






Evrişimli Sinir Ağlarıyla Galaksilerin Sınıflandırılması

E. Kaan Ülgen^{1,2} *, Sinan Aliş^{3,4} , F. Korhan Yelkenci³ , Oğuzhan Çakır^{5,6,7} ,
Süleyman Fişek^{3,4} 

¹ İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Astronomi ve Uzay Bilimleri Programı, 34116, İstanbul, Türkiye

² Huawei Türkiye, Ar-Ge Merkezi, 34768, İstanbul, Türkiye

³ İstanbul Üniversitesi, Fen Fakültesi, Astronomi ve Uzay Bilimleri Bölümü, 34116, İstanbul, Türkiye

⁴ İstanbul Üniversitesi Gözlemevi Uygulama ve Araştırma Merkezi, 34116, İstanbul, Türkiye

⁵ School of Mathematical and Physical Sciences, Macquarie University, NSW 2109, Australia

⁶ Astronomy, Astrophysics and Astrophotonics Research Centre, Macquarie University, Sydney, NSW 2109, Australia

⁷ ARC Centre of Excellence for All Sky Astrophysics in 3 Dimensions (ASTRO 3D), Australia

Accepted: December 17, 2022. Revised: December 17, 2022. Received: November 13, 2022.

Özet

Galaksilerin sınıflandırılması, onların oluşumlarını ve evrimlerini anlamak için atılan önemli bir adımdır. Son 20 yılda artan gökyüzü taramalarında elde edilen görüntülerdeki galaksilerin gözle sınıflandırılması neredeyse imkansız hale gelmiştir. Bu problem günümüzde parametre uzayında makine öğrenmesi, görüntü uzayında ise derin öğrenme yöntemleri ile kısmen çözülmektedir. Bu çalışmada, evrişimli sinir ağları (ing. convolutional neural network - CNN) kullanılarak galaksiler sınıflandırılmıştır. Çalışmada kullanılan model, Galaxy Zoo-2 projesi kapsamında etiketlenmiş galaksilerin hem SDSS hem de DECaLS gökyüzü taramaları kapsamında elde edilen görüntüleri ile eğitilmiştir. Altı sınıf için SDSS verileri ile eğittiğimiz modelin doğruluk oranı %84 olarak elde edilirken, aynı galaksilerin DECaLS görüntülerini kullanarak eğittiğimiz modelin doğruluk oranı ise %87 olarak bulunmuştur.

Abstract

The classification of galaxies is a critical step in understanding their formation and evolution. The images obtained by the imaging surveys have been tremendously increased over the past 20 years. Thus, it nearly became difficult to classify galaxies visually. Today, machine learning in parameter space and deep learning in pixel space help to partially overcome this challenge. In this study, convolutional neural networks (CNN) were used to classify galaxies. The model employed in the study was trained using images of both SDSS and DECaLS surveys which have been labelled from the Galaxy Zoo-2 project. The model we trained for six classes using DECaLS images revealed an accuracy of 87% while the model trained using SDSS images of the same galaxies resulted an accuracy of 84%.

Anahtar Kelimeler: deep learning – Galaxy Morphology – Convolutional Neural Networks – Artificial Neural Network

1 Giriş

Galaksilerin anlaşılmasına yönelik adımlar 1920'lerde Edwin Hubble'in öncü çalışmaları ile başlamıştır (Hubble 1926). Başlangıçta galaksiler, görünümüne göre sınıflandırılmaktaydı. Hubble tarafından geliştirilen, "çatal diyagramı" olarak da bilinen morfolojik sınıflandırma (Hubble 1936) birçok bakımdan günümüzde geçerliliğini korumaktadır. Hubble sınıflandırmasında dört ana galaksi türü bulunmaktadır: eliptik, merceksi, spiral ve düzensiz. Hubble sınıflandırması dışında başka galaksi sınıflandırma yöntemleri ve yaklaşımları da geliştirilmiştir. De Vaucouleurs, DDO ve Yerkes bu sınıflandırma yöntemlerinden bazılarıdır. Hubble sınıflamasındaki eliptik ve merceksi galaksilere "erken tip", spiral ve düzensiz galaksilere de "geç tip" galaksi denilmektedir.

