



**MAKİNE ÖĞRENMESİ TEKNİKLERİ
KULLANILARAK DOĞU ANADOLU GÖZLEMEVİ
(DAG) ADAPTİF OPTİK SİSTEMİ İÇİN KONTROL
ALGORİTMASI GELİŞTİRİLMESİ**

Recep BALBAY

Danışman: Prof. Dr. Cahit YEŞİLYAPRAK
Doktora Tezi
Astronomi ve Astrofizik Ana Bilim Dalı
2025
(Her hakkı saklıdır.)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ASTRONOMİ VE ASTROFİZİK ANA BİLİM DALI

**MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANILARAK DOĞU ANADOLU
GÖZLEMEVİ (DAG) ADAPTİF OPTİK SİSTEMİ İÇİN KONTROL ALGORİTMASI
GELİŞTİRİLMESİ**

(Development of Control Algorithm For Eastern Anatolia Observatory (DAG) Adaptive Optic
System Using Machine Learning Techniques)

DOKTORA TEZİ

Recep BALBAY

Danışman: Prof. Dr. Cahit YEŞİLYAPRAK

Erzurum
Ocak, 2025

KABUL VE ONAY TUTANAĞI

Recep BALBAY tarafından hazırlanan “MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANILARAK DOĞU ANADOLU GÖZLEMEVİ (DAG) ADAPTİF OPTİK SİSTEMİ İÇİN KONTROL ALGORİTMASI GELİŞTİRİLMESİ” başlıklı çalışması 07/01/2025 tarihinde yapılan tez savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Astronomi ve Astrofizik Ana Bilim Dalında Doktora tezi olarak kabul edilmiştir.

Jüri Başkanı:	Prof.Dr. Ali GÜROL <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır
Danışman:	Prof.Dr. Cahit YEŞİLYAPRAK <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır
Jüri Üyesi:	Doç.Dr. Halim KOVACI <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır
Jüri Üyesi:	Prof.Dr. Tolga GÜVER <i>İstanbul Üniversitesi</i>	Aslı ıslak imzalıdır
Jüri Üyesi:	Prof.Dr. Kadri YAKUT <i>Ege Üniversitesi</i>	Aslı ıslak imzalıdır

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Prof. Dr. Alper NUHOĞLU
Enstitü Müdürü

- Bu çalışma T.C. Strateji ve Bütçe Başkanlığı destekli, Doğu Anadolu Gözlemevi (DAG - Proje No: 2011K120230) ve DAG Odak Düzlem Aygıtları ve Adaptif Optik Sistemi (ODA - ODA Proje No: 2016K121140) projeleri kapsamında desteklenmiştir.

- Tez süresi dahilinde aşağıda listelenen makale Q2 sınıfındaki dergide yayınlanmıştır:

1) Balbay, R., Kaba, K., Fişek, S., Yeşilyaprak, C. (2024). Evaluation of PWV products derived from satellite-based and radiosonde retrievals for the eastern anatolia observatory (DAG). *Experimental Astronomy*, 58(1), 2.

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildiriş, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Doktora Tezi olarak Prof.Dr. Cahit YEŞİLYAPRAK danışmanlığında sunulan “MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANILARAK DOĞU ANADOLU GÖZLEMEVİ (DAG) ADAPTİF OPTİK SİSTEMİ İÇİN KONTROL ALGORİTMASI GELİŞTİRİLMESİ” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	0	30
Kuramsal Temeller	6	30
Materyal ve Metot	1	35
Araştırma Bulguları ve Tartışma	2	20
Sonuçlar	0	20
Tezin Geneli	6	25

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5’den büyük olmaması gerekir.

Beyan edilen bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ve beyan ederiz.

Tez Yazarı (Öğrenci)	Tez Danışmanı
Recep BALBAY	Prof. Dr. Cahit YEŞİLYAPRAK
07/01/2025	07/01/2025
İmza: Aslı ıslak imzalıdır	İmza: Aslı ıslak imzalıdır

* Tez ile ilgili YÖKTEZ’de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

☐ Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi sebebiyle Enstitü Yönetim Kurulunun/....../.... tarih ve sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

☐ Enstitü Yönetim Kurulunun/....../.... tarih ve sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

TEŞEKKÜR

Doktora tezim boyunca bana rehberlik eden, destek olan ve yanımda bulunan kişilere minnettarlığımı sunmak istiyorum.

Öncelikle, tez çalışmamın her aşamasında bana değerli fikirleri ve yönlendirmeleriyle destek veren danışmanım Sayın Prof. Dr. Cahit YEŞİLYAPRAK'a en içten teşekkürlerimi sunarım.

Bu zorlu süreçte sevgisi, sabrı ve desteğiyle her zaman yanımda olan eşime, hayatımın neşesi olan kızıma ve bana daima inanan aileme en derin minnetlerimi sunuyorum.

Ayrıca, araştırmalarım sırasında fikir alışverişinde bulunduğum ve beni daima motive eden Dr. Öğr. Üyesi Kazım KABA'ya, Dr. Cihan Tuğrul TEZCAN'a ve Araş. Gör. Dr. Süleyman FİŞEK'e teşekkür ederim. Bilimsel tartışmalar ve paylaşımlarımız, bu çalışmanın gelişmesine büyük katkı sağladı.

Son olarak, bu tezi hazırlarken yararlandığım kaynakları ve olanakları sağlayan Atatürk Üniversitesine ve parçası olmaktan hep gurur duyacağım Türkiye Ulusal Gözlemevleri ATASAM-DAG'a ve personeline çok teşekkür ederim.

Bu tez çalışması T.C. Strateji ve Bütçe Başkanlığı destekli, Doğu Anadolu Gözlemevi (DAG - Proje No: 2011K120230) ve DAG Odak Düzlem Aygıtları ve Adaptif Optik Sistemi (ODA - ODA Proje No: 2016K121140) projeleri kapsamında desteklenmiştir.

Recep BALBAY

ÖZET

DOKTORA TEZİ

MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANILARAK DOĞU ANADOLU GÖZLEMEVİ (DAG) ADAPTİF OPTİK SİSTEMİ İÇİN KONTROL ALGORİTMASI GELİŞTİRİLMESİ

Recep BALBAY

Danışman: Prof. Dr. Cahit YEŞİLYAPRAK

Amaç: Astronomik gözlemler sırasındaki atmosferik etkiler, gözlem kalitesini ciddi şekilde etkilemektedir. Dünya atmosferi, ışığın teleskopa ulaşmadan önce çeşitli türbülanslar ve hava dalgalanmaları nedeniyle kırılmasına neden olur. Atmosferin bozucu etkilerinin tamamını olmasa da bir kısmını ortadan kaldırılması için Adaptif (uyarlanabilir) Optik (AO) yöntemi yaygın olarak kullanılmaktadır. Bu tür sistemler atmosferik türbülansın neden olduğu görüntü bozulmalarını yeterli düzeyde düzeltebilir ve böylece teleskoplar ile daha net ve ayrıntılı gözlemler yapılabilir. Bu tez çalışmada, Doğu Anadolu Gözlemevi (DAG) 4m teleskopu için tasarlanan adaptif optik sistemine yönelik olarak makine öğrenimi (ML) ve derin öğrenme (DL) teknikleri ile model tabanlı algoritma geliştirme çalışmaları yapılmıştır.

Yöntem: Tez kapsamında, simülasyonda kullanılan meteorolojik ve atmosferik girdi parametrelerinden (rüzgâr, sıcaklık, nem, seeing vb.), makine öğrenmesi yöntemleri (random forest) ile model eğitimi yapılmıştır. Eğitilen modelin adaptif optik sisteminin performansını ölçmeye yarayan “Strehl oranı” değerini tahmin etmesi sağlanmıştır. DAG 4m teleskopuna özgün olarak geliştirilen derin öğrenme modelleri, dalga cephesi verilerini analiz etmek ve hataları düzeltmek için kullanılmıştır. DAG 4m teleskobunun AO sistemi için bir simülasyon ortamı geliştirilmesi, sistemin performansını analiz etmek ve optimize etmek açısından kritik öneme sahiptir. Simülasyon, hem teorik modellemeler hem de gerçek veri setleri kullanılarak AO sisteminin performansını değerlendirmeyi ve iyileştirmeyi amaçlamaktadır. UNET modeli, özellikle görüntü segmentasyonu ve çeşitli diğer bilgisayarla görme görevlerinde kullanılan bir derin öğrenme mimarisidir. Elde edilen sentetik veri seti, UNET modeli ile dalga cephesi rekonstrüksiyonu yapmak için kullanılmıştır.

Bulgular: Bulgular kısmında sunulan veriler incelendiğinde en uzun süren derin Öğrenme modelinin, Gerchberg-Saxton algoritmasına göre yaklaşık 2.8 kat daha hızlı olduğu gözlenmiştir. Medyan değerlerde ise bu farkın 4,9 sn ve oranın yaklaşık 3 kat olduğu görülmektedir. Derin öğrenme modeli tahminlerinin büyük bir kısmının (~%98) tahmin hata aralığı -0.001 nm ile 0.001 nm arasında dağılım sergilemiştir.

Sonuç: Sonuç olarak, bu tez çalışması, DAG AO sistemi için makine öğrenimi ve derin öğrenme tekniklerinin uygulanabilirliğini göstermiş ve bu tekniklerin AO sistemlerinin performansını optimize etmek için kullanılabileceğini ortaya koymuştur. Geliştirilen model ve yazılım, DAG 4m teleskopunun AO sisteminin daha iyi anlaşılmasını, optimize edilmesini ve verilen projelerin başarısını ölçmeye ve dolayısıyla genel olarak verimliliği artırmaya sağlayacak önemli araç olarak görülmektedir.

Anahtar Kelimeler: Adaptif optik, Derin öğrenme, Model tabanlı kontrol, Doğu Anadolu Gözlemevi, DAG.

Ocak 2025, 98 sayfa

ABSTRACT

DOCTORAL DISSERTATION

DEVELOPMENT OF CONTROL ALGORITHM FOR EASTERN ANATOLIA OBSERVATORY (DAG) ADAPTIVE OPTIC SYSTEM USING MACHINE LEARNING TECHNIQUES

Recep BALBAY

Supervisor: Prof. Dr. Cahit YEŞİLYAPRAK

Purpose: Atmospheric effects during astronomical observations significantly affect observation quality. The Earth's atmosphere causes the refraction of light due to various turbulences and air fluctuations before it reaches the telescope. Although it is not possible to completely eliminate the atmospheric distortions, Adaptive Optics (AO) is a commonly used method to correct some of these effects. Such systems can adequately correct the image distortions caused by atmospheric turbulence, allowing for clearer and more detailed observations with telescopes. In this thesis, machine learning (ML) and deep learning (DL) techniques were applied to develop a model-based algorithm for the adaptive optics system designed for the Eastern Anatolia Observatory (DAG) 4m telescope.

Method: In the scope of the thesis, model training was conducted using machine learning methods (random forest) on meteorological and atmospheric input parameters (e.g., wind, temperature, humidity, seeing) used in the simulation. The trained model was employed to predict the "Strehl ratio," which is used to measure the performance of the adaptive optics system. Deep learning models, specifically developed for the DAG 4m telescope, were used to analyse wavefront data and correct errors. Developing a simulation environment for the AO system of the DAG 4m telescope is critical for analysing and optimizing the system's performance. The simulation aims to evaluate and improve the AO system's performance by using both theoretical modelling and real datasets. The UNET model, a deep learning architecture commonly used for image segmentation and various other computer vision tasks, was employed for wavefront reconstruction using the synthetic dataset obtained.

Findings: The findings revealed that the deep learning model, which had the longest runtime, was approximately 2.8 times faster than the Gerchberg-Saxton algorithm. In median values, this difference was observed as 4.9 seconds, and the ratio was approximately 3 times. A significant portion of the deep learning model's predictions (~98%) exhibited a prediction error range between -0.001 nm and 0.001 nm.

Results: In conclusion, this thesis demonstrated the feasibility of applying machine learning and deep learning techniques for the DAG AO system and showed that these techniques can be used to optimize the performance of AO systems. The developed model and software are considered essential tools for better understanding, optimizing, and measuring the success of projects related to the AO system of the DAG 4m telescope, thereby increasing overall efficiency.

Keywords: Adaptive optics, Deep Learning, model-based control, Eastern Anatolia Observatory, DAG

January 2025, 98 pages

İÇİNDEKİLER

KABUL VE ONAY TUTANAĞI.....	i
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
TABLolar DİZİNİ.....	ix
ŞEKİLLER DİZİNİ	x
KISALTMALAR VE SİMGELER DİZİNİ	xiv
GİRİŞ.....	1
KURAMSAL TEMELLER.....	4
Astronomik Gözlem ve Teleskoplar	4
Teleskoplarda Görüntü Oluşumu	5
Ritchey-Chrétien Teleskop (RC) Ayna Tasarımı ve Özellikleri.....	7
Odak düzlemi	9
Nokta dağılım fonksiyonu.....	11
Teleskoplarda Görüntü Oluşumuna Etki Eden Faktörler.....	11
Kırınım etkisi	11
Airy diski.....	12
Optik sistemlerdeki aberasyonlar.....	12
Odak dışılık	13
Astigmatizm	13
Küresel aberasyon	14
Koma aberasyonu.....	14
Alan eğriliği	14
Distorsiyon	14
Aberasyonların modellenmesi.....	15
Odak dışılık ve Zernike Polinomu Z ₂₀	16
Astigmatizm ve Zernike polinomu Z ₃₋₁ ve Z ₃₁ ().....	17
Küresel aberasyon ve Zernike polinomu Z ₄₀	17
Koma ve Zernike polinomu Z ₃₀	18
Atmosferik Türbülans ve Gözlemler Üzerindeki Etkileri.....	18

Atmosferi oluşturan parçacık ve bileşiklerin gözlemlere etkisi	19
Türbülans etkisinin giderilmesi ve adaptif optik sistemler	20
Faz Bilgisinin Alınması	21
Faz çeşitliliği	22
Performans Metrikleri ve Strehl oranı	22
Gerchberg-Saxton algoritması	23
Makine öğrenmesi.....	23
Denetimli öğrenme.....	24
Denetimsiz öğrenme	24
Pekiştirmeli öğrenme	24
Derin öğrenme.....	24
Yapay Sinir Ağları	25
Konvolüsyonel sinir ağları	26
Tekrarlayan sinir ağları	27
Derin takviyeli öğrenme.....	27
Derin öğrenme yöntemleri ile dalga cephesi ölçümü.....	27
Faz çeşitliliği ve derin öğrenme uygulamaları	29
MATERYAL ve METOT	30
Materyal	30
Veriler ve ölçümler	30
DAG-MAM sistemi	31
Meteorolojik ölçümler.....	31
Astronomik görüş ölçümleri	31
Su buharı ölçümleri	32
DAG adaptif optik sistemi (TROIA)	32
Metot	35
DAG 4m teleskopu adaptif optik sistemi simülasyonu.....	35
Simülasyonda kullanılan kütüphaneler	36
Simülasyon veri yapısı	37
Simülasyon gerçekleştirim süreci ve analizler	38
Simülasyonda kullanılan platformlar ve algoritmalar	38
Rastgele orman yöntemi ile parametre tahmini	39
Rastgele orman algoritması.....	39
Simülasyon çıktıları ve verilerin saklanması	42
Derin öğrenme model eğitimi hazırlığı ve görüntüleri biçimi	42

Model eğitimi için veri setinin hazırlanması.....	43
UNET modelinin derin öğrenme tabanlı dalga cephesi rekonstrüksiyonu için kullanımı	45
Kodlayıcı (Encoder / daralan yol)	46
Kod çözücü (genişleyen yol).....	46
Köprü (Bridge).....	46
Atlamalı bağlantılar.....	46
ARAŞTIRMA BULGULARI ve TARTIŞMA	48
DAG AO Simülasyonu ve Bileşenleri	48
Derin öğrenme model eğitimi süreci.....	53
İstatistiksel Karşılaştırma ve Yorumlama	69
SONUÇLAR ve ÖNERİLER	74
KAYNAKLAR.....	76
EKLER	81
EK-1. Yayın: Experimental Astronomy, 58(1), 2. 29 Temmuz 2024.....	81
ÖZGEÇMİŞ.....	82

TABLÖLAR DİZİNİ

Tablo 1. DAG 4m Teleskopunun Teknik Özellikleri	6
Tablo 2. MAM ve MGM İstasyonunda İşletilen Cihazların Teknik Özellikleri	31
Tablo 3. DAG AO Simülasyonun Kullanılan Parametreler	37
Tablo 4. Geliştirme ve Test Ortamı Teknik Özellikleri.....	38
Tablo 5. Gerchberg-Saxton Algoritması ve DL Modeline Ait İstatistik Tablosu.....	69
Tablo 6. GS Algoritması ve DL Modeline Ait İstatistik Tablosu.....	70



ŞEKİLLER DİZİNİ

Şekil 1. DAG 4 metre teleskopu.....	1
Şekil 2. DAG 4m teleskopu aynası optik şematiği.....	8
Şekil 3. DAG 4m teleskopu aynası açılışı.....	9
Şekil 4. DAG 4m teleskopu genel tasarımı	10
Şekil 5. DAG 4m Teleskopu ve iki adet Nasmyth Odakları (dikdörtgenler) ile aktif optik sistemi (elips) gösterilmektedir.	11
Şekil 6. Simülasyonda üretilmiş Airy diski ve airy desenleri	12
Şekil 7. Distorsiyonsuz (düz) alan (solda), varil bozulması (ortada) ve iğne yastığı bozulması (sağda).....	15
Şekil 8. Simülasyondan ilk 10 optik aberasyonun 2 boyutlu gösterimi	16
Şekil 9. Odak dışılık (defocus) aberasyonunun 2 boyutlu (solda) ve 3 boyutlu gösterimi (sağda)	17
Şekil 10. Astigmat aberasyonunun 2 boyutlu (solda) ve 3 boyutlu gösterimi (sağda).....	17
Şekil 11. Küresel aberasyonunun 2 boyutlu (solda) ve 3 boyutlu gösterimi (sağda).....	18
Şekil 12. Koma aberasyonunun 2 boyutlu (solda) ve 3 boyutlu gösterimi (sağda).....	18
Şekil 13. 500 nm – 3000 nm arasında kalan (VIS + SWIR) bölgedeki atmosferik PWV geçirgenliğinin PSG aracı kullanılarak üretilmiş spektrum grafiği.....	19
Şekil 14. ESO VLT Teleskopundan alınmış Neptün görüntüleri.....	20
Şekil 15. Adaptif Optik sistemi konsept gösterimi	21
Şekil 16. Biyolojik nöron modeli (a) ve basit bir sinir ağı modeli (b)	26
Şekil 17. Konvolüsyonel süreç.....	27
Şekil 18. Dalga cephesi ölçmeye yönelik geliştirilmiş konvolüsyonel sinir ağları mimarisi.....	28
Şekil 19. DAG yerleşkesinde farklı konumlarda kurulmuş DAG-MAM sistemi istasyonları.....	32
Şekil 20. TROIA 3-boyutlu gösterimi	33
Şekil 21. Optik test masası üzerinde kurulmuş TROIA sistemi görüntüsü.....	34
Şekil 22. Geliştirilen “DAG AO ML Simülasyonu ve Analizi” simülasyonun görsel arayüzü.	36
Şekil 23. Rastgele Orman Algoritmasının DAG simülasyonuna göre, “Strehl oranı” parametresi için oluşan ağaç yapısının görüntüsü	41

