ, N. (2019). Konya İli Çumra Yöresinde Şekerpancarında Görülen Fungal Hastalıklar Üzerine Genel Bir Değerlendirme. *Bahri Dağdaş Bitkisel Araştırma Dergisi*, 8(2), 279-288.
- [9] KAYA, R. 2017. Şeker pancarında Cercospora yaprak lekesi hastalığı ve mücadele. *TÜRKTOB Türkiye Tohumcular Birliği Dergisi* 21: 31-35.
- [10] TUNALI, B., KANSU, B., YILMAZ, N. D. K., MEYVA, G., & Riza, K. A. Y. A. (2018). Türkiye'de Şeker Pancarında Cercospora beticola Sacc.'nın Yaygınlığı, Patojenitesi ve Bazı Çeşitlerin Dayanıklılığının Belirlenmesi. *The Journal of Turkish Phytopathology*, 47(1), 21-30.
- [11] Koç, H., Ergün, A. & Kartal, F. (2018). Problems of sugar beet producers in Sivas province and proposals for solutions. *International Journal of Geography and Geography Education*, 38, 247-265.
- [12] Kaya, R. (2012). Şeker pancarında Cercospora yaprak lekesi (Cercospora beticola Sacc.) hastalığı ve mücadele stratejisi. I. *Uluslararası Anadolu Şeker Pancarı Sempozyumu*, 20-22.
- [13] Ozguven, M. M., & Adem, K. (2019). Automatic detection and classification of leaf spot disease in sugar beet using deep learning algorithms. *Physica A: Statistical Mechanics and its Applications*, 535, 122537.
- [14] Hallau, L., Neumann, M., Klatt, B., Kleinhenz, B., Klein, T., Kuhn, C., Röhrig, M., Bauckhage, C., Kersting, K., Mahlein, A.-K., Steiner, U. and Oerke, E.-C. (2018), Automated identification of sugar beet diseases using smartphones. *Plant Pathol*, 67: 399-410. <https://doi.org/10.1111/ppa.12741>
- [15] Özgür O., E. (2013a). *Şeker Pancarı Tarla Çiçekleri, I (Weeds of Sugarbeet)*. Filiz Matbaacılık San. Ve Tic. Ltd. Sti., Ankara, 410 s.
- [16] Özgür O., E. (2013b). *Şeker Pancarı Tarla Çiçekleri, II (Weeds of Sugarbeet)*. Filiz Matbaacılık San. Ve Tic. Ltd. Sti., Ankara, 410 s.
- [17] Akar A, Öğüt Yavuz D (2020) Uşak ili şeker pancarı (*Beta vulgaris L.*) ekim tarlalarında bulunan yabancı türlerinin, rastlama sıklıklarının ve yoğunlıklarının belirlenmesi. *MKU. Tar. Bil. Derg.* 25(3) : 461-473. DOI: 10.37908/mkutbd.678019
- [18] Lottes, P., Hoeferlin, M., Sander, S., Müter, M., Schulze, P., & Stachniss, L. C. (2016, May). An effective classification system for separating sugar beets and weeds for precision farming applications. In *2016 IEEE International Conference on Robotics and Automation (ICRA)* (pp. 5157-5163). IEEE.
- [19] Miloto, A., Lottes, P. &Stachniss, C., "Real-Time Blob-Wise Sugar Beets vs Weeds Classification For Monitoring Fields Using Convolutional Neural Networks". Bonn, Germany, International Conference on Unmanned Aerial Vehicles in Geomatics, 2017.
- [20] Chavan, R., T. &Nandedkar, A. V., 2018. "Agroavnet for crops and weeds classification: A step forward in automatic farming". *Computers and Electronics in Agriculture*, Issue 154, 2018, pp. 361-372
- [21] Kunz, C., Weber, J. F., Peteinatos, G. G., Sökefeld, M., & Gerhards, R. (2018). Camera steered mechanical weed control in sugar beet, maize and soybean. *Precision Agriculture*, 19(4), 708-720.
- [22] Mink, R., Dutta, A., Peteinatos, G. G., Sökefeld, M., Engels, J. J., Hahn, M., & Gerhards, R. (2018). Multi-temporal site-specific weed control of *Cirsium arvense* (L.) Scop. and *Rumex crispus* L. in maize and sugar beet using unmanned aerial vehicle based mapping. *Agriculture*, 8(5), 65.