Galaksilerin morfolojileri ile fotometrik ve tayfsal özellikleri buldukları ortama yakından ilişkilidir (Dressler 1980; Butcher & Oemler 1978, 1984). Bu ilişkilerin anlaşılması galaksi evrimi çalışmalarının en önemli amaçlarından biridir (Conselice 2006). Galaksilerin morfolojilerinin belirlenmesi çok önemli bir bilgi

sağlasa da, uzak galaksilerin morfolojilerinin belirlenmesi çok güçtür. Galaksinin rengi ile morfolojisinin ait olduğu tip arasında güçlü bir ilişki bulunmaktadır (Strateva ve diğ. 2001; Baldry ve diğ. 2004). Erken tip galaksiler daha kırmızı görünürken, geç tip galaksiler mavi baskın renklere sahiptir. Bu durum temelde galaksilerin sahip oldukları gaz içerik ve yıldız popülasyonları ile bağlantılıdır.

Sloan Sayısal Gökyüzü Taraması (Sloan Digital Sky Survey, SDSS) ile başka bir seviyeye çıkan gökyüzü taramalarında milyonlarca galaksi belirlenmekte ve çok bantta görüntülenebilmektedir. Bu veritabanlarındaki galaksilerin morfolojilerinin geleneksel yöntemlerle belirlenmesi imkansızdır ve bu durum her geçen gün daha da imkansız hale gelmektedir.

Yalnızca SDSS taramasında birkaç yüz milyon galaksi görüntülenmiştir (Blanton ve diğ. 2017). Bu galaksilerin geleneksel yöntemlerle sınıflanamamasının temel nedeni yeterli zaman ve insan kaynağının olmamasıdır. Ayrıca, yapılacak sınıflama özellikle uzak galaksiler için büyük yanlışlık da içerebilir.

İnsan kaynağı probleminin aşılabilmesi için SDSS ile görüntülenen galaksiler Galaxy Zoo (GZ) projesi kapsamında "halk bilim" etkinliğiyle sınıflandırıldı (Lintott ve diğ. 2011;

* k.ulgen90@gmail.com

Çizelge 1. Herbir galaksi sınıfı için veri setindeki galaksi sayısı.

Sınıf (morfoloji)	Galaksi Sayısı
Pürüzsüz tam yuvarlak galaksi	2000
Pürüzsüz tam yuvarlak olmayan galaksi	2000
Pürüzsüz basık (puro şeklinde) galaksi	2000
Çubuklu spiral galaksi	2000
Çubuksuz spiral galaksi	1795
Etkileşen galaksiler	522

Willett ve diğ. 2013). Galaxy Zoo projesinde galaksiler, sayıları yüzbine yaklaşan gönüllüler tarafından incelenerek, uzmanların hazırladığı rehber ve yönlendirmeler ışığında sınıflandırıldı. Bu haliyle bile iki yıl süren ilk çalışmanın (GZ1) sonunda 900.000 galaksi sınıflandırılabilir. Yeni nesil gökyüzü taramalarında elde edilecek görüntülerle halk bilim yaklaşımlarının da uygulanabilirlik sınırlarına ulaşılmaktadır. Örneğin Euclid ve LSST gibi projeler kapsamında gözlenecek galaksileri Galaxy Zoo projesinde olduğu gibi sınıflandırabilmemiz için yaklaşık yüz yıla ihtiyaç duyulduğu tahmin edilmektedir.

Son yıllarda, makine öğrenmesi ve derin öğrenme teknikleri astronomi çalışmalarında başarılı bir şekilde uygulanmıştır. Derin öğrenme algoritmaları, özellikle bilgisayarlı görüş çalışmalarında önemli başarılar imza atmıştır. Piksel düzeyinde en anlamlı öz nitelikleri öğrenmek için, derin öğrenme algoritmalarının biri olan evrişimli sinir ağları (convolution neural network, CNN) en yaygın kullanılan yöntemlerden biridir. Evrişimli sinir ağları yöntemi, beynin görsel korteksi üzerine yapılan çalışmalar sonucunda ortaya çıkmıştır. Günümüzde CNN'ler, nesne tanıma, görüntü sınıflandırma, otomatik video sınıflandırma, ses tanıma ve doğal dil işleme gibi birçok çalışma alanında başarılı bir şekilde kullanılmaktadırlar. Galaksi morfolojileri alanında da CNN'lerin yaygın bir şekilde kullanılması şaşırtıcı değildir (Dieleman ve diğ. 2015; Huertas-Company ve diğ. 2015; Domínguez Sánchez ve diğ. 2018; Ghosh ve diğ. 2020; Goddard & Shamir 2020; Tadaki ve diğ. 2020; Vega-Ferrero ve diğ. 2021; Cheng ve diğ. 2021; Bom ve diğ. 2021; Walmsley ve diğ. 2022; Varma ve diğ. 2022).