Şekil 24. DAG AO parametrelerine göre faz haritası (solda), odak içi (ortada) ve odak dışı (sağda) 2 boyutlu gösterimleri	43
Şekil 25. Simülasyondan üretilen faz haritasının (solda), odak-ıç i (ortada) ve odak-dış ı (solda) görüntülerin PSF'lerinin 3-boyutlu olarak gösterimi	43
Şekil 26. UNET mimarisinin gösterimi (Ronneberger 2015)	45
Şekil 27. UNET mimarisinde WFS için tanımlama için oluşan özellik (ing. feature) haritaları.....	47
Şekil 28. Yüklenicinin teslim ettiğ i (solda) ve doktora tezi kapsamında oluşturulan simülasyon (sağda) sonuçlarının (strehl oranına karş ılık yıldız parlaklığ ı) kıyaslaması.	48
Şekil 29. DAG AO simülasyonunun grafiksel kullanıcı ara yüzü (GUI).....	49
Şekil 30. Türbölans etkisine maruz kalmamış ancak DAG sistemsel etkilerinin (teleskop tutucu kolları – spider) göröllebileceğ i sentetik PSF gösterimi (solda) ve belirlenen parametrelere veya yerleşkeden alınan anlık ölçümlere göre değ iş im sergileyen (temsili) türbölans gösterimi (sağda)	50
Şekil 31. DAG 4m teleskop M1 ve M2 aynalarının gösterimleri (solda) ve DAG AO sisteminde yer alan DM aynanın üzerinde oluşan türbölanslı dalga cephelerine karş ılık gelen DM aynanın yüzey şeklinin gösterim (sağda).....	51
Şekil 32. Piramit lensten dalga cephesi ölçerine (WFS) düş en türbölanslı ış ınlar (solda) ve adaptif optik sistemi kapalı iken bilimsel kameraya (DIRAC) düş en yapay yıldız ış ığ ı (sağda)	51
Şekil 33. DAG AO simülasyonunun “DL Wavefront Analizi” sekmesinde yer alan, odaklanmış dalga cephesi görüntüsü (solda) ve aynı sekmede yer alan odak dış ı dalga cephesi görüntüsü (sağda).....	52
Şekil 34. DAG AO simülasyonunun “DL Wavefront Analizi” sekmesinde yer alan dalga cephesine ait faz haritası (solda) ve derin öğrenme modeli kullanılarak “tahmin” edilmiş dalga cephesine ait faz haritası (sağda).....	52
Şekil 35. DAG AO simülasyonunun “DL Wavefront Analizi” sekmesinde yer alan dalga (farklı) cephelerine ait orijinal ve tahmin edilen dalga cephelerinin farklarının 3 boyutlu gösterimleri.....	53
Şekil 36. Derin öğrenme eğitim sürecinde modelin eğitim ve doğrulama kayıplarının (metriklerinin) izlenmesini sağ layan grafiksel gösterim	54
Şekil 37. Derin öğrenme eğitim sürecinde modelin öğrenme ve doğrulama hassasiyetine ait metriklerin izlenmesini sağ layan grafiksel gösterim	55

Şekil 38. DAG AO Simülasyonunun “DL Wavefront Analizi” sekmesinde seçili (psf_0.fits) bir verinin 2 boyutlu gösterimi	56
Şekil 39. DAG AO Simülasyonunun “DL Wavefront Analizi” sekmesinde seçili (psf_0.fits) bir verinin 3 boyutlu gösterimi	56
Şekil 40. DAG AO Simülasyonunun “DL WF Zernike Analizi” sekmesinde seçili (psf_0.fits) bir verinin Zernike katsayılarının nm biriminden farkına (altta) dair gösterim	57
Şekil 41. DAG AO Simülasyonunun “DL WF Zernike Analizi” sekmesinde seçili (psf_34.fits) bir verinin Zernike katsayılarının nm biriminden farkına (altta) dair gösterim	57
Şekil 42. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 1. Zernike hata (sapma) miktarı histogramı	58
Şekil 43. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 2. Zernike hata (sapma) miktarı histogramı	58
Şekil 44. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 3. Zernike hata (sapma) miktarı histogramı	59
Şekil 45. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 4. Zernike hata (sapma) miktarı histogramı	59
Şekil 46. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 5. Zernike hata (sapma) miktarı histogramı	60
Şekil 47. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 6. Zernike hata (sapma) miktarı histogramı	60
Şekil 48. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 7. Zernike hata (sapma) miktarı histogramı	61
Şekil 49. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 9. Zernike hata (sapma) miktarı histogramı	61
Şekil 50. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 10. Zernike hata (sapma) miktarı histogramı	62
Şekil 51. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 12. Zernike hata (sapma) miktarı histogramı	62
Şekil 52. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 11. Zernike hata (sapma) miktarı histogramı	63
Şekil 53. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 13. Zernike hata (sapma) miktarı histogramı	63

Şekil 54. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği	
14. Zernike hata (sapma) miktarı histogramı	64
Şekil 55. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği	
15. Zernike hata (sapma) miktarı histogramı	64
Şekil 56. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği	
16. Zernike hata (sapma) miktarı histogramı	65
Şekil 57. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği	
17. Zernike hata (sapma) miktarı histogramı	65
Şekil 58. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği	
18. Zernike hata (sapma) miktarı histogramı	66
Şekil 59. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği	
19. Zernike hata (sapma) miktarı histogramı	66
Şekil 60. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği	
20. Zernike hata (sapma) miktarı histogramı	67
Şekil 61. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği	
21. Zernike hata (sapma) miktarı histogramı	67
Şekil 62. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği	
22. Zernike hata (sapma) miktarı histogramı	68
Şekil 63. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin edilen	
hata miktarlarının ortalamaları ve medyan değerlerinin histogramı	68
Şekil 64. Gerchberg-Saxton algoritmasının 100 tekrarda ölçülen zaman serisi grafiği.....	72
Şekil 65. Derin Öğrenme algoritmasının 100 tekrarda ölçülen zaman serisi grafiği	73

KISALTMALAR VE SİMGELER DİZİNİ

ADAM	: Adaptive Moment Estimation
aO	: Active optic
AO	: Adaptive Optic
CCD	: Charge Coupled Device
CMOS	: Complementary Metal Oxide Semiconductor
CNN	: Convulational Neural Networks
CPU	: Central Processing Unit
DAG	: Doğu Anadolu Gözlemevi
DIRAC	: DAG Infrared Camera
DL	: Deep Learning
DM	: Deformable Mirror
ESO	: European Southern Observatory
GPU	: Graphics Processing Unit
GRU	: Gated Recurrent Units
LSTM	: Long Short-Term Memory
ML	: Machine Learning
NIR	: Near-Infrared
PSF	: Point Spread Function
RAM	: Random Access Memory
RC	: Ritchey-Chrétien
RNN	: Recurrent Neural Network
SLM	: Spatial Light Modulation
SSD	: Solid-State Drive
SWIR	: Short-Wave Infrared
TROIA	: TuRkish adaptive Optics for Infrared Astronomy
TTM	: Tip-Tilt Mirror
VLT	: Very Large Telescope
WFS	: Wavefront Sensor
θ	: Theta işareti. Açısal çözünürlüğü (yay-saniye biriminde) temsil etmektedir
λ	: Lambda işareti. Dalga boyunu (genel olarak nm biriminde) temsil etmektedir.

GİRİŞ

Bu tez çalışmasında, makine öğrenmesi yöntemleri kullanılarak Türkiye Ulusal Gözlemevleri ATASAM-DAG (Doğu Anadolu Gözlemevi) 4m Teleskopu Adaptif Optik (AO) sistemi için model tabanlı kontrol algoritması ve yazılım geliştirilmesi üzerine odaklanılmıştır.

DAG, Türkiye'nin en büyük ayna çapına (4 metre), ilk kırmızı ötesi (IR) sensör sistemine ve gelişmiş (aktif optik-aO, Adaptif Optik-AO, SLM Koronograf vb.) teleskop sistemine sahip gözlemevi olup, yüksek ve hassas çözünürlüklü astronomik gözlemler için adaptif optik sistemleri kullanmaktadır (Yeşilyaprak 2022). Şekil 1'de DAG 4m teleskopunun kubbe içerisinden alınmış bir fotoğrafı gösterilmektedir.



Şekil 1. DAG 4 metre teleskopu

Bu doktora tez çalışmasında irdelenen problemin niteliği, DAG' 4m teleskopundaki adaptif optik sistemlerin yazılımsal geliştirmeler ve mevcut donanımlar kullanılarak performansını nasıl arttırılabileceğinin araştırılmasıdır. Böyle bir performans arayışı ile DAG 4m teleskopundan elde edilen gözlemlerin kalitesinin, etkinliğinin ve verimliliğinin artmasını hedeflenmektedir.

Adaptif optik (ing. adaptive optics) sistemler, atmosferik türbülans gibi optik bozulmaların düzeltilmesinde önemli bir rol oynamaktadır. Atmosferik türbülans, astronomik cisimlerin ışığının yer yüzeyine ulaşırken kırılmasına ve bozulmasına neden olur. Bu sebeple astronomik gözlemlerin netliğini ve doğruluğunu önemli ölçüde etkiler (Sterken 1992; Quirrenbach 2004). Adaptif optik sistemler, bu bozulmaları düzeltmek için belirli algoritmalar kullanır ancak bu algoritmalar, atmosferik türbülansın dinamik ve karmaşık doğası karşısında bazı durumlarda yetersiz kalmaktadırlar (Hickson 2014; Guyon 2018). Bu nedenle, daha etkili ve hızlı yanıt verebilen yeni nesil algoritmaların geliştirilmesi gerekmektedir.

Literatür incelendiğinde, makine öğrenmesi tekniklerinin adaptif optik sistemlerde kullanımının henüz yeterince araştırılmadığı ve bu alanda önemli bir boşluk olduğu görülmektedir.

Makine öğrenmesi, özellikle derin öğrenme ve yapay sinir ağları, karmaşık veri desenlerini tanıma ve tahmin etme yetenekleri ile bilinmektedir (Shinde 2018). Bu teknikler, atmosferik türbülansın dinamiklerini modellemede ve öngörmede önemli bir potansiyele sahiptir (Vorontsov 2020; Bolbasova 2021). Ancak, adaptif optik sistemlerde bu tekniklerin uygulanabilirliği konusunda daha fazla araştırma yapılması gerekmektedir (Fowler 2023).

Bu çalışma, adaptif optik sistemler için makine öğrenmesi tabanlı kontrol algoritmalarının geliştirilmesi ve uygulanması konusunda literatüre ve aynı zamanda DAG sistemlerine verimlilik açısından katkı sağlamayı hedeflemektedir.

Bu kapsamda tezin çıktısı, mevcut yöntemlere kıyasla daha hızlı ve daha hassas düzeltmeler sunabilen yeni bir kontrol algoritması ve yazılımı geliştirmek ve dolayısıyla gözlem kalitesini artırmayı amaçlamaktadır. Çalışmamız, makine öğrenmesi tekniklerinin adaptif optik sistemlerde etkin bir şekilde kullanılabileceğini göstererek, bu alandaki literatüre önemli bir katkı sağlayacaktır.

Bu tez çalışmasında, adaptif optik sistemlerde makine öğrenmesi yöntemleri kullanarak atmosferik ve astronomik girdi parametrelerinin çıktı parametreleri ile olan bağıntılarının ortaya konması ve dalga cephesi sensörlerinden ölçülen değerlerin derin öğrenme algoritmaları

ile eğitilerek, dalga cephelerinin model tabanlı karakteristiğinin ortaya konması amaçlanmaktadır.

Bu tez kapsamında eğitilmiş derin öğrenme modellerinin, teleskop sistemlerinde kullanılmakta olan kontrol algoritmaları simülasyonları ile kıyaslanması yapılarak performans karşılaştırması yapılmıştır.

Bu tez kapsamında eğitilen model ve geliştirilen simülasyon yazılımı sayesinde:

- 1) Simülasyondan ve yazılım aracılığıyla elde edilen sonuçlar, potansiyel projelerin başarısını önceden tahmin etmek için kullanılabilir. Örneğin, DAG 4m Teleskop AO sisteminin farklı atmosferik koşullar altında nasıl performans göstereceğini anlamak için yazılım üzerinden araştırmalar yapılabilir.
- 2) Modelin tahmin yetenekleri, DAG 4m Teleskop AO sisteminin performansını optimize etmek için kullanılabilir ve böylece daha iyi gözlem sonuçları elde edilmesine katkıda bulunabilir.
- 3) Geliştirilen hem model hem de yazılım, sadece mevcut DAG 4m Teleskop AO sistemi için değil, aynı zamanda diğer gözlemevleri için de uyarlanabilir bir sistemdir.
- 4) Simülasyon ve yazılım aracılığıyla DAG 4m teleskopu üzerine çalışmak isteyen araştırmacılara, gözlemevi personeline ve öğrencilere test ortamı sağlanabilir.
- 5) Adaptif optik sistemlerde en çok zaman alan dalga cephelerinin ölçülmesi ve hesaplanması süresi dramatik olarak azaltılabilir.
- 6) Konvansiyonel yöntemlere göre ölçülen (hesaplanan) dalga cephelerinin daha yüksek doğrulukla tahmin edilebilir.
- 7) Teleskop kontrol sisteminde kullanılan donanımların teknik kapasite gereksinimleri azalacak veya aynı kapasiteye sahip sistemler kullanılarak daha hızlı sonuçlar alınabilir.
- 8) Azalan gereksinimler ile bütçe maliyetleri ve sistemin enerji tüketiminin de azalacağı öngörülmektedir.

KURAMSAL TEMELLER

Astronomik Gözlem ve Teleskoplar

Modern teleskoplar, gök cisimlerini gözlemlemek için kullanılan karmaşık sistemlerdir. Bu sistemler, ışığı toplayarak ve sonrasında bir noktaya odaklayarak gök cisimlerinin detaylı görüntülenmesini sağlar. Teleskoplarla yapılan gözlemler, uzay araştırmalarında ve evreni anlamada oldukça önemli bulgular sunmaktadır. Atmosferin gözlemlerdeki bozucu etkisinden dolayı teleskoplar çoğu zaman yüksek rakımlı yerlere kurulmaktadır veya uzayda konumlandırılmaktadır.

Atmosferin bozucu etkilerinin tamamını olmasa da önemli bir kısmını ortadan kaldırmak için Adaptif (uyarlanabilir) Optik (kısaca AO) yöntemi modern teleskoplarda yaygın olarak kullanılmaktadır. Adaptif optik, teleskoplarla yapılan gözlemlerin kalitesini artırmak için geliştirilmiştir. Bu tür sistemler atmosferik türbülansın neden olduğu görüntü bozulmalarını yeterli düzeyde düzeltebilir ve böylece teleskoplar ile daha detaylı gözlemler yapılabilmektedir (Davies 2012).

Dünya atmosferi, zararlı kozmik ışınları ve güneşten gelen ultraviyole ışınları süzerek dünya üzerindeki yaşamı korur. Ancak, atmosferik türbülans teleskoplarla yapılan gözlemlerin kalitesine olumsuz etkiler.

Atmosferik türbülans, atmosferdeki hava tabakalarının sürekli hareketi ve karışımı sonucu oluşan düzensiz hava akımlarıdır. Türbülans, astronomik cisimlerden gelen ışığın atmosferden geçerken kırılmasına, sapmasına ve soğrulmasına neden olur (Travouillon 2003). Türbülansın oluşturduğu bu bozulmalar, cisimlerin ışığının yolunu değiştirir ve teleskopların topladığı görüntülerin bulanıklaşmasına neden olur. Bu durum, astronomik gözlemlerin netliğini ve detayları önemli ölçüde azaltır.

Dünya atmosferi, farklı katmanlarda farklı yoğunluklara sahiptir (Laj 2009). Işık, atmosferdeki bu yoğunluk farklılıkları sebebiyle kırılır ve sapar. Bu kırılma, yıldızların ve diğer gök cisimlerinin gerçek konumlarından farklı yerlerde görülmesine neden olur. Aslında bu sebeple geceleri gökyüzüne baktığımızda yıldızları kırıpşıyor gibi görürüz. Ayrıca, atmosferde bulunan parçacıklar, yoğunlaşabilir su buharı (ing. precipitable water vapor – PWV), karbon dioksit (CO₂) ve diğer gazlar, belirli dalga boylarında ışığı soğurur ve zayıflatır (Özdemir 2018; Balbay 2024). Bu soğurma, özellikle kırmızı ötesi ve morötesi dalga boylarında yapılan gözlemleri oldukça zorlaştırmaktadır.

Teleskoplarda Görüntü Oluşumu

Teleskoplar, gök cisimlerinden gelen ışığı bir noktaya odaklayarak görüntü oluşturur. İki temel optik teleskop türü vardır. Bunlar *Mercekli* teleskoplar ve *Yansıtıcı (Aynalı)* teleskoplar olarak sınıflandırılır. Mercekli teleskoplar, ışığı genellikle camdan imal edilmiş merceklerle odaklar iken aynalı teleskoplar ise ışığı aynalar veya özel olarak üretilmiş yansıtıcı yüzeyler kullanarak odaklar. Günümüzde modern ve profesyonel teleskoplar yansıtıcı yapıda tasarlanmaktadır.

Görüntü oluşumu ile ilgili önemli kavramların başında teleskop optik bileşenlerinin birbirlerine ile ilişkili olan temel parametreleri gelmektedir. Bunlardan ilki odak uzaklığıdır. Odak uzaklığı, bir optik sistemin merceği ya da aynasının, paralel gelen ışınları topladığı nokta ile optik eleman arasındaki mesafedir. Bu mesafe, optik sistemin ışığı nasıl topladığını ve odakladığını belirler. Kısa odak uzaklığı, geniş bir görüş alanı sağlarken, uzun odak uzaklığı dar bir görüş alanı sunar.

Görüntü oluşumu ile ilgili diğer önemli bir parametre ise ayırma (çözünürlük) gücüdür. Ayırma gücü (ing. resolving power), bir optik sistemin iki yakın nesneyi ayrı ayrı görme yeteneğini tanımlayan temel bir performans ölçütüdür (Bowen 1967). Bu ifade bir teleskopun gökyüzündeki iki yıldız gibi birbirine çok yakın iki ışık kaynağını ayırt edebilme kabiliyetini tanımlar. Ayırma gücü, genellikle optik sistemin çapı (açıklık) ile ilişkilidir; daha büyük bir açıklık, daha yüksek bir çözünürlük gücü sağlar, bu da daha ince detayların gözlemlenmesine olanak tanır.