- [23] Kun Hu, et al. "Graph Weeds Net: A Graph-based Deep Learning Method for Weed

- Recognition." *Computers and electronics in agriculture*, v. 174 .. pp. 105520. doi: [10.1016/j.compag.2020.105520](https://doi.org/10.1016/j.compag.2020.105520)
- [24] Gao, J., French, A. P., Pound, M. P., He, Y., Pridmore, T. P., & Pieters, J. G. (2020). Deep convolutional neural networks for image-based *Convolvulus sepium* detection in sugar beet fields. *Plant Methods*, 16(1), 1-12.
- [25] Jabir, B., Falih, N., Sarih, A., & Tannouche, A. (2021). A Strategic Analytics Using Convolutional Neural Networks for Weed Identification in Sugar Beet Fields. *Agris online Papers in Economics and Informatics*, 1(March), 49-57.
- [26] Khoshboresh-Masouleh, M., and M. Akhoondzadeh. "Improving weed segmentation in sugar beet fields using potentials of multispectral unmanned aerial vehicle images and lightweight deep learning. *JARS* 15, 034510." (2021). <https://doi.org/10.11117/1.JRS.15.034510>
- [27] Bah, M. D., Dericquebourg, E., Hafiane, A., & Canals, R. (2018, July). Deep learning based classification system for identifying weeds using high-resolution UAV imagery. In *Science and Information Conference* (pp. 176-187). Springer, Cham.
- [28] S. I. Moazzam *et al.*, "A Patch-Image Based Classification Approach for Detection of Weeds in Sugar Beet Crop," in *IEEE Access*, vol. 9, pp. 121698-121715, 2021, doi: 10.1109/ACCESS.2021.3109015.
- [29] Bentini, M.; Caprara, C.; Rondelli, V.; Caliceti, M. The use of an electronic beet to evaluate sugar beet damage at various forward speeds of a mechanical harvester. *Trans. ASAE* 2002, 45, 547.
- [30] Nasirahmadi, A.; Wilczek, U.; Hensel, O. Sugar Beet Damage Detection during Harvesting Using Different Convolutional Neural Network Models. *Agriculture* 2021, 11, 1111. <https://doi.org/10.3390/agriculture11111111>
- [31] Çakmakçı, R., & Oral, E. (1998). Seyreltmeli ve seyreltmesiz şeker pancarı tarımında farklı tarla çıkışlarının verim ve kaliteye etkisi. *Turkish Journal of Agriculture and Forestry*, 22, 451-461.
- [32] Etienne David, Gaëtan Daubige, François Jou delat, Philippe Burger, Alexis Comar, Benoit de Solan, Frédéric Baret, Plant detection and counting from high-resolution RGB images acquired from UAVs: comparison between deep-learning and handcrafted methods with application to maize, sugar beet, and sunflower crops, bioRxiv 2021.04.27.441631; doi: <https://doi.org/10.1101/2021.04.27.441631>
- [33] N. Kussul, M. Lavreniuk, S. Skakun and A. Shelestov, "Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data," in *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 5, pp. 778-782, May 2017, doi: 10.1109/LGRS.2017.2681128.
- [34] Ashqar, Belal AM, Bassem S. Abu-Nasser, and Samy S. Abu-Naser. "Plant seedlings classification using deep learning." (2019).
- [35] Alimboyong, C. R., Hernandez, A. A., & Medina, R. P. (2018, October). Classification of plant seedling images using deep learning. In *TENCON 2018-2018 IEEE Region 10 Conference* (pp. 1839-1844). IEEE.
- [36] Barreto, A., Lottes, P., Yamati, F. R. I., Baumgarten, S., Wolf, N. A., Stachniss, C., ... & Paulus, S. (2021). Automatic UAV-based counting of seedlings in sugar-beet field and extension to maize and strawberry. *Computers and Electronics in Agriculture*, 191, 106493.
- [37] Marschner, H. *Marschner's Mineral Nutrition of Higher Plants*; Academic Press: Cambridge, MA, USA, 2011.
- [38] Yi, J.; Krusenbaum, L.; Unger, P.; Hüging, H.; Seidel, S.J.; Schaaf, G.; Gall, J. Deep Learning for Non-Invasive Diagnosis of Nutrient Deficiencies in Sugar Beet Using RGB Images. *Sensors* 2020, 20, 5893. <https://doi.org/10.3390/s20205893>