Bu çalışmada iki ayrı gökyüzü tarama projesinden elde edilen görüntüler, daha önce Galaxy Zoo projesi kapsamında yapılan sınıflandırmalar temel alınarak, CNN yöntemiyle sınıflandırılmıştır. §2'de çalışmada kullanılan veri setleri ve uygulanan yöntemi, §3'te de ise uygulanan CNN modeli ile elde edilen sınıflama sonuçları verilmektedir.

2 Veriler ve Yöntem

Galaksilerin morfolojilerini CNN kullanarak belirleyebilmemiz için sınıflaması önceden yapılmış bir veri setinin temel alınması ve bu verilerdeki etiketin kullanılmasına ihtiyaç duyulmaktadır. Etiket terimi makine öğrenmesi yöntemlerinde sınıflama yapılmak istenen cismin (burada galaksi) hangi sınıfa ait olduğunu belirtir. Bu çalışmada, CNN modelinin eğitilmesi amacıyla Galaxy Zoo 2 projesi (Willett ve diğ. 2013) kapsamında etiketlenmiş galaksiler kullanılmıştır.

2.1 Galaxy Zoo-2 Kataloğu

GZ projesi, SDSS kapsamında görüntülenen galaksilerin sayıları yüzbinde bulan kişiler tarafından morfolojik olarak sınıflandırılmasına dayanmaktadır. GZ'nin çeşitli alt projeleri

olmakla birlikte, iki büyük versiyonu bulunmaktadır. GZ1 projesinde 2007-2009 yılları arasında 900.000 galaksi sınıflanmıştır (Lintott ve diğ. 2011), devamında yürütülen GZ2 projesinde ise yaklaşık 300.000 galaksi sınıflandırılabilmiştir (Willett ve diğ. 2013). GZ2'de daha az galaksi sınıflandırılabilmesinin nedeni, ikinci projede sınıflama yapanlara çok daha fazla soru sorularak galaksilerin daha ayrıntılı sınıflandırılmasının hedeflenmiş olmasıdır. GZ1'de galaksiler, temelde, erken ve geç tip olmak üzere iki sınıfa ayrılırken, GZ2'de 11 sınıf tanımlanmıştır.

Bu çalışmada, evrişimli sinir ağları yönteminin uygulanması için GZ2 kataloğundan yararlanılmıştır. GZ2 kataloğunda yer alan galaksilerin parlaklık limiti $r < 17$ ve buna bağlı olarak tayfsal kırmızı kaymaları da $z_s < 0.25$ 'den küçüktür. GZ2 projesi kapsamında gönüllülere 37 sorudan oluşan ve toplam 11 sınıfı kapsayan sorular sorulmuştur. Willett ve diğ. (2013) tarafından verilen GZ2 kataloğu daha sonra Hart ve diğ. (2016) tarafından gözden geçirilerek olası yanlışlıklar giderilmiştir.

Çalışmamız için seçtiğimiz sınıflar şu şekildedir: pürüzsüz tam yuvarlak galaksi (smooth, completely round), pürüzsüz tam yuvarlak olmayan galaksi (smooth, in-between round), pürüzsüz basık (puro şeklinde) galaksi (smooth, cigar shaped), çubuklu spiral galaksi (barred spiral), çubuksuz spiral galaksi (unbarred spiral) ve etkileşen galaksiler (merger). Galaksiler seçilirken, en az 15 GZ kullanıcısı tarafından sınıflama yapılan ve verilen yanıtların %70 oranda tutarlı olduğu cisimler seçilmiştir.

2.2 SDSS ve DECaLS Görüntüleri

CNN yöntemiyle sınıflandırılan galaksilere ait görüntüler SDSS ve DECaLS tarama projelerinden alınmıştır.