Ayırma gücü, *Rayleigh kriteri* ile tanımlanır ve bu kritere göre iki nesne, aralarındaki açısal mesafe sistemin minimum çözünürlük limitinin altına indiğinde birbirinden ayırt edilemez hale gelir. Bu kavram, yıldızların ve öte gezegenlerin ince ayrıntılarını veya galaksileri detaylı incelemek için oldukça önemlidir. Denklem 1’de *Rayleigh kriteri* verilmiştir.

$$\theta = 1.22 \frac{\lambda}{D} \quad (1)$$

Denklem 1’de, λ gözlenen ışığın dalga boyunu ve D ise teleskopun açıklığını (ing. aperture) ifade etmektedir. θ radyan biriminde λ ve teleskop açıklığı metre biriminde ifade edilir. DAG 4m teleskopu ayırma gücü ($\lambda = 600\text{nm}$) **0.0383”** olarak hesaplanmıştır.

Açıklık, optik sistemlerin performansını belirleyen en önemli faktördür. Açıklık, bir teleskopun veya merceğin önündeki açık alanın çapını ifade eder. Optik sistemin açıklığı ne kadar büyükse, o kadar fazla ışık toplama kapasitesine sahip olur. Bu, özellikle zayıf ışıklı gök cisimlerinin gözlemlenmesinde kritik bir rol oynamaktadır. DAG teleskopu aynası için

açıklığın tam değeri **3942 mm'dir** (Abdulkadyrov 2018). Bir optik sistemin ne kadar ışık toplayabileceğini açıklığın karesi ile orantılıdır. Daha büyük açıklıklı bir teleskop, daha fazla ışık toplar, bu da daha parlak ve net görüntüler elde edilmesini sağlar.

Alan derinliği (ing. depth of field) ve görüş alanı (ing. field of view, kısaca FOV), optik sistemlerin performansını belirleyen diğer önemli parametrelerdir. Alan derinliği, bir optik sistemin net görüntü elde edebileceği mesafe aralığını tanımlar. Bu, görüntüdeki nesnelerin ne kadarının odak içinde kalacağını belirler. Alan derinliği, odak uzaklığı, diyafram açıklığı ve nesnenin optik sisteme olan mesafesi gibi faktörlerden etkilenir. Daha küçük bir diyafram açıklığı, daha geniş bir alan derinliği sağlar, bu da hem yakın hem de uzak nesnelerin net bir şekilde gözlemlenmesine olanak tanır. Ancak, optik sistemin açıklığı genişledikçe alan derinliği daralır, bu da belirli bir mesafedeki nesnelerin netleşmesini sağlar. Optik sistemlerin tasarımında alan derinliği, netlik ve odaklanma gereksinimleri dikkate alınarak optimize edilir.

Görüş alanı, optik bir sistemin görebildiği alanın genişliğini tanımlar ve açısal ölçüyle (yay-saniye, yay-dakika veya yay-derece) ifade edilir. Geniş bir görüş alanı, daha geniş bir gökyüzünün gözlemlenmesini sağlar. Görüş alanı, odak uzaklığı ve optik (lensler, yansıtıcı aynalar vb.) sisteminin düzenlemesiyle doğrudan ilişkilidir. DAG 4m teleskopun farklı optik sistemleri (AO, SLM-Koronograf ve bilimsel kamera) için farklı görüş alanları bulunmaktadır. DAG 4m teleskopu için görüş alanları; adaptif optik sisteminde 30', SLM Koronograf sisteminde 15.3' x 9.2' olarak ve bilimsel kamera için 1.8' x 1.8' olarak hesaplanmıştır. Tablo 1'de DAG 4m Teleskopunun görüntü oluşumunu belirleyen teknik özellikleri yer almaktadır.

Tablo 1. DAG 4m Teleskopunun Teknik Özellikleri

Bileşenler / Parametreler	Özellikler
M1 ayna (net) çapı	3942 mm
M2 ayna çapı	975 mm
Teleskop odak uzunluğu	56000 mm
Teleskop f/oranı	F14.2
M3'ün odak düzlemine olan uzaklığı	4200 mm
Maksimum Parlaklık Limiti	20.68 mag
Aktif optik (arka) Aktüatör yapısı	66 adet
Aktif optik (yanal) Aktüatör yapısı	12 adet
EMCCD kamera (WFS) piksel yapısı	128 x 128 px
EMCCD kamera (WFS) piksel büyüklüğü	24 μm
Adaptif Optik çalışma dalgaboyu	600 nm

Tablo 1. (devamı)

DM Aktüatör yapısı	22 x 22
DM Aktüatör sayısı	468
Pupil çapı (AO için)	33 px veya 792 μm
Ayırma Gücü @ 600nm	0.0383 yay-saniye
Filtreler (standart)	Y, J, H ve K
Filtreler (özel)	4 adet dar-bant ve 2 adet özelleştirilmiş
SLM Koronograf piksel yapısı	1920 x 1152
SLM Koronograf piksel boyutu	9.2 μm
SLM Koronograf çalışma dalgaboyu	NIR
Bilimsel kamera (DIRAC) piksel yapısı	1024 x 1024
Bilimsel kamera (DIRAC) piksel boyutu	33 x 33 μm
Bilimsel kamera (DIRAC) çalışma dalgaboyu	1650 – 2200 nm
Strehl Oranı	>%90


Teleskoplardaki ayna yapısı (geometrisi) görüntü oluşumunu belirleyen diğer bir önemli faktördür. Ayna sistemin tasarımı gözlem amacına göre farklılık göstermektedir. Ayna yapısı türleri, ışığı toplama ve odaklama biçimleriyle birbirinden ayrılır ve her biri belirli avantajlar sunar.

Yaygın olarak kullanılan bazı teleskop ayna türleri Cassegrain, Gregorian, Schmidt-Cassegrain (SCT), Dall-Kirkham (DK), Newtonian olarak sayılabilir. Farklı teleskop ayna türleri, belirli gözlem ihtiyaçlarına uygun çözümler sunmaktadır. Her tasarımın kendine özgü avantajları ve dezavantajları vardır. Bundan dolayı teleskop tasarımı yapılırken gözlem amacı ve optik ihtiyaçlar göz önünde bulundurulur.

DAG 4m teleskopu aynası optik tasarımı Ritchey-Chrétien (RC) türündedir (Yeşilyaprak 2022). Bu sebeple RC tasarımın detayları devam eden başlıkta açıklanmıştır.


Ritchey-Chrétien Teleskop (RC) Ayna Tasarımı ve Özellikleri

Ritchey-Chrétien tasarımı, Cassegrain tasarımının bir türevidir olup, hem birincil hem de ikincil aynaları hiperbolik şekillidir (Nelson 2006). Bu tasarım, özellikle astigmatizm ve koma gibi optik bozulmaların hatasını en aza indirir ve böylelikle bu tür teleskoplar özellikle geniş görüş alanlarında yüksek / keskin görüntü kalitesine sahip olmaktadır. Şekil 2’de DAG 4m teleskopu aynası optik şematığı ve Şekil 3’te DAG 4m teleskop aynası gösterilmiştir.



Şekil 2. DAG 4m teleskopu aynası optik şematığı (Yeşilyaprak 2022)

Ritchey-Chrétien tasarımında, ikincil ayna açıklığının merkezi bir bölümünü engeller. Bu halka şeklindeki açıklık, tam açıklıklı bir tasarıma kıyasla, düşük uzaysal frekanslar aralığında modülasyon aktarım fonksiyonunun belirli bir kısmını önemli ölçüde azaltır. Bu düşüş, geniş özelliklerin görüntülenmesi sırasında görüntü kontrastını düşürme etkisine sahiptir. Ayrıca, ikincil aynayı destekleyen yapılar (örümcek veya ing. “spider” adı verilen) görüntülerde kırınım desenleri oluşturmaktadır.



Şekil 3. DAG 4m teleskopu aynası açılışı. 30 Ağustos 2022, Erzurum

Odak düzlemi

Odak düzlemi (ing. focal plane), optik sistemlerde özellikle mercekler ve aynalar gibi ışık odaklayan elemanların ürettikleri görüntülerin yer aldığı düzlemler olarak tanımlanır. Bu düzlemler, odaklama sürecinde önemli bir rol oynar ve optik sistemin performansını belirleyen temel unsurlardan biridir.


Optik bir sistemde, paralel ışık ışınlarının optik eksen boyunca kırınım veya yansıma sonucunda bir noktada toplandığı yere odak noktası olarak ifade edilir. Bu odak noktasının üzerinde bulunduğu düzlem ise odak düzlemi olarak adlandırılır. Bir başka deyişle, bir optik sistemde görüntü düzlemi olarak da bilinen odak düzlemi, görüntünün net ve keskin bir şekilde odaklandığı yerdir. Şekil 4'te DAG 4m teleskopunun tasarımı ve Nasmyth platformları ile Şekil 5'te teleskopun fabrika kabul testleri sırasında alınmış fotoğraf gösterilmiştir.

Görüntüleme sistemlerinde odak düzlemi genellikle düz bir yüzey olarak kabul edilir. Ancak bazı durumlarda, özellikle geniş görüş alanına sahip sistemlerde, bu düzlem eğri olabilir ve bu eğrilik, optik sistem tasarımında dikkate alınmalıdır. Özellikle, Ritchey-Chrétien türü

teleskoplarda odak düzlemi, optik bozulmaları (koma aberasyonu gibi) azaltmak amacıyla hafifçe eğrilmiştir.


DAG 4m teleskopu tasarımı Nasmyth olarak yapılmıştır. Nasmyth tasarımı, ışık birincil aynadaki bir delikten geçirilmez; bunun yerine, üçüncü bir ayna (M3) ışığı teleskopun yanına yansıtarak ağır aletlerin montajına izin verir (Quirrenbach 2004).

Nasmyth tasarım, büyük teleskoplarda örneğin, 10m Keck İkiz Teleskopları (Nelson 1990), 8.2m Subaru Teleskopu (Ando 2002) ve 8.2m Çok Büyük Teleskop (VLT) gibi, yaygın olarak tercih edilmektedir.



Şekil 4. DAG 4m teleskopu genel tasarımı (Pirnay 2018)

Odak düzlemi, teleskoplar, mikroskoplar, kameralar gibi optik cihazlarda kritik bir öneme sahiptir. Özellikle yüksek çözünürlüklü görüntülerin elde edilmesi gereken durumlarda, görüntü sensörünün (CCD veya CMOS kameralar) odak düzlemiyle hizalanması kritik bir öneme sahiptir. Eğer sensör bu düzlemden uzaksa, görüntüde bulanıklık meydana gelir ve optik sistemin çözünürlüğü azalır.



Şekil 5. DAG 4m Teleskopu ve iki adet Nasmyth Odakları (dikdörtgenler) ile aktif optik sistemi (elips) gösterilmektedir. DAG 4m Teleskop Fabrika Kabul Testleri, Milano / İtalya, 2019

Nokta dağılım fonksiyonu

Nokta dağılım fonksiyonu (ing. point spread function - PSF), bir optik sistemin, nokta şeklindeki bir ışık kaynağını nasıl görüntülediğini tanımlayan bir fonksiyondur (Liaudat 2023). İdeal bir optik sistemde, nokta kaynakların görüntüsü de nokta şeklinde olmalıdır.

Ancak pratikte, çeşitli optik kusurlar, kırınım (difraksiyon) ve diğer etkiler nedeniyle, bu noktalar dairesel bir dağılım gösterir. PSF, bu dairesel dağılımın matematiksel bir ifadesi olarak optik sistemin performansını karakterize eder.

$$PSF(f, z) = I_r(0, z, f) \exp \left[-z\alpha - \frac{2\rho^2}{0.36 \frac{cka}{NA_f} \sqrt{1 + \left(\frac{2\ln 2}{c\pi} \left(\frac{NA}{0.56k} \right)^2 f z \right)^2}} \right] \quad (2)$$

Teleskoplarda Görüntü Oluşumuna Etki Eden Faktörler


Kırınım etkisi

Teleskoplarda görüntü kalitesi, optik sistemin sınırlamaları nedeniyle her zaman mükemmel olmaz. Bunların en önemlilerinden biri kırınım etkisidir. Kırınım, ışığın bir engelin veya açıklığın kenarlarından geçerken sapması olayıdır. Teleskop optiklerinde, ışığın teleskopun açıklığından geçerken veya yansırken sapması sonucunda görüntüler bulanıklaşır. Bu bulanıklık, özellikle çok küçük veya çok yakın nesnelerin ayırt edilmesini zorlaştırır (Pedrotti 2018).

Kırınım etkisi tam olarak ortadan kaldırılamaz. Bu nedenle optik sistem tasarımlarında kırınım limitli performans hedeflenir. Kırınım limitine ulaşan bir teleskop, en yüksek teorik çözünürlüğe sahip olarak, optik kusurların etkisinin minimize edildiği bir sistem sunar. Işık teleskop aynasından ya da merceğinden geçerken kenarlarından sapması, difraksiyon halkaları (Airy diskleri) olarak bilinen yapılar oluşturur.

Airy disk

PSF'nin ideal bir temsilinin en yaygın modeli, bir Airy disk ile temsil edilen kırınım PSF'dir. Airy disk, tek bir daire etrafında belirgin bir ışık halkası ile çevrili merkez bir parlaklık noktası olarak görülür. Şekil 6'da airy disk ve airy desenleri gösterilmiştir.



Şekil 6. Simülasyonda üretilmiş Airy disk ve airy desenleri

Airy disk ve Airy deseni, dairesel bir açıklığa sahip mükemmel bir merceğin yapabileceği, ışığın kırınımıyla sınırlı (ing. diffraction limited) en iyi odaklanmış ışık noktasının açıklamalarıdır. Eşit şekilde aydınlatılmış dairesel bir açıklıktan kaynaklanan kırınım deseni, Airy disk olarak bilinen parlak bir merkezi bölgeye sahiptir ve etrafındaki eş merkezli halkalar dizisiyle birlikte Airy deseni olarak adlandırılır. George Biddell Airy'den adını almıştır (Bradt 2003).

Optik sistemlerdeki aberasyonlar

Bir optik sistemde, gelen ışık, sistemden geçtikten sonra tek bir noktada toplanmadığında (ya da tek bir noktadan dağılmadığında) optik bozulmalar meydana gelir. Bozulmalar, “aberrasyonlar” olarak ifade edilirler. Aberasyonlar, optik elemanların tasarım ve imalatındaki kusurlar veya optik sistemin geometrisinden kaynaklanan hatalar nedeniyle oluşurlar.

Aberasyonlar, bir lens tarafından oluşturulan görüntünün bulanıklaşmasına veya bozulmasına yol açar; bozulmanın niteliği, aberasyonun türüne bağlıdır. Astronomik olarak net ve doğru gözlemler yapabilmesi için bu optik kusurları anlamak ve bu kusurları düzeltmek kritik önem taşımaktadır.

Aberasyonların analizi bu tez kapsamında üzerinde durulan en önemli konuların başında gelmektedir. Aberasyonlar, geometrik optik teknikleriyle analiz edilebilir. Yansıma, kırılma ve kaustik (kavisli bir yüzey veya nesne tarafından yansıtılmış veya kırılmış ışınların ya da bu ışın zarfının başka bir yüzeye yansıması) üzerine yapılan çalışmalar, yansıyan ve kırılan ışınların genel özelliklerini tartışır.

Aberasyonlar temel olarak iki sınıfa ayrılır: monokromatik (tek renk / tek dalga boyundaki) ve kromatik (renkli / çoklu dalga boyunda).

Monokromatik aberasyonlar, lensin veya aynanın geometrisinden kaynaklanır ve ışık hem yansıdığı hem de kırıldığında meydana gelir. Bu aberasyonlar, monokromatik ışık kullanıldığında bile ortaya çıkar, bu nedenle bu adı alır. Optik sistemleri etkileyen başlıca aberasyon (bunlar düşük düzeyli aberasyonlar olarak da isimlendirilir) türleri devam eden başlıklarda tanımlanmıştır.

Kromatik aberasyonlar ise bir lensin kırılma indisinin dalga boyuna bağlı olarak değişmesi anlamına gelen dispersiyondan (optikte ve genel olarak dalga yayılımında, bir dalganın faz hızının frekansına bağlı olduğu bir olgudan) kaynaklanır. Dispersiyon nedeniyle, farklı dalga boylarındaki ışık farklı noktalarda odaklanır. Kromatik aberasyonlar, monokromatik ışık kullanıldığında ortaya çıkmazlar.

Odak dışılık

Odak dışılık veya odak dışı kalma, odak noktasının optik eksen boyunca tespit yüzeyinden uzaklaşması anlamına gelir. Genel olarak, bu aberasyon görüntünün keskinliğini ve kontrastını azaltır. Bir sahnedeki keskin, yüksek kontrastlı kenarlar, yumuşak geçişlere dönüşür. Sahnedeki ince detaylar bulanıklaşır veya tamamen görünmez hale gelir. Neredeyse tüm görüntü oluşturan optik cihazlar, odak dışı kalmayı en aza indirmek ve görüntü kalitesini maksimize etmek için bir tür odak ayar mekanizması içerir. Şekil 9'da odak dışı (defocus) aberasyonunun 2 boyutlu ve 3 boyutlu gösterimi sunulmuştur.

Astigmatizm

Astigmatizm, bir optik sistemin iki dikey düzlemde farklı odak uzunluklarına sahip olmasından kaynaklanır. Bu, özellikle merceklerin veya aynaların kenarlarında belirgin olan bir

sorun olup, bir noktadan gelen ışığın, bir odak yerine iki farklı odakta toplanmasına neden olur. Sonuç olarak, görüntü ya dikey ya da yatay bir çizgi şeklinde uzanır. Şekil 10'da astigmatizm aberasyonunun 2 boyutlu ve 3 boyutlu gösterimi sunulmuştur.

Küresel aberasyon

Küresel aberasyon, küresel yüzeye sahip lensler veya aynalar kullanan optik sistemlerde meydana gelir. Küresel bir yüzey, optik eksene yakın gelen ışınlarla, optik eksenden uzakta gelen ışınları farklı noktalarda odaklar. Bu durum, bir görüntüde bulanıklık veya dağılma ile sonuçlanır. Küresel aberasyon, genellikle lensin merkezine daha yakın olan bölgelerde daha az, kenarlara yaklaştıkça daha fazla belirgin hale gelir. Şekil 11'de küresel aberasyonunun 2 boyutlu ve 3 boyutlu gösterimi sunulmuştur.

Koma aberasyonu

Koma, özellikle bir noktadan gelen ışığın, optik eksene yakın olmayan bir alanda odaklandığında ortaya çıkan bir aberasyon türüdür. Komada, ışığın optik eksenle yaptığı açı arttıkça, ışık noktaları kuyruklu yıldız benzeri uzanmış bir şekil alır. Bu, özellikle geniş açılı teleskoplarda belirgin olan bir sorundur ve görüntüdeki noktaların uzanmış (asimetrik) noktalar gibi görünmesine neden olur.

Koma etkisi, ışığın optik eksenden uzaklığına ve optik sistemin eğrilik yarıçapına bağlıdır. Şekil 12'de koma aberasyonunun 2 boyutlu ve 3 boyutlu gösterimi sunulmuştur.


Alan eğriligi

Eğrilik, düz bir cisimden gelen ışığın, eğri bir görüntü düzleminde odaklanmasına neden olan bir optik hatadır. Bu, görüntünün kenarlarında netlik kaybı ile sonuçlanır. Eğrilik aberasyonu, genellikle geniş açılı lenslerde veya geniş görüş alanına sahip teleskoplarda belirgin hale gelir. Görüntü, merkezde netken kenarlarda bulanık olabilir. Görüntü düzlemindeki eğrilik yarıçapı, lensin odak uzaklığına ve sistemin açıklığına bağlıdır.

Distorsiyon

Distorsiyon, optik sistemdeki büyütmenin, görüntü alanı boyunca düzgün olmaması nedeniyle meydana gelir. Distorsiyon, görüntüdeki bir noktanın ideal konumundan sapma miktarı olarak ölçülür. Distorsiyon miktarı, görüntü yarıçapı ve optik sistemin bir faktörüne bağlıdır. İki ana distorsiyon türü vardır. Varil distorsiyonu, görüntü merkezden dışa doğru yayılır, kenarlar içe doğru bükülür. İğne yastığı veya sadece yastık distorsiyonu, görüntü

merkeze doğru b z l r ve kenarlarda dıřa doğru b k l r. řekil 7’de d z alan ve her iki distorsiyon t r  g sterilmiřtir.



řekil 7. Distorsiyonsuz (d z) alan (solda), varil bozulması (ortada) ve ięne yastıęı bozulması (saęda)

Aberasyonların modellenmesi

Aberasyonların modellenmesi, optik sistemlerdeki dalga cephelerini ve hatalarını matematiksel olarak modellemek ve analiz etmek i in Zernike polinomlarının kullanılmasına dayanır. Zernike polinomları,  zellikle dairesel a ıklıklı optik sistemlerde yaygın olarak kullanılır ve optik aberasyonları farklı bileřenlere ayırarak bu hataların karakterize edilmesini saęlar. Zernike polinomları, Hollandalı fizik i Frits Zernike tarafından tanıtılmıř olan, dairesel bir alanda tanımlanan polinomlardır. Bu polinomlar, bir optik sistemin dalga cephesi aberasyonlarını  eřitli bileřenlere ayırmak i in kullanılır. Zernike polinomları, genellikle birim  apa sahip bir daire  zerinde ifade edilir. Radyal (**R**) ve a ısal (** **) bileřenler olarak iki par aya ayrılır. Genel formu řu řekildedir:

$$Z_n^m(\rho, \theta) = R_n^m(\rho) \cdot e^{im\theta} \quad (3)$$


Denklem 3, Zernike polinomlarının kutupsal koordinatlar cinsinden genel form l d r. Denklem 3’te; Zernike polinomu (Z_n^m), genellikle sıra (n) ve derece (m), ρ kutupsal koordinatlardaki radyal mesafe, genellikle 0 ile 1 arasında normalize edilir, (θ) a ısal koordinat, R_n^m radyal Zernike polinomu ve $e^{im\theta}$ a ısal bileřeni ifade eden kompleks (i sanal birim, m ise a ısal frekans)  s terimidir.

Optik sistem tasarımımda aberasyonların modellenmesi, yalnızca teorik analizlerde deęil, aynı zamanda  retim hatalarını ve ortam kořullarını hesaba katan pratik optimizasyonlarda da kullanılır. Optik sistemin tasarımından ve ortam kořullarından kaynaklanan aberasyonlar Zernike polinomları kullanılarak analiz edilebilir (Niu 2022) ve bu sayede sistemdeki hataların d zeltilmesi i in gerekli optik elemanlar tasarlanabilir.

Her bir Zernike polinomu belirli bir aberasyonu temsil eder. Denklem 4 ile gösterilen ifade gerçek dünyada aberasyonların modellenmesini yani ifade eder. Tüm aberasyonların toplamı, her bir Zernike polinomunun bir katsayısıyla çarpılarak toplanmasıyla elde edilir.

$$W(\rho, \theta) = \sum_{n=0}^{\infty} \sum_{m=-n}^{\infty} a_n^m Z_n^m(\rho, \theta) \quad (4)$$


Burada $W(\rho, \theta)$, dalga cephesi fonksiyonu, a_n^m , Zernike polinomunun genlik katsayısıdır. Bu katsayılar, dalga cephesindeki aberasyonun büyüklüğünü gösterir. Bu toplamlar, dalga cephesinin tüm hatalarının (farklı sıradaki ve derecedeki aberasyonlar) bir toplamı olarak gösterilmesini sağlar. Dalga cephesindeki sapmaları farklı Zernike polinomları cinsinden ayrı ayrı tanımlar ve bu sapmaların büyüklükleri katsayılar ile belirlenir. Katsayılar pozitif ya da negatif olabilir. Bu durum, dalga cephesinin yönünü ve pozitif/negatif sapmaları belirler. Dalga cephesinin fiziksel birimi genellikle dalga boyu ya da mikrometre cinsindendir. a_n^m katsayıları, dalga cephesini oluşturan optik hataların büyüklüğünü temsil eder ve her bir Zernike polinomunun dalga cephesine ne kadar katkıda bulunduğunu gösterir.



Şekil 8. Simülasyondan ilk 10 optik aberasyonun 2 boyutlu gösterimi

Odak dışılık ve Zernike Polinomu Z_2^0


Bu polinom, dalga cephesindeki odak dışılık (ing. defocus) hatasını modellemek için kullanılır. Defocus, bir optik sisteminde ışığın odak düzleminde sapmasıdır ve bu polinom odak düzlemindeki kaymayı temsil eder. Odak dışılık hatası, genellikle termal genleşme, mekanik hizalama hataları veya optik elemanlardaki küçük sapmalardan kaynaklanır. Odak dışılık hatası düzeltildiğinde, görüntü netliği önemli ölçüde artar.



Şekil 9. Odak dışılık (defocus) aberasyonunun 2 boyutlu (solda) ve 3 boyutlu gösterimi (sağda)

Astigmatizm ve Zernike polinomu Z_3^{-1} ve Z_3^1 ()


Bu polinomlar, dikey ve yatay astigmatizmi temsil eder. Astigmatizm, farklı düzlemlerde odaklanma hatası yaratan bir aberasyondur.



Şekil 10. Astigmat aberasyonunun 2 boyutlu (solda) ve 3 boyutlu gösterimi (sağda)

Küresel aberasyon ve Zernike polinomu Z_4^0


Küresel aberasyon, tüm ışınlarının aynı noktada odaklanamaması durumudur.



Şekil 11. Küresel aberasyonunun 2 boyutlu (solda) ve 3 boyutlu gösterimi (sağda)

Koma ve Zernike polinomu Z_3^0

Koma, optik eksene eğimli gelen ışık ışınlarının neden olduğu kuyruklu yıldız benzeri görüntü hatasıdır.



Şekil 12. Koma aberasyonunun 2 boyutlu (solda) ve 3 boyutlu gösterimi (sağda)

Atmosferik Türbülans ve Gözlemler Üzerindeki Etkileri

Astronomik gözlemler sırasında atmosferik etkiler gözlem kalitesini bozucu etkiler sergilemektedir. Dünya atmosferinde, özellikle troposferde meydana gelen sıcaklık ve yoğunluk değişiklikleri, ışık ışınlarının farklı hızlarda kırılmasına neden olur. Bu durum, yıldızların gözlemlenmesi sırasında görüntüde sürekli bir hareketlenme ve bulanıklık olarak


kendini gösterir. Astronomik gözlemler için bu atmosferik dalgalanmalar, teleskobun teorik çözünürlük sınırına ulaşmasını engeller ve görüntü netliğini azaltır.

Atmosferik türbülansın neden olduğu sapmaların büyüklüğü, astronomik görüş kalitesi (ing. seeing) değeri ile ölçülür. Astronomik görüş kalitesi genellikle yay saniyesi cinsinden ifade edilir ve bu değer ne kadar küçükse gözlem kalitesi o kadar iyidir. Özellikle büyük teleskoplar için atmosferik koşulların gözlemler üzerindeki etkileri daha da belirgin hale gelir.

Atmosferik türbülansın etkilerini azaltmak için adaptif optik sistemler geliştirilmiştir (Quirrenbach 2004) ancak atmosferin tamamen etkisiz hale getirilmesi ancak uzay teleskoplarıyla mümkündür. Örneğin, Hubble Uzay Teleskobu, atmosferik türbülansın olmadığı bir ortamda konumlandığı için Dünya'dan yapılan gözlemlere kıyasla çok daha net görüntüler sağlar. Buna karşılık, adaptif optik sistemlerle donatılmış modern yeryüzü teleskopları (DAG 4m teleskopu gibi) atmosferik etkileri büyük ölçüde azaltarak uzaya teleskop göndermenin yüksek maliyetlerini düşürmeyi hedefler.

Atmosferi oluşturan parçacık ve bileşiklerin gözlemlere etkisi

Dünya atmosferi, yaşamı sürdüren rolünün ötesinde, astronomik gözlemleri önemli ölçüde sınırlamaktadır. Yerkürenin atmosferi, N_2 , O_2 , Ar, CO_2 , O_3 gibi çeşitli gazlardan oluşur ve bu gazlar, atmosferik soğurma özelliklerini önemli ölçüde etkiler (Quirrenbach 2004). Bu yüzden DAG gibi yüksek rakımlı ve büyük çaplı teleskoplara sahip gözlemevleri için yer seçiminde çalışılması planlanan dalga boyu önemli bir rol oynamaktadır.



Şekil 13. 500 nm – 3000 nm arasında kalan (VIS + SWIR) bölgedeki atmosferik PWV geçirgenliğinin PSG aracı kullanılarak üretilmiş spektrum grafiği

Atmosferdeki su buharı da özellikle kısa-dalgaboyu kırmızı öte ($1.4 \mu\text{m} - 3 \mu\text{m}$) dalga boylarında opaklık oluşturur (Travouillon 2003). Bu nedenle, yıllar boyunca atmosferik sütun üzerindeki yoğunlaşabilir su buharı izlenmesi, mikrodalga, milimetre, milimetre-altı ve kırmızı ötesi bölgelerde gözlem yapmak için en uygun gözlemevi yerlerini belirlemek açısından kritik öneme sahiptir.

Su buharının etkisi, özellikle 3000 nanometre altındaki dalga boylarında, yakın- kırmızı öte tayfsal aralığında belirgin olarak gözlemlenmektedir. Şekil 13'te NASA Gezegen Spektrum Üretici (PSG) aracı kullanılarak üretilmiş simule edilmiş bir Dünya transmisyon spektrumunu göstermektedir (Villanueva 2018).

Türbülans etkisinin giderilmesi ve Adaptif Optik sistemler


Adaptif optik sistemler, türbülansın bozucu etkilerini en aza indirmek için kullanılmaktadır. Bu sistemler, bir dalga cephesi sensörü yardımıyla atmosferik bozulmaları sürekli olarak ölçer ve teleskobun aynasında gerçek zamanlı düzeltmeler yaparak görüntü kalitesini artırır. Ancak, adaptif optik sistemler ne kadar gelişmiş olursa olsun, atmosferin tamamen etkisiz hale getirilmesi mümkün değildir.

Adaptif optik sistemler atmosferik türbülansın neden olduğu dalga cephesi hatalarını düzeltmek için Zernike polinomlarını kullanır. Dalga cephesi sensörleri (ing. wavefront sensor), dalga cephesindeki sapmaları Zernike polinomları cinsinden analiz ederek düzeltici aynaların hareketini kontrol eder. Şekil 15'te adaptif optik sisteminin genel konsept tasarımı gösterilmiştir.



Şekil 14. ESO VLT Teleskopundan alınmış Neptün görüntüleri

Şekil 14’te Neptün gezegeninin, Avrupa Güney Gözlemevi (ing. European Southern Observatory – ESO) Çok Büyük Teleskopu’ndaki (ing. Very Large Telescope - VLT) MUSE/GALACSI aygıtının adaptif optik modunun testleri sırasında alınan görüntüleri görülmektedir. Adaptif optik sistemi çalışmadan önce(sağda), adaptif optik sistemi açıldıktan sonraki görüntüdür (ESO Credit: ESO/P. Weilbacher (AIP))



Şekil 15. Adaptif Optik sistemi konsept gösterimi (Rao 2024)

Teleskoptan gelen ışık, hızlı hareket eden bir eğme-döndürme aynasından (tip-tilt mirror) ve bir deformasyon aynasından (DM) yansıtılarak, dalga cephesi sensörü (WFS) ve bilimsel (yüksek çözünürlüklü) kamera arasına gönderilir (Rao 2024).

Faz Bilgisinin Alınması

Faz bilgisi, ışığın dalga yapısını anlamak ve optik sistemlerdeki dalga cephesi bozulmalarını analiz etmek açısından temel bir unsurdur. Işığın fazı, dalga cephesinin hangi noktada olduğunu ve belirli bir dalga boyundaki ışığın ne kadar yol kat ettiğini tanımlar. Faz, sadece ışığın yoğunluğu değil, aynı zamanda dalga formunun bütünlüğü hakkında da bilgi verir. Bu yüzden, gözlemler sırasında ışığın faz bilgisi, optik sistemlerdeki hataların ve sapmaların incelenmesi için son derece önemlidir.

Dalga cephesindeki bozulmalar genellikle optik sistemin mercekleri, aynaları ya da atmosferik etkilerden kaynaklanır ve bu bozulmalar ışığın fazını değiştirir. Faz bozulmaları, net olmayan, bulanık ya da çarpık görüntülere yol açabilir. Ancak faz bilgisi yardımıyla bu bozulmaların kaynakları tespit edilebilir ve uygun düzeltmeler yapılabilir. Astronomik gözlemlerde, atmosferik türbülansın dalga cephesinde oluşturduğu bozulmalar, ışığın fazını etkileyerek görüntü kalitesini düşürür. Adaptif optik sistemler, faz bilgisini kullanarak bu tür bozulmaları gerçek zamanlı olarak düzeltebilir ve daha net görüntüler elde edilmesini sağlar.

Faz bilgisinin dalga cephesi analizine katkısı, özellikle Zernike polinomları gibi matematiksel yöntemlerle daha da önemli hale gelir. Faz bilgisinin doğru bir şekilde analiz edilmesi, hem görüntü netliğini artırmak hem de optik sistemlerin performansını optimize etmek açısından kritik öneme sahiptir.

Faz çeşitliliği

Faz çeşitliliği (ing. phase diversity), optik sistemlerdeki faz bozulmalarını düzeltmek için kullanılan bir tekniktir. Bu teknik, farklı faz bilgilerini kullanarak dalga cephesindeki bozulmaları modellemeye ve düzeltmeye yardımcı olur. Adaptif optik sistemler, faz çeşitliliği tekniklerini kullanarak daha hassas ve doğru düzeltmeler yapabilir. Farklı faz bilgileri, özellikle optik sistemlerde odak dışı ve diğer aberasyonların tespitinde önemli bir rol oynar. Bu teknik, dalga cephesi sensörlerine duyulan ihtiyacı ortadan kaldırarak, sadece görüntü verilerini kullanarak bozulmaları düzeltmeye olanak tanır.

Mugnier (2006) ve Gonsalves (1982) tarafından yapılan çalışmalar, faz çeşitliliği yöntemlerinin teorik temellerini ortaya koymuş ve bu yöntemin optik sistemlerdeki uygulamalarını detaylandırmıştır.

Performans Metrikleri ve Strehl oranı

Strehl oranı, bir optik sistemin performansını ölçen bir metriktir. Bu oran, ideal bir optik sistemin üreteceği maksimum ışık yoğunluğuna kıyasla, gerçek sistemin ürettiği maksimum ışık yoğunluğunu ifade eder. Adaptif optik sistemler, Strehl oranını artırarak daha kaliteli görüntüler elde edilmesini sağlar (Liang 2016).

AO sistemin performansı, genel olarak, sistemin odak düzleminde ölçülen bir nokta yayılma fonksiyonunun (PSF) Strehl oranı cinsinden verilir. Strehl oranı, PSF'nin normalleştirilmiş tepe yoğunluğunu, ideal bir PSF'ye kıyasla, yani sistem boyunca aberasyon olmaksızın ölçülmesidir.

Gelen bir ışının ne kadar sapmış olduğunu, dalga cephesi hatasını ölçerek ve onu Strehl oranı cinsinden ifade ederek temsil edebiliriz. Adaptif optik sisteminde, optik sistemin artık (geriye kalan) oranını belirterek ne kadar iyi performans gösterdiğini söyleyebiliriz.

Gerchberg-Saxton algoritması

Gerchberg-Saxton algoritması, optik ve görüntü işleme alanlarında kullanılan bir faz yakalama algoritmasıdır. İlk olarak 1972 yılında R.W. Gerchberg ve W.O. Saxton tarafından tanıtılmıştır (Gerchberg 1972). Bu algoritma, bir nesnenin faz bilgisini kaybetmiş olan iki boyutlu Fourier dönüşümü ile tanımlanan bir nesnenin hem genlik hem de faz bilgisini yeniden elde etmek amacıyla kullanılır.

Genellikle, sadece bir düzlemdeki faz dağılımını bilmek yeterlidir, çünkü diğer düzlemdeki faz dağılımı, bilinen düzlem üzerinde Fourier dönüşümü yapılarak elde edilebilir. GS algoritması genellikle iki boyutlu sinyaller için kullanılsa da, tek boyutlu sinyaller için de geçerlidir.

Makine öğrenmesi

Makine öğrenmesi (ing. machine learning – ML), bilgisayarların veriden öğrenerek belirli görevleri otomatik olarak gerçekleştirebilmesini sağlayan bir yapay zeka (ing. artificial intelligence - AI) alt alanıdır. ML, büyük miktarda veri kullanarak algoritmaların ve modellerin iyileştirilmesine dayanır. Bu teknik, doğrudan veri üzerinden öğrenme yeteneği ile farklı alanlarda başarılar elde etmiştir (Mahesh 2020). Makine öğrenmesi, denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme gibi çeşitli türlere ayrılır.