SDSS, 2000 yılında başlamış ve halen devam eden bir gökyüzü tarama projesidir (York ve diğ. 2000). New Mexico (ABD)'de bulunan 2.5 m'lik bir teleskopla hem çok-bant görüntüleme (u, g, r, i, z) yapılmakta hem de tayf alınmaktadır (Gunn ve diğ. 2006). En son veri sürümü DR17 yayındadır ve şimdiye kadar bir trilyondan fazla cisim kataloglanmıştır. Bu cisimlerin yaklaşık üç milyununun da tayfları alınabilmiştir (Abdurro'uf ve diğ. 2022).

DECaLS (Dark Energy Camera Legacy Survey) ise DESI (Dark Energy Spectroscopic Instrument) projesinin 1/3'ünü içeren bir alanda yürütülen bir görüntüleme projesidir (Dey ve diğ. 2019). DECaLS gözlemleri 4 m'lik Blanco teleskobu tarafından gerçekleştirilmiştir. GZ2 kataloğundaki galaksiler DECaLS'in de tarama alanına düşmektedir.


Böylece, çalışmada aynı galaksilerin Sloan (2.5 m) ve Blanco (4 m) teleskopları ile elde edilen görüntülerinin kullanılması ve sonuçların karşılaştırılması mümkün olmuştur.

Seçilen galaksilerin "true-color" (RGB) görüntüleri, hem SDSS hem de DECaLS projelerinin sağlamış olduğu çevrim-içi platformlar üzerinden indirilmiştir. Her iki platformdan da görüntüler 69x69 piksel boyutlarında üretilmiştir. Bu galaksi morfolojilerine ait örnek görüntüler Şekil 1'de gösterilmiştir.

2.3 Evrişimli Sinir Ağının Uygulanması

CNN uygulaması için veri setinin dengeli olması önemlidir. Yaklaşık 240.000 galaksi içeren Hart ve diğ. (2016) kataloğundan, §2.1'de belirtilen altı sınıf için galaksi seçilmiştir. Yukarıda belirtilen kriterleri sağlayan galaksilerden her bir sınıf için 2000 galaksiyi rastgele seçildi. Ancak Çizelge 1'de verilen sınıflardan çubuksuz spiraller ve etkileşen sınıflarına ait galaksi sayısı uygulanan tutarlılık kriterinden sonra 2000'in

SDSS



Completely Round Smooth


In-between Round Smooth

Cigar Shaped Round Smooth

Barred Spiral

Unbarred Spiral

Merger



DECaLS

Şekil 1. Çalışmada kullanılan galaksilerin Çizelge 1'de verilen sınıfları için örnek görüntüleri. Aynı galaksilerin görüntüleri SDSS (üst sıra) ve DECaLS (alt sıra) için ayrı ayrı verilmektedir.

altına düşmüştür. Bu galaksiler olduğu gibi listeye eklendi. Bu şekilde bazı galaksi morfolojilerinin model tarafından ezberlenmesinin önüne geçilmiş oldu. Çizelge 1'de her bir sınıfa ait galaksi sayıları verilmektedir. Kullanılan galaksi sayısı toplam 10317'dir. Bu galaksilerin yaklaşık %70'i modelin eğitimi için, %30'u ise modelin testi için kullanılmıştır.

Evrışimli sinir ağları, yapay sinir ağlarının bir alt mimarisidir. Tarihsel olarak beynin görsel korteksiyle ilgili yapılan araştırmalar sırasında ortaya çıkmıştır. Günümüzde bilgisayarlı görü alanında başarılı sonuçlar elde etmesinden dolayı yaygın biçimde kullanılmaktadır. Derin öğrenme alanında evrişim yaklaşımını ilk kez kullanan **LeCun ve diğ. (1998)**'dir. Ekip, bu çalışma kapsamında posta numaraları ve banka çekleri üzerine yazılmış sayıların tanımlanması için geliştirdikleri evrişim yaklaşımını içeren LeNet-5 mimarisini yayınlamışlardır. Literatürde farklı evrişimli sinir ağları mimarileri mevcuttur. En bilinenleri LeNet-5, AlexNet, GoogleNet, VGG-16, Res-Net ve Xception'dır.