Makine öğrenmesi (ML), bir bilgisayarın doğrudan yönergeler (kodlama) olmadan öğrenmesine yardımcı olmak için matematiksel modelleri kullanma işlemidir. Makine öğrenmesi, verilerdeki kalıpları belirlemek için algoritmalar kullanır. Tahmin yapabilen bir veri modeli oluşturmak için de bu kalıplar kullanılır.

Tıpkı insanların daha fazla alıştırma yaptıkça gelişmesi gibi veri miktarı arttıkça makine öğrenmesinin sonuçları da daha doğru hale gelmektedir. Makine öğrenmesinin temel dayanağı, giriş verisini alabilen algoritmalar oluşturmak ve çıktıları yeni veriler ortaya çıktıkça güncellerken bir çıktıyı tahmin etmek için istatistiksel analiz kullanmaktır.

Makine öğrenmesinde üç ana teknik kullanılır: Denetimli Öğrenme, Denetimsiz Öğrenme ve Pekiştirmeli Öğrenme.

Denetimli öğrenme

Denetimli öğrenme (ing. supervised learning), makine öğrenmesinin en yaygın kullanılan türlerinden biridir. Bu yöntemde, model, etiketli veri kullanılarak eğitilir. Model, giriş ve çıkış çiftlerinden oluşan veri setini analiz ederek, girişlerden çıkışları tahmin etmeyi öğrenir (Nasteski 2017).

Denetimli öğrenme, sınıflandırma ve regresyon gibi birçok uygulamada kullanılır. Bu teknik, görüntü tanıma, doğal dil işleme ve tahmin modellerinde yaygın olarak kullanılmaktadır. Denetimli Öğrenme, veri kümelerinin etiketlerle veya yapılarla işlendiği bu teknikte, veriler bir öğretmen olarak görev yapar ve makineyi “eğiterek” tahmin yapma veya karar verme yeteneğini geliştirir.

Denetimsiz öğrenme

Denetimsiz öğrenme (ing. unsupervised learning), etiketlenmemiş veriler üzerinde çalışır ve veri içindeki gizli desenleri (paternleri) bulmayı amaçlar. Kümeleme ve boyut indirgeme gibi yöntemler, denetimsiz öğrenmenin önemli örnekleridir. Kümeleme algoritmaları, veri noktalarını benzerliklerine göre gruplandırırken, boyut indirgeme teknikleri veri setinin boyutunu azaltarak analizi kolaylaştırır. Denetimsiz öğrenme, özellikle veri keşfi ve veri madenciliğinde önemli bir rol oynar (Ge 2017). Denetimsiz öğrenmede veri noktaları etiketlenmez. Algoritma, verileri düzenleyerek veya bunların yapısını açıklayarak veri noktalarını kullanıcılar için etiketler.

Pekiştirmeli öğrenme

Pekiştirmeli öğrenme (ing. reinforcement learning), bir ajanın belirli bir ortamda deneyim yoluyla öğrenmesini sağlar. Ajan, çevresiyle etkileşime girer ve aldığı ödüllere veya cezalara göre stratejisini geliştirir. Bu teknik, özellikle robotik, oyun ve optimizasyon problemlerinde etkilidir. Pekiştirmeli öğrenme, ajanın çevresine uyum sağlama ve stratejik kararlar alma yeteneğini artırır (Sutton 2018).

Pekiştirmeli öğrenme, sonuçlardan öğrenen ve gerçekleştirilecek eylemi kararlaştıran algoritmaları kullanır. Algoritma, her eylemden sonra seçeneğin doğru mu, nötr mü yoksa yanlış mı olduğunu belirlemeye yardımcı olan geri bildirim alır.

Derin öğrenme

Derin öğrenme (ing. deep learning), nesne tanıma, konuşma tanıma, doğal dil işleme gibi alanlarda çok katmanlı yapay sinir ağlarının kullanan bir yapay zeka yöntemi olup makine öğrenmesinin çeşitlerinden biridir (Deng 2016; Bishop 2023).

Derin öğrenme, birden fazla işlem katmanından oluşan hesaplama modellerinin verilerin temsilini çoklu soyutlama seviyeleriyle öğrenmesini sağlar. Bu yöntemler, konuşma tanıma, görsel nesne tanıma ve nesne algılama gibi birçok alanda mevcut durumu önemli ölçüde geliştirmiştir.

Derin öğrenme, büyük veri setlerinde karmaşık yapıları keşfederek geri yayılım (ing. feedback) algoritmasını kullanır; bu algoritma, bir makinenin önceki katmandaki temsilden bir sonraki katmandaki temsili hesaplamak için kullandığı iç parametrelerini nasıl değiştirmesi gerektiğini gösterir.


Derin konvolüsyonel ağlar, görüntü, video, konuşma ve ses işleme alanlarında atılımlar sağlarken, yinelemeli ağlar metin ve konuşma gibi sıralı verilerde aydınlatıcı olmuştur. Özellikle görüntü tanıma, konuşma tanıma ve doğal dil işleme gibi alanlarda derin öğrenme modelleri, insan performansını aşan sonuçlar vermektedir (LeCun 2015).

Yapay Sinir Ağları

Yapay sinir ağları (ing. artificial neural networks), derin öğrenmenin temel yapı taşlarıdır. Bu ağlar, biyolojik sinir sistemlerini taklit ederek çalışır ve birbirine bağlı çok sayıda nörondan oluşur. Nöronlar, giriş sinyallerini alır, işler ve çıkış sinyalleri üretir. Derin sinir ağları, giriş ve çıkış arasındaki karmaşık ilişkileri öğrenerek, verilerin derin temsillerini oluşturur. Bu ağlar, birçok katmandan oluşabilir ve her katman, veri özelliklerini daha yüksek seviyelerde temsil eder (Goodfellow 2016). Şekil 16'da hem biyolojik nöron modeli hem de basit nöron modeli ile temsil edilen sinir ağı modeli gösterilmiştir.

Yapay sinir ağları, öğrenme sürecinde büyük miktarda veri kullanarak modelin doğruluğunu artırabilir. Ağın katman sayısı arttıkça, modelin derinliği de artar ve bu, daha karmaşık ilişkileri öğrenme kabiliyetini geliştirir.

Bu ağların başarısı, özellikle büyük veri kümeleriyle beslenmeleri ve yüksek işlem gücüne sahip donanımlarla desteklenmeleri sayesinde mümkün hale gelmiştir. Ancak, fazla katman kullanımı modelin aşırı öğrenmesine (ing. overfitting) yol açabilir; bu nedenle model düzenleme (ing. regularization) ve erken durdurma gibi yöntemler yaygın olarak kullanılır.




Şekil 16. Biyolojik nöron modeli (a) ve basit bir sinir ağı modeli (b) (Zhang, 2019)

Bu bağlamda, özellikle görüntü ve video verileriyle çalışmada kullanılan konvolüsyonel sinir ağları (CNN'ler), yerel özellikleri (ing. feature) yakalamak ve işlem yükünü azaltmak için filtreler ve evrişim işlemlerinden yararlanır.

Konvolüsyonel sinir ağları

Konvolüsyonel sinir ağları (ing. convolutional neural networks - CNN), özellikle görüntü işleme görevlerinde yaygın olarak kullanılan derin öğrenme modelleridir. CNN'ler, görüntülerdeki uzaysal ilişkileri koruyarak, özellikleri otomatik olarak öğrenir.

Bu ağlar, konvolüsyonel katmanlar, havuzlama katmanları ve tam bağlı katmanlar gibi farklı bileşenlerden oluşur. CNN'ler, görüntü tanıma ve nesne algılama gibi görevlerde yüksek doğruluk oranlarına ulaşır (Krizhevsky 2012). Şekil 17'de konvolüsyonel süreç gösterilmiştir.



Şekil 17. Konvolüsyonel süreç (Zhao 2024)

Tekrarlayan sinir ağları


Tekrarlayan sinir ağları (ing. recurrent neural networks - RNN), ardışık veri işleme için kullanılan bir başka derin öğrenme modelidir. RNN'ler, önceki adımların çıktısını hatırlayarak, zaman serisi verilerini ve dizilimleri analiz edebilir. Bu özellik, konuşma tanıma, dil modelleme ve müzik üretimi gibi alanlarda RNN'leri etkili kılar. Ancak, RNN'ler uzun süreli bağımlılıkları öğrenmede zorluk yaşayabilir ve bu sorunu aşmak için LSTM ve GRU gibi gelişmiş teknikler kullanılır (Hochreiter 1997).

Derin takviyeli öğrenme

Derin takviyeli öğrenme (ing. deep reinforcement learning), derin öğrenme ve pekiştirmeli öğrenmenin birleşimidir. Bu teknik, ajanın çevresiyle etkileşim kurarak ve derin sinir ağları kullanarak karmaşık stratejiler öğrenmesini sağlar. Derin takviyeli öğrenme, özellikle oyunlarda ve robotikte büyük başarılar elde etmiştir. Örneğin, DeepMind'in AlphaGo programı, Go oyununda dünya şampiyonlarını yenerek bu alandaki potansiyeli göstermiştir (Silver 2016).

Derin öğrenme yöntemleri ile dalga cephesi ölçümü

Derin öğrenme, dalga cephesi ölçümü alanında daha da büyük potansiyele sahiptir. Derin sinir ağları, karmaşık veri desenlerini tanıma ve modelleme konusunda son derece başarılıdır. Bu nedenle, derin öğrenme modelleri, dalga cephesi verilerini analiz etmek ve hataları düzeltmek için kullanılabilir. Özellikle konvolüsyonel sinir ağları (CNN), görüntü verilerini işleyerek dalga cephesi bozulmalarını algılayabilir ve düzeltebilir (Swanson 2018).



Şekil 18. Dalga cephesi ölçmeye yönelik geliştirilmiş konvolüsyonel sinir ağları mimarisi

Şekil 18’de, a) Aberasyon fazının yeniden oluşturulması için kullanılan bir mimaridir. b) Zernike katsayılarının yeniden oluşturulması için kullanılır; burada 'M', nöron sayısını belirtir. c) Kalıntı (ing. residual) blok: Bu blokta 'N' ve 'N/4', kanal sayısını gösterir (Wang 2022).

Geleneksel dalga cephesi ölçme yöntemleri, çeşitli optik sistemler ve algoritmalar kullanarak dalga cephesindeki hataları tespit eder. Son yıllarda, makine öğrenmesi (ML) ve derin öğrenme (DL) tekniklerinin dalga cephesi ölçümü uygulamalarında kullanılması bu alanda önemli ilerlemelere yol açmıştır.

Bu yöntemi kullanan çalışmalarda, adaptif optik sisteminde, dalga cephesi algılamadan, makine öğrenimini ve derin öğrenme kullanılarak faz tabanlı bir algılama yapılması önerilmiştir (Linhai 2010). Bu çalışmalar kullanılan modeller evrişimli sinir ağına (CNN) dayanmaktadır. Teknik olarak, çıktıyı ölçerek bilinmeyen girdiyi (dalga cephelerini) yeniden yapılandıran ters evrişim katmanı (dekonvülyasyon katmanı), odak (on-axis) ve odak dışı (off-axis) düzlemlerde nokta dağılım fonksiyonlarının (PSF) faz haritalarını temsil etmek için kullanılmaktadır. Daha sonra, evrişimli sinir ağı optik sistemin giriş noktasındaki nokta dağılım fonksiyonları ve karşılık gelen faz haritaları arasındaki eşleştirmeyi oluşturmak için kullanılmıştır. Eğitilen bu model, optik sistemin faz haritasını iyi bir hassasiyetle vermiştir. Önerilen yöntemin doğruluğunu ve gerçek zamanlı performansını göstermek için simülasyonlar yapılmıştır (Vanberg 2019).

Dalga cephesi sensörü üzerinden derin öğrenme teknikleri uygulaması yapan farklı bir çalışma da ise evrişimli bir sinir ağı (CNN) kullanarak tek bir WFS görüntüsünden dalga cephelerinin Zernike katsayılarını doğrudan tahmin edebilen Derin Öğrenme Dalga Cephesi Alıcısı (DLWFS) önerilmiştir (Nishizaki 2019). Bu çalışmada, Zernike katsayı miktarlarını

tahmin etmek için piksel sayısını azaltmanın etkisinin oldukça iyi sonuçlar verdiği keşfedilmiştir. Ayrıca derin öğrenme dalga cephesi algılama için daha yeni ve daha basit modeller anlatılmış ve bu modeller test edilmiştir.

Faz çeşitliliği ve derin öğrenme uygulamaları

Derin öğrenme, faz çeşitliliği verilerini analiz ederek optik sistemlerdeki dalga cephesi hatalarının daha doğru ve hızlı bir şekilde tahmin edilmesine olanak tanır. Özellikle, zaman serisi verilerini işlemek üzere geliştirilen RNN ve LSTM gibi derin öğrenme modelleri, faz çeşitliliği verilerini işleyerek dinamik bozulmaların zaman içerisindeki evrimini yakalayabilir (Meher, 2021). Bu yöntemler, klasik analiz tekniklerine kıyasla optik hataların zamanla değişen doğasını daha iyi modelleyebilme kapasitesine sahiptir.

Bu doktora tez çalışmasında, DAG 4m teleskopu ve optik sistemlerine özel olarak geliştirilen bir derin öğrenme modeli ile faz çeşitliliği yöntemi kullanılarak dalga cephesi hatalarının tahmin edilmesi amaçlanmıştır. Geliştirilen derin öğrenme modeli, teleskop verilerinden elde edilen faz çeşitliliği görüntü verilerini kullanarak, dalga cephesi bozulmalarını Zernike polinomlarına dayalı olarak tahmin etmektedir.

MATERYAL ve METOT

Bu tez çalışmasında Adaptif Optik (AO) sistemlerinde kullanılmakta olan konvansiyonel yaklaşımlı kontrol algoritmaları yerine Makine Öğrenmesi (ML) ve Derin Öğrenme (DL) yöntemleri kullanarak model tabanlı ölçüm yöntemi geliştirilmesi amaçlanmıştır. Devam eden başlıklarda kullanılan meteorolojik, astronomik ve optik sistemlerden üretilmiş girdi verileri, bu verilerin alındığı sistemler (hava durumu ölçerleri, astronomik görüş ölçeri, su buharı ölçeri vb.), geliştirilen simülasyonlar ve arayüz (GUI), simülasyonları gerçekleştirmek için kullanılan donanım ve yazılım platformları (CUDA ve PyTorch), makine öğrenmesi modelleri ve simülasyondan elde edilen verilerin analizleri ile bu verilerin veri tabanında saklanmasına yönelik materyal ve metot bilgisine yer verilmiştir.

Adaptif optik sistemlerinde kullanılmakta olan (belirli piksel ve piksel gruplarının birbirleri ile olan farklarını ölçme) yöntem yerine yeni bir yaklaşım getirilerek, makine öğrenmesi ve derin öğrenme yöntemleri ile sistemsel girdi parametrelerinin arasındaki ilişkiler ortaya konarak, hem sistemin olası performansı tahmin edilecek hem de anlık dalga cephelerinin tahminleri yapılmıştır.

Rasgele Orman (ing. random forest) makine öğrenmesi algoritması özellikle astronomik (astronomik görüş), atmosferik (sıcaklık, nem, rüzgâr hızı, su buharı) ve optiksel sistemlere ait parametrelerin (Strehl oranı) aralarındaki ilişkileri ortaya çıkarmak için kullanılacaktır.

Bu çalışmada geliştirilen derin öğrenme modeli ile DAG 4m teleskopu üzerinde yapılan gözlemler sırasında atmosferik ve optik bozulmaların gerçek zamanlı tespitine ve düzeltme stratejilerine katkıda bulunmayı amaçlamaktadır. Modelin performansı, DAG teleskopuna özgü optik ve atmosferik koşullarla optimize edilerek, teleskobun gözlem kalitesini artırmaya yönelik potansiyel çözümler sunmaktadır.

Materyal

Veriler ve ölçümler

Tez kapsamında, simülasyonda kullanılan meteorolojik ve atmosferik girdi parametrelerinden (rüzgâr, sıcaklık, nem, görüş vb.), makine öğrenmesi yöntemleri (random forest) ile model eğitimi yapılacaktır. Eğitilen modelin adaptif optik sisteminin performansını ölçmeye yarayan “Strehl oranı” değerini tahmin etmesi istenecektir. Girdi parametreleri gözlemevinde işletilmekte olan DAG-MAM sisteminden alınmıştır.

DAG-MAM sistemi

DAG-MAM (ing. **M**eteorological and **A**stronomical **M**onitoring, tr. meteorolojik ve astronomik izleme) sistemi; donanımlar, altyapı ve yazılımlardan oluşan, "akıllı" bir ekosistemdir ve astronomik gözlemler için teleskop alt sistemlerine ve operatörlere önemli ölçümlerin kesintisiz olarak sunma amacını taşır (Balbay 2020).

Kullanıcılara (gözlemciler, teknik personel, araştırmacılar vd.) için anlık ve geçmişe dönük (günlük, haftalık, yıllık) veriler sunulmaktadır. Bu sayede, kullanıcılar herhangi bir zamanda DAG-MAM web portalını kullanarak gözlemevinin istatistiksel verilerine erişebilirler. Bu tez kapsamında DAG-MAM sistemi üzerinden ilgili ölçümler indirilerek makine öğrenmesi sürecine veri hazırlığı yapılmıştır.

Meteorolojik ölçümler

DAG-MAM sisteminde farklı konumlardan anlık hava durumu ölçümleri yapılmaktadır. Şekil 19’da sistemin üç farklı istasyonları sarı renkli kutular ile gösterilmiştir. DAG-MAM kulesinde kullanılan ölçer (VAISALA Weather Transmitter - WXT536) ile MGM istasyonunda kullanılan ölçerin teknik özellikleri Tablo 2’de listelenmiştir (Balbay 2022).


Tablo 2. MAM ve MGM İstasyonunda İşletilen Cihazların Teknik Özellikleri

İstasyon	Sıcaklık [°C]	Bağıl Nem [%]	Basınç [hPa]	Rüzgar hızı [m/s]	Rüzgar yönü [derece]
MAM	-52...+60	0...100	600...1100	0...60	0...360
MGM	-80...+60	0...100	500...1100	0...80	0...360

Astronomik görüş ölçümleri

DAG-MAM sisteminde astronomik görüş değerinin belirlenmesi için kullanılan Alcor-system marka Cyclope Seeing Monitor model cihaz kuzey yarım küre için kutup yıldızının (Polaris) anlık PSF piksel dağılım istatistiklerini kullanarak görüş ölçümü yapmaktadır (Alcor-system, 2024). Bu tez kapsamında Alcor-system Cyclope Seeing Monitör’den alınan veriler kullanılmıştır. Ayrıca DAG yerleşkesinde hazırlıkları tamamlanan ve hizmete sunulan diğer bir astronomik görüş ölçeri, GDIMM ve MASS/DIMM yöntemlerini kullanarak ölçüm yapan sistemdir (Tezcan 2024).

Meteorolojik ve astronomik görüş ölçümlerine ait veriler makine öğrenmesi ve derin öğrenme yöntemlerine girdi parametreleri olarak tanımlanmıştır.



Şekil 19. DAG yerleşkesinde farklı konumlarda kurulmuş DAG-MAM sistemi istasyonları

Su buharı ölçümleri

Su Buharı aynı zamanda kırmızı ötesi (IR) gözlemler için önemli bir atmosferik bileşendir ve kırmızı ötesi radyasyonun emilimi ve yeniden emisyonu yoluyla bu gözlemlerin doğruluğunu ve güvenilirliğini etkiler.


DAG yerleşkesinden su buharı ölçümleri için “*Küresel Konumlama Sistemi (GPS) Kullanılarak DAG İçin Yoğuşturulabilir Su Buharı Miktarının (PWV) Araştırılması*” başlıklı proje kapsamında GNSS alıcı sistemi (STONEX S8-plus) kurulmuş ve ölçümlere devam edilmektedir.

Aynı zamanda su buharının farklı kaynaklardan da (uydu gözlemleri, radyosonda balonları vb.) ölçümleri ve analizleri yapılarak DAG yerleşkesinin hassas su buharı karakteristiği “*Evaluation of PWV products derived from satellite-based and radiosonde retrievals for the eastern anatolia observatory (DAG)*” başlıklı çalışmada ortaya konulmuştur (Balbay 2024).

DAG adaptif optik sistemi (TROIA)

DAG 4m teleskopu, yüksek çözünürlükte astronomik gözlemler gerçekleştirmek amacıyla kısaltması TROIA (tr. **Tu**Rkish **a**daptive **O**ptics for **I**nfrared **A**stronomy) olan gelişmiş adaptif optik (AO) sistemi ile donatılmıştır (Keskin 2022). DAG 4m teleskopu adaptif optik sistemi dinamik bir şekilde atmosferik bozulmaları düzeltmek üzere tasarlanmıştır.


DAG AO sistemi, yüksek performanslı sunucular, deformasyon aynası (DM) ve dalga cephesi sensöründen (WFS) oluşmaktadır. Sistemde dalga cephesi sensörleri, yıldızlardan gelen ışığın atmosferden geçerken nasıl bozulduğunu algılar ve bu bilgiyi kullanarak deformasyon aynasını kontrol eden bilgisayara iletir. Deformasyon aynası, gelen ışığın bozulmalarını düzelterek yüksek çözünürlüklü görüntüler elde edilmesine imkan verir.



Şekil 20. TROIA 3-boyutlu gösterimi (Keskin 2022)

TROIA sisteminde ALPAO marka DM-468 model Deformasyon Aynası (DM) kullanılmaktadır. Şekil 20’de “DM-468” ifadesi ile gösterilmiştir. Bu ayna, yüzeyleri aktif olarak değiştirilerek gelen ışığın dalga cephesini düzeltir. TROIA’da kullanılan DM, yüzeyinde yer alan 468 adet aktüatör sayesinde ışığın farklı bölümlerine farklı düzeltmeler uygulayarak, atmosferik bozulmaların etkilerini minimize eder (Alpao 2024). Şekil 22’de TROIA sisteminin optik test masası üzerinde kurulmuş hali görülmektedir.

TROIA sisteminde Nüvü marka HNü 128 model EMCCD kamera (128x128 piksel, piksel boyutu 24 μm) dalga cephesi zensörü (ing. wavefront sensor - WFS) kullanılmaktadır (Nüvü 2024). Şekil 20’de “NUVU-128 camera” ifadesi ile gösterilmiştir. Bu kamera, teleskoba gelen ışığın dalga cephesini ölçerek, atmosferik bozulmaların miktarını belirler. DAG’da kullanılan sensörler, yüksek hassasiyetli ölçümler yapabilen tiptedir ve bu ölçümler deformasyon aynalarının ne şekilde ayarlanması gerektiğini belirler.



Şekil 21. Optik test masası üzerinde kurulmuş TROIA sistemi görüntüsü. Grenoble / Fransa. 2019

Dikroik ışın ayırıcı (beam splitter - BS) 850 nm'de görsel bölge (VIS) ve yakın kırmızı öte (NIR) fotonlarını ayırır. Şekil 20'de "dichroic BS" ifadesi ile gösterilmiştir.

Tip-Tilt Modulasyon Aynası (Tip-Tilt Modulation), Physik Instrumente (Almanya) firmasının S-331 modelidir. Şekil 20'de "TT mod mirror" ifadesi ile gösterilmiştir. TTM, 1.5 kHz'e kadar çalışabilir ve 5 mrad sapma açısına sahiptir. TTM çapı 0.5 inç (12.7 mm) tir.

TROIA sisteminde iki adet atmosferik dağılım dengeleyici (atmospheric dispersion compensator - ADC) yerleştirilmiştir. Şekil 20'de "ADC" ifadesi ile gösterilmiştir.

TROIA sisteminde bir adet piramit prizma (pyramid prism) yerleştirilmiştir. Şekil 20'de "pyramid prism system" ifadesi ile gösterilmiştir.

TROIA sisteminde Lenovo marka R710 model gerçek zamanlı kontrol sunucu bilgisayarı kullanılmaktadır. Bu sunucu tipindeki bilgisayar, Dalga cephesi sensörlerinden

gelen verileri işleyerek deformasyon aynalarına komut veren yüksek hızlı bir bilgisayardır. Bu bilgisayar, saniyede binlerce ölçüm yapıp bu verileri işleyerek gerçek zamanlı düzeltmeler sağlayabilmektedir.

DAG'ın adaptif optik sistemi, modern astronomideki en ileri teknolojilerden biridir ve atmosferik bozulmaların neden olduğu görüntü kalitesi düşüşlerini etkili bir şekilde telafi eder. Bu sistem sayesinde DAG, evrenin derinliklerine dair daha net ve yüksek çözünürlüklü gözlemler yapabilecektir.

Şekil 21'de Optik test masası üzerinde kurulmuş TROIA sistemi gösterilmiştir.


Metot

DAG 4m teleskopu adaptif optik sistemi simülasyonu

Adaptif optik sistemler, atmosferik türbülansın neden olduğu görüntü bozulmalarını gerçek zamanlı olarak düzeltme kapasitesine sahiptir. Bu bağlamda, DAG 4m teleskopu AO sistemi için bir simülasyon ortamı geliştirilmesi, sistemin performansını analiz etmek ve optimize etmek açısından kritik öneme sahiptir. Bu bölümde, DAG 4m teleskopu için geliştirilen adaptif optik simülasyonunun tasarımı, kullanılan yöntemleri ve simülasyon sürecini ayrıntılı bir şekilde açıklanmıştır.

Simülasyon, hem teorik modellemeler hem de gerçek veri setleri kullanılarak AO sisteminin performansını değerlendirmeyi amaçlamaktadır. Bu sayede, simülasyon ile teleskopun operasyonel sürecine rehberlik ederek gözlem kalitesini artırmaya yönelik stratejik kararların alınmasına katkı sağlaması hedeflenmiştir. Şekil 23'te tez kapsamında hazırlanan simülasyonun grafik arayüzü (ing. graphical user interface – GUI) gösterilmiştir.

Simülasyon arayüzü sekmeli yapıda hazırlanmıştır. Açılıştaki kullanıcıyı karşılayan sekme (ana sekme) “DAG Simülasyonu” başlıklı sekmedir. Bunu sırasıyla “ML Analizi ve Tahmin”, “ML Eğitimi”, “DL Wavefront Analizi”, “DL WF Zernike Analizi”, “Meteoroloji Entegrasyonu” ve “Ayarlar” sekmeleri takip eder.



Şekil 22. Geliştirilen “DAG AO ML Simülasyonu ve Analizi” simülasyonun görsel arayüzü.

Simülasyonda kullanılan kütüphaneler

DAG AO simülasyonu, Python 3.10 (64-bit) programlama dilinde geliştirilmiştir. PyQt5 arayüz kütüphanesi kullanarak görsel arayüzü oluşturulmuştur. Simülasyonda optik ve matematiksel hesaplamalar için NumPy ve HCIPy kütüphaneleri kullanılmıştır.

DAG AO simülasyonunda, yüksek kontrastlı görüntüleme araçlarının uçtan uca simülasyonlarını gerçekleştirmek için Python'da geliştirilmiş açık kaynaklı nesne tabanlı bir çerçeve (ing. framework) olan HCIPy kütüphanesinden yararlanılmıştır. HCIPy, astronomik gözlemler için yüksek kontrastlı görüntüleme sistemlerini simüle etmek amacıyla geliştirilmiş bir Python kütüphanesidir (Por, 2018).

Yüksek kontrastlı görüntüleme, özellikle öte gezegenlerin keşfi ve yıldız sistemlerinin detaylı incelenmesi gibi alanlarda kritik bir rol oynar. HCIPy, bu tür gözlemler için gerekli olan optik sistemlerin simülasyonlarını yapmak ve analiz etmek için kullanılabilir. HCIPy, açık kaynaklı bir kütüphane olarak GitHub'da mevcuttur ve kapsamlı bir dokümantasyona sahiptir (HCIPy, 2024). Kullanıcılar, temel optik simülasyonlardan karmaşık yüksek kontrastlı görüntüleme sistemlerine kadar çeşitli örnekler ve rehberlerle kütüphaneyi öğrenebilir ve projelerine entegre edebilir.

HCIPy, ışığın dalga cephesini (ing. wavefront) modellemek, aberasyonları simüle etmek ve adaptif optik sistemlerinin performansını değerlendirmek için çeşitli fonksiyonlar sağlar. HCIPy ile teleskoplar, deformasyon aynaları, koronagraf maskeleri ve atmosferik türbülans gibi birçok bileşen simüle edebilir. Aynı zamanda adaptif optik sistemlerin modellenmesi için de

kapsamlı bir araç seti bulunmaktadır. Dalga cephesi sensörleri ve kontrol algoritmaları gibi bileşenler, AO sistemlerinin performansını analiz etmek ve optimize etmek için kullanılabilir.

HCIPy, kullanıcıların kendi optik bileşenlerini ve algoritmalarını kolayca tanımlamalarına ve simülasyonlarına entegre etmelerine olanak tanımaktadır. Böylece, özel gereksinimlere uygun simülasyonlar yapılabilir.

Simülasyon veri yapısı

Simülasyon da kullanılan parametreler ve değerleri Tablo 3’de verilmiştir. Simülasyon arayüzü üzerinden istenen değerler değiştirilebilmek ve simülasyon bu parametrelere uygun şekilde tekrar çalıştırılabilmektedir.

Tablo 3. DAG AO Simülasyonun Kullanılan Parametreler

Parametre	Değer
wavelength	1650E-9
wavelength_wfs	700E-9
zero_magnitude_flux	6.6E11
stellar_magnitude	0
r0	0.2
L0	20
cn2	[[9.57, 9, 649], [10.83, 9, 1299], [4.37, 15, 2598], [6.58, 25, 5196], [3.71, 40, 10392], [6.71, 21, 20785]]
pupil_pixels	128
q	8
num_airy	32
super_sample_num	4
m1_diameter	3.940
m2_diameter	0.975
spiders_width	0.015
spiders	4
spatial_resolution	wavelength / m1_diameter
dm_actuators	22
dm_delta	1E-3
dm_leakage	0.01
dm_gain	0.5
dm_cond	1E-2
wfs_integration_time	1E-3

Simülasyon gerçekleştirim süreci ve analizler

Bu çalışmada geliştirilen simülasyonlar ve analizler, araştırmacının özellikleri Tablo 4’de gösterilen kişisel test ortamında gerçekleştirilmiştir. Simülasyonlar için gerekli olan hesaplamalar, bilgisayar ortamında optimize edilerek, yüksek doğruluk ve verimlilikle tamamlanmıştır. Bu yaklaşım, araştırma sürecinin her aşamasında esneklik ve kontrol sağlamış, aynı zamanda simülasyonların tekrarlanabilirliğini ve analizlerin güvenilirliğini artırmıştır. Simülasyon için gerekli olan veriler, test ortamının donanımın kapasiteleri göz önünde bulundurularak değerlendirilmiş ve üretilmiştir.

Tablo 4. Geliştirme ve Test Ortamı Teknik Özellikleri

Donanım	Marka / Model	Özellikler
İşlemci (CPU)	AMD Ryzen 5 3600X	6 Core, 3.8 Ghz
Bellek (RAM)	Kingston HyperX Fury	32 GB DDR4, 3200 MHz
Grafik Kartı (GPU)	NVIDIA RTX 3050	8 GB, 128 Bit, GDDR6
Depolama	Gigabyte Aorus M.2 NVMe	1 TB, 7300MB/s okuma-6000MB/s yazma hızı

Simülasyonda kullanılan platformlar ve algoritmalar

Tez çalışmasında, derin öğrenme tekniklerinin adaptif optik sistemleri için algoritmalar geliştirilmesinde kullanılması amaçlanmıştır. Bu süreçte, derin öğrenme modellerinin verimli bir şekilde eğitilebilmesi için CUDA destekli GPU'ların paralel işlem kapasitesinden faydalanılmıştır. CUDA, model eğitim süresini kısaltarak, simülasyon ve analiz süreçlerinin hızlandırılmasına katkı sağlamıştır.

CUDA (Compute Unified Device Architecture), NVIDIA firması tarafından geliştirilen ve grafik işlem birimini (GPU) genel amaçlı hesaplamalar için kullanılabilir hale getiren bir paralel hesaplama platformu ve programlama modelidir (NVIDIA 2024).

CUDA, geliştiricilere GPU'nun çoklu çekirdeklerini kullanarak yüksek performanslı hesaplamalar yapma imkanı tanır. C, C++, Python gibi programlama dillerini destekleyen CUDA, paralel hesaplamaların etkin bir şekilde yürütülmesine olanak sağlar ve GPU'nun geniş paralel işleme kapasitesinden faydalanır.

Bu tez çalışmasında, adaptif optik sistemleri için geliştirilen derin öğrenme algoritmalarının tasarımı ve eğitimi için PyTorch kütüphanesi kullanılmıştır. PyTorch, esnek ve dinamik yapısı sayesinde karmaşık sinir ağlarının kolayca oluşturulmasına ve eğitilmesine olanak tanımaktadır (PyTorch 2024). Özellikle CUDA platformu ile entegre çalışabilmesi,

model eğitim süreçlerinin hızlandırılmasını ve büyük veri setlerinin verimli bir şekilde işlenmesini sağladığı için tercih edilmiştir.

Ayrıca tez çalışmasında kullanılan veri setinin modele aktarılmasında farklı (Townson 2019; Vanberg 2019) çalışmalardan faydalanılmıştır.

Rastgele orman yöntemi ile parametre tahmini

Bu tez çalışmasında belirtilen amaçlara yönelik olarak, verilen ortam koşullarında en iyi sonuçların elde edilmesini sağlayacak tahminlerin, denetimli öğrenme makine öğrenmesi algoritmasında karar-verici yapıların (algoritmaların) kullanılması başarılabileceği öngörülmüştür.

Karar-verici algoritmalarından en yaygın olarak kullanılanları, “Karar Ağacı” ve “Rastgele Orman” algoritmalarıdır.

Rastgele orman (ing. random forest) algoritması, tek bir karar ağacına kıyasla birkaç önemli avantaja sahiptir. Karar ağaçları, veri setindeki gürültüye ve özel durumlara fazla uyum sağlayarak aşırı uyum riski taşır. Rastgele Orman, birden fazla karar ağacını birleştirerek bu riski azaltır. Her ağaç, farklı bir alt veri kümesi ve özellik seti üzerinde eğitildiğinden, modelin genel performansı artırılır ve aşırı uyumdan kaçınılır.

Rastgele Orman, birden fazla karar ağacının oylarının çoğunluğunu alarak son tahminleri yapar. Bu yöntem, tek bir karar ağacının yapabileceği hataları telafi eder ve genel doğruluğu artırır. Bu avantajlar sayesinde, Rastgele Orman algoritması, daha dengeli ve güvenilir tahminler yaparak karar ağaçlarına kıyasla daha başarılı sonuçlar verebilir. Bu sebeple tez çalışmasında rastgele orman algoritması tercih edilmiştir.

Şekil 23’de rastgele orman algoritmasının DAG AO simülasyonuna göre, “Strehl oranı” parametresi için oluşan ağaç yapısı gösterilmiştir.

Rastgele orman algoritması


Bu tez çalışmasında yukarıda bahsedilen Rastgele Orman (Random Forest) algoritma yapısından yararlanılmıştır. Rastgele Orman (Random Forest) algoritması, makine öğreniminde yaygın olarak kullanılan bir yöntemdir.

Bu algoritma, birden fazla karar ağacını bir araya getirerek sonuçların doğruluğunu artırır ve modelin genelleme kabiliyetini iyileştirir. Karar ağaçlarının çeşitlendirilmesi, algoritmanın hem regresyon hem de sınıflandırma problemlerinde esnek ve etkili olmasını sağlar. Ancak, her yöntem gibi rastgele orman algoritmasının da bazı avantajları ve dezavantajları bulunmaktadır.

Avantajları

- **Yüksek Doğruluk:** Rastgele orman, birden fazla karar ağacının çıktısını birleştirerek hataları minimize eder ve modelin doğruluğunu artırır.
- **Aşırı Uyumdan Kaçınma:** Algoritma, karar ağaçlarının çeşitliliği sayesinde aşırı uyum riskini azaltır.
- **Çok Yönlülük:** Hem sınıflandırma hem de regresyon problemlerinde etkili bir şekilde kullanılabilir.
- **Öznitelik Seçimi:** Rastgele Orman, hangi özniteliklerin daha önemli olduğunu belirleyerek özellik seçiminde yardımcı olabilir.





Şekil 23. Rastgele Orman Algoritmasının DAG simülasyonuna göre, “Strehl oranı” parametresi için oluşan ağaç yapısının görüntüsü

Dezavantajları

- **Hesaplama Maliyeti:** Çok sayıda karar ağacının oluşturulması ve bunların sonuçlarının birleştirilmesi, özellikle büyük veri setlerinde yüksek hesaplama gücü gerektirir.
- **Yorumlanabilirlik:** Rastgele Orman algoritması, tek bir karar ağacına kıyasla daha az şeffaftır ve modelin iç işleyişini anlamak zor olabilir.
- **Hafıza Kullanımı:** Büyük veri setleriyle çalışıldığında hafıza kullanımı artabilir ve bu da bazı durumlarda verimli olmayabilir.


Bu avantajlar ve dezavantajlar göz önüne alındığında, Rastgele Orman algoritması, doğru veri setleri ve hesaplama kaynakları ile kullanıldığında güçlü bir araç olarak öne çıkar.