Geleneksel CNN mimarisi evrişim (convolution) katmanı, ortaklama (pooling) katmanı ve tam bağlantı (fully connected) katmanına sahiptir. İsminden anlaşılacağı üzere CNN'in en önemli yapı taşı evrişim katmanıdır. Evrişim katmanı, görüntülerdeki öz nitelikleri farklı filtreler kullanarak belirlemeye çalışır. İlk evrişim katmanındaki nöronlar giriş katmanında verilen her piksel ile bağlantılı değildir. Sadece alıcı alanlardaki piksellere bağlıdır. İkinci katmandaki her bir nöron ise sadece birinci katmandaki küçük bir bölge ile bağlantılıdır. Bu yaklaşım tarzı, ağın öncelikle birinci katman üzerindeki alt seviyeli öz niteliklere odaklanmasını daha sonra mevcut olan katmanda daha yüksek seviyeli öz nitelikler halinde birleştirmesine izin verir. Bu hiyerarşik yapı, CNN'lerin görüntü tanımda yüksek başarımlerinin temel sebebidir. Evrişim katmanından sonra hesaplama maliyetini ve bellek kullanımını düşürmek ve aşırı öğrenme riskini azaltmak amacıyla boyut düşürme işlemini gerçekleştiren ortaklama katmanı vardır. Ortaklama

katmanının genel olarak üç türü vardır: maksimum ortaklama, ortalama ortaklama ve L2-norm ortaklamadır. Ortaklama katmanından sonra incelenen öz niteliklerin tek boyutlu bir vektör haline getirildiği düzleştirme (flatten) işlemi gelir. Bunun sebebi, tek boyutlu vektöre dönüşmüş olan girdinin yapay sinir ağına eklenecek olmasıdır. Bu aşamadan sonra tam bağlantı katmanı gelmektedir ve bu katman sınıflandırma işlemini gerçekleştirmek için kullanılır.


Bu çalışma kapsamında kullandığımız CNN modelinin mimarisi Şekil 2'de gösterilmiştir. Evrişim katmanlarında aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Ortaklama katmanlarında, maksimum ortaklama tercih edilmiştir. Modelimizde iki aşamada seyreltme (drop-out) katmanı kullanılmıştır. Bu sayede belirtilen orandaki girdiyi sıfıra eşitleyerek modelin veriye aşırı uyum sağlamasının (overfitting) önüne geçilmiştir. Görüntüleri altı galaksi sınıfına ayıracağımız için son katmanda softmax aktivasyon fonksiyonu kullanılmıştır.

3 Sonuçlar

Bu çalışmada CNN kullanılarak galaksiler sınıflandırılmıştır. GZ2 projesi kapsamında incelenen galaksilerin hem SDSS hem de DECaLS görüntüleri modelimizin eğitiminde kullanılmıştır. İki veri seti için de aynı CNN mimarisi kullanılmıştır. Bu şekilde farklı teleskoplarla gözlenen aynı galaksilerin model sonuçları üzerine etkileri incelenmiştir. SDSS verileri ile eğittiğimiz modelin doğruluk oranı %84 iken aynı galaksilerin DECaLS görüntülerini kullanarak eğittiğimiz modelin doğruluk oranında %87 olarak hesaplanmıştır. İncelenen sınıfların veri kümesi içerisinde dengeli bir şekilde dağıldıkları durumlarda sadece doğruluk metriği başarımleri ölçütü olarak rahatlıkla kullanılabilir. Bu çalışma kapsamında dengeli bir veri seti oluşturulmaya çalışıldı ancak kriterleri sağlayan etkileşen galaksi sayısı diğer sınıflara göre daha az kullanılabildi. Bu sebeple sadece doğruluk



Şekil 2. Çalışmada uygulanan evrişimli sinir ağının mimarisi.



Şekil 3. SDSS (sol) ve DECaLS (sağ) veri setleri için CNN modelinin karmaşıklık matrisi.

Çizelge 2. Bu çalışma kapsamında elde edilen model başarımları sonuçları.