Simülasyon çıktıları ve verilerin saklanması

DAG AO simülasyonunda üretilen sonuçların saklanması için PostgreSQL 14 açık kaynaklı ve SQL destekli ilişkisel veritabanı yönetim sistemi kullanılmıştır (PostgreSQL 2024). Veritabanı oluşturulurken, simülasyonda kullanılan tüm optik-elektronik parametreler dikkate alınmıştır. Tüm parametreler için ayrı ayrı sütunlar oluşturulmuş ve her bir satırı özel olarak temsil etmesi için “id” sütünü PRIMARY_KEY olarak veritabanına eklenmiştir. “id” sütunu ve diğer on dokuz (19), toplamda 20 sütunlu bir veritabanı oluşturulmuştur. Bu sütunların türleri herbirine karşılık gelen veri tipinde; örneğin yıldız parlaklığı ya da M1 ve M2 ayna çapları “double” tipinde, spider sayısı “integer” tipinde, performans göz önünde bulundurularak oluşturulmuştur.


Derin öğrenme model eğitimi hazırlığı ve görüntüleri biçimi

DAG AO simülasyonundan üretilen görüntüler, odak içi ve odak dışı olarak saptırılmış PSF çiftlerinden ve PSF’in faz haritası dağılımından oluşur. 100.000 görüntüden oluşan veri seti oluşturulmuştur. Veriler, FITS (ing. flexible image transport System) (Wells 1979) formatında 3 katmanlı (görüntünün faz bilgisi, odak-içi PSF ve odak-dışı PSF) ve 32-bit veri yapısında kayıt edilmiştir. Şekil 24’te örnek bir DAG AO simülasyonunda üretilmiş FITS dosyasının içeriği gösterilmiştir.



Şekil 24. DAG AO parametrelerine göre faz haritası (solda), odak içi (ortada) ve odak dışı (sağda) 2 boyutlu gösterimleri

DAG AO simülasyonu aynı zamanda üretilen görüntülerin pratik bir biçimde yorumlanmasını sağlayacak gerekli algoritmalara sahiptir. Bunlara örnek olarak, üretilmiş görüntülerin 2 boyutlu ve 3 boyutlu görselleştirilmesini sağlayan grafiklerdir. Şekil 25’de üretilmiş görüntülerden rasgele seçilmiş bir setin 3 boyutlu gösterimi gösterilmiştir.



Şekil 25. Simülasyondan üretilen faz haritasının (solda), odak-içi (ortada) ve odak-dışı (solda) görüntülerin PSF’lerinin 3-boyutlu olarak gösterimi

Model eğitimi için veri setinin hazırlanması

Simülasyon, DAG 4m teleskopu AO sisteminde dalga cephesi rekonstrüksiyonu için sentetik veri setleri üretmek amacıyla tasarlanmıştır. Simülasyon süreci, teleskop sisteminin fiziksel ve optik parametrelerini dikkate alarak gerçekleştirilmiştir.

Bu parametreler arasında teleskop aynasının çapı, optik elemanların düzeni, atmosferik türbülansın etkileri ve optik sistemin dalga cephesi hataları gibi faktörler yer almaktadır. Simülasyon öncesinde, teleskop sisteminin farklı odak düzlemlerinde oluşan PSF’ler hesaplanmış ve kaydedilmiştir. Bu PSF çiftleri, dalga cephesi rekonstrüksiyonu için gerekli olan temel verileri sağlamaktadır.

UNET modeli, özellikle görüntü segmentasyonu ve çeşitli diğer bilgisayarla görme görevlerinde kullanılan bir derin öğrenme mimarisidir (Ronneberger 2015). Elde edilen sentetik veri seti, UNET modeli ile dalga cephesi rekonstrüksiyonu yapmak için kullanılmıştır. UNET


modelinin yapısı ve konvansiyonel ağ akışı Şekil 27’de gösterilmiştir. UNET modeli giriş olarak ikinci ve üçüncü katmanlardaki PSF verilerini alarak birinci katmandaki dalga cephesi bilgisi ile olan ilişkisini öğrenmeyi amaçlamaktadır. Bu süreçte, modelin PSF’leri analiz ederek dalga cephesi hatalarını doğru bir şekilde tahmin etmesi hedeflenmiştir.

Model eğitimi sırasında, sentetik veri setinin çeşitliliği ve doğruluğu büyük önem taşımaktadır. Simülasyon, teleskop sisteminin çeşitli çalışma koşullarını ve atmosferik türbülans senaryolarını kapsayacak şekilde genişletilmiştir. Bu sayede, modelin genel performansı artırılarak gerçek dünya uygulamalarına daha uygun hale getirilmiştir. Eğitim veri seti, veri artırma teknikleri kullanılarak zenginleştirilmiş ve modelin farklı koşullara karşı dayanıklılığı artırılmıştır.

UNET modeli, veri setindeki PSF’leri analiz ederken çeşitli konvolüsyon katmanları kullanarak düşük ve yüksek seviyeli özellikleri öğrenir. Kodlayıcı ve kod çözücü yapılarına sahip olan model, giriş PSF verilerini işlemekten geçirerek dalga cephesi hatalarını tahmin eder. Atlamalı bağlantılar (skip connections), kodlayıcıdan gelen düşük seviyeli detayları koruyarak modelin doğruluğunu artırır. UNET mimarisi Şekil 26’da gösterilmektedir. Şekil 26’da her mavi kutu çok kanallı bir özellik haritasına karşılık gelir. Kanal sayısı kutunun üstünde belirtilir. X-Y boyutu kutunun sol alt kenarında sağlanır. Beyaz kutular kopyalanmış özellik haritalarını temsil eder. Oklar farklı işlemleri belirtir.

Modelin doğruluğunu ve genelleme kabiliyetini artırmak için çeşitli hiper-parametre (eğitim oranı, mini-batch boyutu, doğru optimizasyon algoritmasının seçimi ve çevrim sayısı) ayarlamaları yapılmıştır. Optimizasyon sürecinde Adam optimizasyon algoritması kullanılmıştır. Eğitim sırasında modelin aşırı öğrenme eğilimlerini azaltmak için doğrulama veri seti kullanılarak düzenli performans değerlendirmeleri yapılmıştır.

Geliştirilen model, adaptif optik sistemlerinde dalga cephesi hatalarını doğru bir şekilde tahmin ederek teleskop görüntü kalitesini artırmayı hedeflemektedir. Modelin başarıyla eğitilmesi ve test edilmesi sonucunda, teleskop sistemlerinde kullanılabilecek etkili bir dalga cephesi rekonstrüksiyon aracı elde edilmiştir. Bu çalışma, adaptif optik sistemlerinin performansını iyileştirme ve daha net astronomik görüntüler elde etme açısından önemli bir adım olarak değerlendirilmektedir.



Şekil 26. UNET mimarisinin gösterimi (Ronneberger 2015)

UNET modelinin kullanımı ve geliştirilmesi, derin öğrenme ve bilgisayarla görme tekniklerinin adaptif optik sistemlerine entegrasyonunu sağlamaktadır. Bu entegrasyon, hem simülasyon tabanlı veri setlerinin kullanımı hem de gerçek dünya uygulamalarındaki başarısı ile dikkat çekmektedir. Çalışmanın sonuçları, adaptif optik sistemlerinin gelecekteki gelişmelerine önemli katkılar sunmakta ve daha ileri düzeyde görüntüleme teknolojilerinin yolunu açmaktadır.

UNET modelinin derin öğrenme tabanlı dalga cephesi rekonstrüksiyonu için kullanımı

Adaptif optik sistemlerinde dalga cephesi rekonstrüksiyonu için UNET modelinin kullanımı, modelin detayları ve bağlamsal bilgiyi yüksek doğrulukla birleştirme yeteneğinden faydalanır. Faz çeşitliliği, görüntüleri kullanılarak UNET modelinin eğitilmesi ve dalga cephesi tahminleri için optimize edilmesi mümkündür. Bu, adaptif optik sistemlerinin performansını artırarak daha doğru görüntüleme ve analiz sağlar.

UNET modeli, girdi görüntüsünden çıkarılan özellikleri kullanarak aynı boyutta bir çıktı görüntüsü üretir. UNET'in başarısı, geniş ve daraltıcı yol adı verilen iki simetrik parça içermesinden kaynaklanır. Bu yapı hem düşük seviyeli özellikleri hem de yüksek seviyeli bağlamsal bilgiyi birleştirerek yüksek doğrulukta segmentasyon sağlar. UNET modeli, temel olarak iki ana bölümden oluşur: kodlayıcı ve kod çözücü.

Kodlayıcı (Encoder / daralan yol)

Kodlayıcı yapısı, geleneksel bir konvolüsyonel sinir ağına (CNN) benzer. Bir dizi konvolüsyon katmanı, aktivasyon fonksiyonları (ReLU gibi) ve maksimum havuzlama (max pooling) işlemleri içerir.

Kodlayıcı yapısının amacı, girdi görüntüsünden giderek daha karmaşık ve soyut özellikleri çıkarmaktır. Her konvolüsyon katmanında, özellik haritasının boyutunu azalırken derinliğini artmaktadır.

Kod çözücü (genişleyen yol)

Kod çözücü yapısı, özellik haritalarını orijinal boyutlarına geri döndürmek için yükseltme (ing. upsampling) işlemleri, konvolüsyon katmanları ve birleşme (ing. concatenation) işlemleri içermektedir.

Kod çözücü yapısının amacı, kodlayıcıdan gelen özellik haritalarını, orijinal boyutlarına geri döndürerek segmentasyon maskesi oluşturmaktır. Yükseltme işlemleri, ara özellik haritalarını birleştirerek yüksek çözünürlüklü çıktı sağlar.


Köprü (Bridge)

Köprü yapısı, kodlayıcı ve kod çözücü arasında yer alır. Derin katmanlardan gelen bilgi, burada daha yüksek seviyeli özelliklerle birleştirilir.

Atlamalı bağlantılar

Atlamalı bağlantılar, kodlayıcı ve kod çözücü arasındaki aynı seviyelerdeki katmanlar arasında doğrudan bağlantılar kurulur.

Atlamalı bağlantıların amacı, kodlayıcıdan gelen düşük seviyeli detayları kod çözücüye aktararak daha iyi segmentasyon sonuçları elde edilir. Bu bağlantılar, özellikle ince detayların korunmasını sağlar. Şekil 27’de DAG AO simülasyonundan üretilmiş dalga cephesi verileri için, UNET mimarisinde oluşan özellik bazı örnek haritalar gösterilmiştir.




Şekil 27. UNET mimarisinde WFS için tanımlama için oluşan özellik (ing. feature) haritaları

ARAŞTIRMA BULGULARI ve TARTIŞMA

DAG AO Simülasyonu ve Bileşenleri

DAG AO simülasyonunda yapılan çalışmalar sonrası analiz ve kıyaslamalar yapılmıştır. Bu analiz ve kıyaslamalar sonucunda DAG optik sistemleri için, DAG teleskop yüklenicileri tarafından yapılan modelleme ve analizlere oldukça yakın değerler elde edildiği gözlemlenmiştir.

Şekil 28’de Doğal Kılavuz Yıldızı (ing. naturel guide star - NGS) için 1 m/s ve 10 m/s rüzgâr hızları altında DAG AO sisteminin çalışma performansını gösterir yüklenici simülasyon sonucu yer almaktadır. 1 m/s rüzgâr hızı (soldaki şekilde kırmızı çizgi) altında iki model sonucu oldukça yakın değerler vermektedir.




Şekil 28. Yüklenicinin teslim ettiği (solda) ve doktora tezi kapsamında oluşturulan simülasyon (sağda) sonuçlarının (strehl oranına karşılık yıldız parlaklığı) kıyaslaması.

Rasgele Orman modelinde, giriş parametresi olarak yıldız parlaklığı ve astronomik görüş değerlerini kabul etmektedir.

Modelin çıktı parametresi ise “Strehl oranı” değeridir. Yani geliştirilen bu modele kullanıcı yıldız parlaklığını (görsel aralıkta) ve astronomik görüş değerini girdi olarak verdiğinde eğitilmiş model tüm optik sistemsel parametreleri göz önüne alarak Strehl oranını vermektedir. Modelin, hata payı (ing. mean absolute error - MAE) **0,03** olarak hesaplanmıştır.

Şekil 29’da DAG AO simülasyonunun grafiksel kullanıcı arayüzü (GUI) gösterilmektedir. Bu arayüz aynı zamanda geliştirilen yazılımın açılış ekranında yer almaktadır.


Kullanıcılar geliştirilen yazılımı kullanırken parametrelerin anlık değişimi bu arayüz üzerinden görsel olarak takip edebilmektedirler.




Şekil 29. DAG AO simülasyonunun grafiksel kullanıcı ara yüzü (GUI)

DAG AO simülasyonunun grafiksel ara yüzünde optik bileşenlere dair görsel bulunmaktadır. Bunlar sol üstten sağ alta doğru sırasıyla;


- Belirlenen dalga boyuna ve yıldız parlaklık parametresine göre çizilen boş uzay ortamında yani sentetik olarak üretilmiş PSF (Şekil 30) gösterimi,
- girilen Fried parametresine (r_0) ve L0 parametresine göre anlık olarak değişen çok katmanlı türbülans gösterimi (Şekil 30),
- DAG M1 ve M2 aynalarının temsili gösterimi (Şekil 31),
- DAG AO sisteminde yer alan 22x22 (468 adet) dizilişli DM aynanın üzerine DAG aynalarından yansıtılmış türbülanslı PSF gösterimi (Şekil 31),
- DAG AO sisteminde yer alan 4 (dört) yüzeyine anlık olarak DM aynadan Tip-Tilt Ayna vasıtası ile yansıtılan düzeltilmemiş (türbülanslı) PSF gösterimi (Şekil 32),
- DAG AO sistemleri kullanılarak bilimsel IR kamera üzerinde düzeltilmiş PSF gösterimi (Şekil 32).




Şekil 30. Türbülans etkisine maruz kalmamış ancak DAG sistemseller etkilerinin (teleskop tutucu kolları – spider) görülebileceği sentetik PSF gösterimi (solda) ve belirlenen parametrelere veya yerleşkeden alınan anlık ölçümlere göre değişim sergileyen (temsili) türbülans gösterimi (sağda)




Şekil 31. DAG 4m teleskop M1 ve M2 aynalarının gösterimleri (solda) ve DAG AO sisteminde yer alan DM aynanın üzerinde oluşan türbülanslı dalga cephelerine karşılık gelen DM aynanın yüzey şeklinin gösterim (sağda)



Şekil 32. Piramit lensten dalga cephesi ölçerine (WFS) düşen türbülanslı ışınlar (solda) ve adaptif optik sistemi kapalı iken bilimsel kameraya (DIRAC) düşen yapay yıldız ışığı (sağda)




Şekil 33. DAG AO simülasyonunun “DL Wavefront Analizi” sekmesinde yer alan, odaklanmış dalga cephesi görüntüsü (solda) ve aynı sekmede yer alan odak dışı dalga cephesi görüntüsü (sağda)



Şekil 34. DAG AO simülasyonunun “DL Wavefront Analizi” sekmesinde yer alan dalga cephesine ait faz haritası (solda) ve derin öğrenme modeli kullanılarak “tahmin” edilmiş dalga cephesine ait faz haritası (sağda)

Şekilde 34’teki her iki görsel göz ile incelendiğinde aradaki fark anlaşılmayacak kadar azdır. Şekil 34 de gösterilen orijinal ve tahmin edilmiş faz haritalarının görsel olarak anlaşılabilmesi amacıyla, bu haritaların farkları alınarak oluşturulmuş 3 boyutlu “fark haritası” Şekil 35’te gösterilmiştir.




Şekil 35. DAG AO simülasyonunun “DL Wavefront Analizi” sekmesinde yer alan dalga (farklı) cephelerine ait orijinal ve tahmin edilen dalga cephelerinin farklarının 3 boyutlu gösterimleri

Derin öğrenme model eğitimi süreci

Derin öğrenme eğitimi süreci, bir yapay sinir ağı modelinin belirli bir veri kümesi üzerinde eğitilmesi ve bu modelin optimize edilerek en iyi performansı göstermesi için gerçekleştirilen adımlardan oluşur.

Tez çalışmasının derin öğrenme modeli eğitimi için farklı çevrim süreleri denenmiş ve 300 çevrim sonunda artık daha fazla öğrenme sergilemediği için eğitim süreci durdurulmuştur. Yaklaşık 100. çevrimden sonra modelin öğrenimi düz bir platoda seyretnmiştir. Şekil 36 ve Şekil 37’de öğrenme sürecine dair eğitim ve doğrulama kayıpları (ing. loss) grafiği ile eğitim ve hassasiyet (ing. accuracy) grafiği gösterilmektedir.




Şekil 36. Derin öğrenme eğitim sürecinde modelin eğitim ve doğrulama kayıplarının (metriklerinin) izlenmesini sağlayan grafiksel gösterim

Derin öğrenme modeli eğitimine ait eğitim kaybı yaklaşık 100. çevrimden sonra tüm çevrimler bitinceye kadar düz bir platoda seyretmiştir. Bu durum, modelin eğitim verilerine iyi uyum sağladığını ve hatalarının azaldığını göstermektedir. Doğrulama kaybı ise 50 çevrim civarında hızlı bir düşüşten sonra doğrulama kaybı bir süre daha eğitim kaybına paralel olarak azalmıştır, ancak 100 çevrimden itibaren yavaşça bir sabitlenme eğilimine girmiş ve 0.1 seviyesinde dengelenmiştir.

Şekil 36 incelendiğinde, eğitim kaybı sürekli olarak azalmaya devam ederken doğrulama kaybının sabitlenmesi, modelin eğitim verisine aşırı uyum sağladığını (ing. overfitting) ve doğrulama verisine göre daha iyi performans gösteremediğine işaret etmektedir. Doğrulama kaybının eğitim kaybına göre yüksek kalması da bu durumu desteklemiştir.

Eğitim kaybının ve doğrulama kaybının belirli bir seviyede sabitlenmesi, modelin artık öğrenmesinin durduğunu ve optimizasyon sürecinin sona erdiğini göstermektedir. Ayrıca doğrulama kaybının eğitim kaybına kıyasla daha yüksek olması, genel olarak modelin genelleme yeteneğinin sınırlı olabileceğine işaret eder.

Şekil 37’de Eğitim ve Doğrulama Doğruluğu gösterilmektedir. Genel olarak modelin doğruluk (ing. accuracy) performansını izlemek, modelin öğrenme sürecinde ne kadar başarılı olduğunu anlamak için önemlidir.




Şekil 37. Derin öğrenme eğitim sürecinde modelin öğrenme ve doğrulama hassasiyetine ait metriklerin izlenmesini sağlayan grafiksel gösterim

Şekil 37 incelendiğinde, eğitim doğruluğu (mavi çizgi), yaklaşık 50 çevrimden sonra %100'e (1.0) yakın bir seviyeye ulaşmakta ve sonrasında da oldukça sabit kalmaktadır. Model eğitim verileri üzerinde mükemmel bir doğruluk sağladığına işaret etmektedir.