Galaksi Morfolojisi	Kesinlik	Yakalama	F1-Skoru
Veri Seti: SDSS			
Pürüzsüz tam yuvarlak	0.80	0.92	0.85
Pürüzsüz tam yuvarlak olmayan	0.85	0.76	0.81
Pürüzsüz basık (puro şeklinde)	0.90	0.95	0.93
Çubuklu spiral	0.88	0.95	0.91
Çubuksuz spiral	0.89	0.78	0.83
Etkileşen	0.89	0.77	0.82
Veri Seti: DECaLS			
Pürüzsüz tam yuvarlak	0.84	0.92	0.88
Pürüzsüz tam yuvarlak olmayan	0.83	0.86	0.84
Pürüzsüz basık (puro şeklinde)	0.94	0.84	0.89
Çubuklu spiral	0.78	0.95	0.86
Çubuksuz spiral	0.83	0.65	0.73
Etkileşen	0.84	0.85	0.84

metriği değil, aynı zamanda kesinlik, yakalama ve F1 değeri gibi diğer başarı ölçüm metrikleri de dikkate alındı. Çizelge 2'de iki farklı veri seti için kullandığımız CNN modelimizin

sonuçları sunulmaktadır. Elde ettiğimiz sonuçlar ayrıca Şekil 3'te karmaşıklık matrisi olarak da sunulmaktadır.

Aynı CNN mimarisini kullanarak aynı galaksilerin farklı teleskop ve detektörler ile elde edilen görüntüleri sınıflandırılmış ve oldukça yakın sonuçlar elde edilmiştir. Her ne kadar ayna çapı olarak 2.5 m ile 4 m arasında çok büyük bir fark olmasa da, her iki tarama projesinin nihai görüntü çözünürlüğü birbirine çok yakındır. DECaLS görüntülerinin nihai görüntü kalitesi (ing. delivered image quality – DIQ) g , r ve z bantları için SDSS'e ait olan değerlere çok yakındır [Dey ve diğ. \(2019\)](#). Çalışmamız, benzer görüntü kalitesi söz konusu olduğunda, derin öğrenme ile benzer sonuçlara ulaşılabilirdiğini göstermektedir.

Kaynaklar

- Abdurro'uf ve diğ., 2022, [ApJS](#), 259, 35
 Baldry I. K., Glazebrook K., Brinkmann J., et al. 2004, [ApJ](#), 600, 681
 Blanton M. R., ve diğ., 2017, [AJ](#), 154, 28
 Bom C. R., ve diğ., 2021, [MNRAS](#), 507, 1937
 Butcher H., Oemler A. J., 1978, [ApJ](#), 226, 559
 Butcher H., Oemler A. J., 1984, [ApJ](#), 285, 426
 Cheng T.-Y., ve diğ., 2021, [MNRAS](#), 507, 4425
 Conselice C. J., 2006, [MNRAS](#), 373, 1389
 Dey A., ve diğ., 2019, [AJ](#), 157, 168

- Dieleman S., Willett K. W., Dambre J., 2015, *MNRAS*, 450, 1441
Domínguez Sánchez H., Huertas-Company M., Bernardi M., Tuccillo D., Fischer J. L., 2018, *MNRAS*, 476, 3661
Dressler A., 1980, *ApJ*, 236, 351
Ghosh A., Urry C. M., Wang Z., Schawinski K., Turp D., Powell M. C., 2020, *ApJ*, 895, 112
Goddard H., Shamir L., 2020, *ApJS*, 251, 28
Gunn J. E., ve diğ., 2006, *AJ*, 131, 2332
Hart R. E., ve diğ., 2016, *MNRAS*, 461, 3663
Hubble E. P., 1926, *ApJ*, 64, 321
Hubble E. P., 1936, *Realm of the Nebulae*. New Haven: Yale University Press
Huertas-Company M., ve diğ., 2015, *ApJS*, 221, 8
LeCun Y., Bottou L., Bengio Y., Haffner P., 1998, in *Proceedings of the IEEE*. pp 2278–2324, <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.42.7665>
Lintott C., ve diğ., 2011, *MNRAS*, 410, 166
Strateva I., ve diğ., 2001, *AJ*, 122, 1861
Tadaki K.-i., Iye M., Fukumoto H., Hayashi M., Rusu C. E., Shimakawa R., Tosaki T., 2020, *MNRAS*, 496, 4276
Varma S., ve diğ., 2022, *MNRAS*, 509, 2654
Vega-Ferrero J., ve diğ., 2021, *MNRAS*, 506, 1927
Walmsley M., ve diğ., 2022, *MNRAS*, 509, 3966
Willett K. W., ve diğ., 2013, *MNRAS*, 435, 2835
York D. G., ve diğ., 2000, *AJ*, 120, 1579

Access:

M23-0382: *Turkish J.A&A* — Vol.4, Issue 3.