Doğrulama doğruluğu (turuncu çizgi), eğitim doğruluğuna kıyasla daha dalgalı ve yaklaşık %90 (0.9) civarında sabitlenmiş durumdadır. Yaklaşık 50 çevrimden sonra doğrulama doğruluğu büyük oranda artış göstermekte ancak %100'e yaklaşıyor ve belirli bir seviyede kalmaktadır. Bu durum, modelin eğitim verilerine göre daha fazla doğrulama verisinde zorlandığını gösterir, yani modelin genelleme yeteneği eğitim setine göre daha sınırlı kalmıştır.

Şekil 38'de DAG AO Simülasyonunun "DL Wavefront Analizi" sekmesinde seçili (*psf_0.fits*) bir verinin sol üstten sağ alta doğru sırası ile odaktaki, odak dışındaki, 3 boyutlu (odak) faz haritası, dalga cephesi faz haritası, tahmin edilen faz haritası ve gerçek ile tahmin arasındaki faz haritası farkına ait GUI üzerinden 2 boyutlu gösterimi sunulmuştur.

Şekil 39'da DAG AO Simülasyonunun "DL Wavefront Analizi" sekmesinde seçili (*psf_0.fits*) bir verinin sol üstten sağ alta doğru sırası ile odaktaki, odak dışındaki, 3 boyutlu (odak dışı) faz haritası, dalga cephesi faz haritası, tahmin edilen faz haritası ve gerçek ile tahmin arasındaki faz haritası farkına ait GUI üzerinden 3 boyutlu gösterimi sunulmuştur.



Şekil 38. DAG AO Simülasyonunun “DL Wavefront Analizi” sekmesinde seçili (psf_0.fits) bir verinin 2 boyutlu gösterimi




Şekil 39. DAG AO Simülasyonunun “DL Wavefront Analizi” sekmesinde seçili (psf_0.fits) bir verinin 3 boyutlu gösterimi

Şekil 40’da DAG AO Simülasyonunun “DL WF Zernike Analizi” sekmesinde seçili (psf_0.fits) bir verinin, orijinal ve modelin tahmin ettiği ilk 22 Zernike katsayıları (üstte) ve orijinal ile modelin tahmin ettiği Zernike katsayılarının nm biriminden farkına (altta) dair GUI üzerinden gösterimi sunulmuştur.


Şekil 41’de DAG AO Simülasyonunun “DL WF Zernike Analizi” sekmesinde seçili (psf_34.fits) bir verinin, orijinal ve modelin tahmin ettiği ilk 22 Zernike katsayıları (üstte) ve orijinal ile modelin tahmin ettiği Zernike katsayılarının nm biriminden farkına (altta) dair GUI üzerinden gösterimi sunulmuştur.

Şekil 42, Şekil 43, Şekil 44, Şekil 45, Şekil 46, Şekil 47, Şekil 48, Şekil 49, Şekil 50, Şekil 51, Şekil 52, Şekil 53, Şekil 54, Şekil 55, Şekil 56, Şekil 57, Şekil 58, Şekil 59, Şekil 60, Şekil 61 ve Şekil 62’de DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği ilk 22 Zernike ölçümlerinin hata (sapma) miktarı histogramları gösterilmiştir.


Şekil 63’de DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin edilen hata miktarlarının ortalamaları ve medyan değerlerinin histogramı gösterilmiştir.




Şekil 40. DAG AO Simülasyonunun “DL WF Zernike Analizi” sekmesinde seçili (**psf_0.fits**) bir verinin Zernike katsayılarının nm biriminden farkına (altta) dair gösterim




Şekil 41. DAG AO Simülasyonunun “DL WF Zernike Analizi” sekmesinde seçili (**psf_34.fits**) bir verinin Zernike katsayılarının nm biriminden farkına (altta) dair gösterim




Şekil 42. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 1. Zernike hata (sapma) miktarı histogramı




Şekil 43. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 2. Zernike hata (sapma) miktarı histogramı




Şekil 44. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 3. Zernike hata (sapma) miktarı histogramı




Şekil 45. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 4. Zernike hata (sapma) miktarı histogramı




Şekil 46. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 5. Zernike hata (sapma) miktarı histogramı




Şekil 47. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 6. Zernike hata (sapma) miktarı histogramı




Şekil 48. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 7. Zernike hata (sapma) miktarı histogramı




Şekil 49. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 9. Zernike hata (sapma) miktarı histogramı




Şekil 50. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 10. Zernike hata (sapma) miktarı histogramı




Şekil 51. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 12. Zernike hata (sapma) miktarı histogramı




Şekil 52. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 11. Zernike hata (sapma) miktarı histogramı




Şekil 53. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 13. Zernike hata (sapma) miktarı histogramı




Şekil 54. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 14. Zernike hata (sapma) miktarı histogramı




Şekil 55. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 15. Zernike hata (sapma) miktarı histogramı




Şekil 56. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 16. Zernike hata (sapma) miktarı histogramı




Şekil 57. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 17. Zernike hata (sapma) miktarı histogramı




Şekil 58. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 18. Zernike hata (sapma) miktarı histogramı




Şekil 59. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 19. Zernike hata (sapma) miktarı histogramı




Şekil 60. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 20. Zernike hata (sapma) miktarı histogramı



Şekil 61. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 21. Zernike hata (sapma) miktarı histogramı



Şekil 62. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin ettiği 22. Zernike hata (sapma) miktarı histogramı



Şekil 63. DAG AO simülasyonundaki derin öğrenme (UNET) modelinin tahmin edilen hata miktarlarının ortalamaları ve medyan değerlerinin histogramı

Tablo 5. Gerchberg-Saxton Algoritması ve DL Modeline Ait İstatistik Tablosu

Zernike #	Medyan [nm]	Ortalama [nm]	Standart Sapma
1	-2.72E-03	-2.67E-03	1.41E-02
2	-3.60E-03	-1.38E-03	1.79E-02
3	-6.89E-04	7.71E-04	1.14E-02
4	-7.99E-04	-5.98E-04	1.09E-02
5	-1.50E-03	-1.08E-03	1.13E-02
6	-1.07E-03	-8.80E-04	9.27E-03
7	1.36E-03	9.54E-05	8.19E-03
8	9.39E-04	7.72E-05	8.17E-03
9	-1.97E-03	-2.01E-03	8.02E-03
10	-4.44E-04	-5.02E-04	9.19E-03
11	6.01E-04	8.22E-04	6.84E-03
12	6.13E-05	-1.62E-04	6.95E-03
13	-1.87E-04	1.03E-05	6.32E-03
14	6.79E-04	-1.32E-04	7.28E-03
15	1.26E-04	2.06E-04	7.93E-03
16	-3.83E-04	6.77E-05	6.95E-03
17	3.74E-04	6.97E-04	6.02E-03
18	-4.51E-04	-4.00E-04	6.16E-03
19	-3.593E-04	-1.10E-03	5.23E-03
20	-1.028E-03	1.23E-04	7.348E-03
21	-5.795E-04	-9.45E-04	6.37E-03
22	6.970E-04	2.84E-04	5.92E-03

İstatistiksel Karşılaştırma ve Yorumlama

Tablo 5'te Gerchberg-Saxton algoritması ve DL modeline ait istatistik tablosu sunulmuştur. İlk 22 Zernike terimi üzerinden yapılan inceleme sonucunda, optik sistemin dalga cephesi hatalarının karakteristiği detaylı olarak ortaya konmuştur.

Zernike polinomlarının çoğunda (örneğin Zernike 1, 2, 5, 9, 10) hem medyan hem de ortalama değerler negatif bulunmuştur. Bu durum, sistemin negatif yönlü bir sapma eğilimi gösterdiğini ve düzenli olarak belirli türde dalga cephesi hatalarının ortaya çıktığını göstermektedir. Buna karşılık, bazı polinomlarda (Zernike 7, 11, 17) medyan ve ortalama değerlerin pozitif olduğu gözlemlenmiştir. Bu durum, ilgili terimler için optik sistemde pozitif sapmaların mevcut olduğunu işaret etmektedir.

Medyan ve ortalama değerler arasındaki fark incelendiğinde, bazı terimlerde bu farkın düşük olduğu (Zernike 4, 10, 13) ve dolayısıyla verilerin daha simetrik dağıldığı görülmektedir.

Buna karşılık, Zernike 7 ve 20 gibi terimlerde ortalama ve medyan değerler arasında önemli farklılıklar mevcuttur; bu durum, ilgili terimlerde verilerin asimetrik bir dağılım gösterdiğini düşündürmektedir.

Standart sapma, dalga cephesi hatalarının varyasyonunu belirlemek açısından kritik bir parametredir. Zernike 2, 3 ve 5 gibi terimlerde yüksek standart sapma değerleri gözlenmiştir. Bu sonuç, bu terimlerin daha değişken olduğunu ve optik sistemin bu bölgelerde daha fazla dalgalanmaya maruz kaldığını göstermektedir. Diğer taraftan, Zernike 19 ve 22 gibi terimlerde standart sapma değerlerinin düşük olduğu tespit edilmiştir. Bu, bu terimlerin daha kararlı hatalarla ilişkilendirildiğini ve sistemin daha az değişkenlik gösterdiğini ifade etmektedir.

Optik sistemin genel performansı değerlendirildiğinde, bazı Zernike terimlerinin (Zernike 4, 10, 13) medyan ve ortalama değerlerinin sıfıra yakın olması, bu terimler için dalga cephesi hatalarının minimal olduğunu göstermektedir. Ancak, Zernike 2, 5 ve 9 gibi terimlerde yüksek varyasyonlar ve sapmalar sistemdeki hataların etkisini artırmaktadır. Özellikle standart sapması yüksek olan terimler, optik sistemin tutarsız performans sergileyebileceği alanları işaret etmektedir. Buna karşın, düşük standart sapma gösteren terimler, daha kararlı fakat sürekli hataların bulunduğu bölgeleri göstermekte olup, bu alanlar sistemin performansını olumsuz etkileyebilir.

Tablo 6. GS Algoritması ve DL Modeline Ait İstatistik Tablosu

İstatistikler	Gerchberg-Saxton Algoritması Sonuçları	Derin Öğrenme Modeli Sonuçları
Farklı Veri Sayısı	100	100
Ortalama	7,42 (sn)	2,46 (sn)
Standart Sapma	0,04	0,05
Minimum Değer	7,37 (sn)	2,31 (sn)
Medyan Değer	7,41 (sn)	2,44 (sn)
Maksimum Değer	7,58 (sn)	2,66 (sn)

Tablo 6'daki değerlere göre:

- **Ortalama sürede:** Fark: 4,96 sn, Oran: 3,01
- **Minimum değerde:** Fark: 5,06 sn, Oran: 3,19
- **Medyan değerde:** Fark: 4,97 sn, Oran: 3,03
- **Maksimum değerde:** Fark: 4,92 sn, Oran: 2,84

Tablo 6'da paylaşılan istatistikleri inceleyerek Gerchberg-Saxton (GS) ve Derin Öğrenme (DL) modelinin performansını analiz edebilir. Tablodaki değerler, GS ve DL modelinin işlem sürelerini (saniye biriminde) temsil etmektedir.

Tablo 6'daki veriler incelendiğinde en uzun sürede çalışan Derin Öğrenme modelinin (2.66 sn), Gerchberg-Saxton algoritması ile ölçülen (7.58sn) değerden yaklaşık 2.8 kat daha hızlı olduğu gözlenmiştir. Medyan değerlerde ise farkın **4,9 sn** ve oranın yaklaşık **3 kat** olduğu görülmektedir.

Şekil 63'de Zernike polinomlarına dayanan dalga cephesi sapmalarını temsil eden iki veri setini karşılaştırılmıştır. Grafikte mavi çizgi “Ortanca” değerleri ve turuncu çizgi “Ortalama” değerleri temsil etmektedir. Şekil 63 analizi, Zernike polinomlarına dayalı dalga cephesi sapmalarının karşılaştırıldığı iki veri setini temsil etmektedir. Mavi ve turuncu olarak gösterilen bu veri setleri, sırasıyla ortanca ve ortalama değerleri ifade etmektedir.

Şekil 63 yatay ekseninde dalga cephesi sapmaları (nm cinsinden), dikey ekseninde ise her bir sapma seviyesindeki gözlem sayıları (frekans) gösterilmektedir. Sapma değerlerinin -0.003 nm ile 0.01 nm arasında dağıldığı gözlemlenmektedir.

Grafikğin genel dağılımı incelendiğinde, her iki veri setinin de büyük oranda 0 nm civarında yoğunlaştığını göstermektedir. Bu, dalga cephesindeki sapmaların çoğunlukla küçük olduğu ve sistemin nispeten doğru sonuçlar verdiğini işaret etmektedir. Mavi veri seti (Ortanca Değerler), turuncu veri setine (Ortalama Değerler) kıyasla daha geniş bir yayılım sergilemektedir. Bu durum, ortanca değerlerin uç değerlerden daha az etkilenmesinden kaynaklanmaktadır. Ortalama değerler ise daha dar bir dağılım göstermekte ve 0'a yakın bir merkezde yoğunlaşmaktadır. Bu, ortalama değerlerin uç değerler tarafından daha fazla etkilenebileceğini ve bu nedenle dağılımın merkezine yakın kaldığını düşündürmektedir.


Grafikteki çakışmalar ve farklılıklar incelendiğinde, iki veri seti arasında, -0.002 nm ile 0.001 nm aralığında büyük ölçüde örtüşme gözlenmiştir. Ancak, 0.001 nm ve üzerindeki sapmalar için mavi veri seti daha yüksek frekans göstermektedir. Bu da ortanca değerlerin bu bölgede daha geniş bir sapma aralığına sahip olduğuna işaret ederken, turuncu veri seti negatif sapmalarda daha fazla gözlem içermektedir.

Histogramın genel dağılımı, sapmaların büyük bir kısmının 0 nm civarında toplandığını ve dalga cephesi hatalarının genellikle küçük olduğunu ortaya koymaktadır. Ancak, mavi veri setindeki geniş sapmalar, bazı durumlarda sistem performansının olumsuz etkilenebileceğini göstermektedir. Bu sapmaların azaltılması için model üzerinde optimizasyon çalışmaları önerilebilir. Özellikle uç değerlerdeki sapmaları kontrol altına almak, sistem performansını iyileştirebilir.

Şekil 64'de Gerchberg-Saxton algoritmasının zaman serisi analizi sunulmuştur. dikey-eksen, ölçüm sürecinin saniye (sn) biriminde temsil etmektedir. Bu parametrenin değeri 7.371

sn ile 7.538 sn arasında değişmekte olup her çevrimde ölçülen süreyi göstermektedir. Yatay eksen yapılan ölçümlerin sayısını göstermektedir. Grafikte toplamda 100 ölçüm yer almakta ve zaman serisinin bu ölçümler boyunca nasıl değiştiği izlenmektedir.

Kırmızı çizgi, tüm ölçümlerin ortalamasını (7.425 sn) temsil etmektedir. Verilerin büyük bir kısmı bu ortalama değere yakın seyretmekte olup, ölçümlerde genellikle bu değer çevresinde dalgalanmalar görülmektedir. Minimum değer (7.371 sn) yeşil çizgi ile temsil edilmiştir. Maksimum değer (7.538 sn) mavi çizgi ile gösterilmektedir. Veri seti genel itibarıyla ortalama değer etrafında dalgalanmalar sergilemekle birlikte, belirli ölçümlerde (özellikle 60. ve 90. ölçümler) gözlemlenen ani artışlar algoritmanın davranışında sapmalara neden olmaktadır. Bu sapmaların, algoritmanın bu ölçümler sırasında karşılaştığı hata ya da beklenmedik koşulların bir sonucu olduğu düşünülebilir.




Şekil 64. Gerchberg-Saxton algoritmasının 100 tekrarda ölçülen zaman serisi grafiği

Şekil 65'te derin öğrenme algoritmasının bir zaman serisi analizi yer almaktadır. İlgili analiz, verilerin genel davranışını ve algoritmanın performansını anlamaya yönelik önemli ipuçları sunmaktadır.

Şekil 65'te Y-ekseni, zaman birimi olan saniye (s) cinsinden ölçülen bir büyüklüğü göstermektedir. Y-ekseni değerleri 2.3173 s ile 2.6172 s arasında değişmektedir. Bu, derin öğrenme algoritmasının tahmin ettiği veya modellediği bir zaman serisini ifade etmektedir. X-ekseni, 100 farklı ölçümün yer aldığı zaman serisini göstermektedir. Her bir ölçüm, algoritmanın farklı zaman dilimlerinde elde ettiği süreleri temsil etmektedir.

Şekil 65'te yer alan kırmızı çizgi, zaman serisinin ortalama değerini göstermektedir. Algoritmanın tahmin ettiği süreler genellikle bu ortalama etrafında değişmekte, ancak zaman zaman belirgin sapmalar meydana gelmektedir.



Şekil 65. Derin Öğrenme algoritmasının 100 tekrarda ölçülen zaman serisi grafiği

Şekil 65'te en düşük değer (2.3173 sn) yeşil çizgi ile temsil edilmiştir ve algoritmanın en düşük tahmin ettiği süreyi göstermektedir. En yüksek değer (2.6172 s) mavi çizgi ile gösterilmiştir ve en yüksek tahmin edilen süreyi temsil etmektedir.

Şekil 65'te 20. ölçüm civarında dikkat çeken büyük bir sapma gözlemlenmektedir. Algoritma, bu ölçümde hem minimum hem de maksimum değerlere yakın süreler tahmin etmiş, bu da önceki ve sonraki ölçümlerle kıyaslandığında farklı bir davranış sergilediğini göstermektedir. Benzer şekilde 30. ölçüm civarında da bir sapma bulunmaktadır. Bu sapma, ortalama değerden belirgin bir uzaklaşma göstermekte, ancak önceki sapma kadar büyük değildir. Şekil 65'te genel olarak algoritmanın tahmin ettiği sürelerin ortalama etrafında dalgalandığını göstermektedir.

SONUÇLAR ve ÖNERİLER

Bu tez çalışmasında, Türkiye Ulusal Gözlemevleri ATASAM-DAG Doğu Anadolu Gözlemevi yerleşkesinde kurulmuş olan DAG 4 metre teleskopu için tasarlanan adaptif optik (AO) sistemine yönelik olarak makine öğrenimi (ML) ve derin öğrenme (DL) teknikleri ile model tabanlı algoritma geliştirmeye çalışmaları yapılmıştır.

Araştırma bulgularında sunulan veriler doğrultusunda, model tabanlı yaklaşım mevcut AO sistemlerinin performansını iyileştirmeye yönelik olarak büyük bir potansiyel taşımaktadır. Geliştirilen model aynı zamanda DAG 4m teleskop AO sistemi için hem bir test ortamı sunmaktadır hem de bir geliştirme aracı olarak kullanılabilecektir.

Tez kapsamında geliştirilen yazılım ve grafiksel kullanıcı arayüzü (GUI), kullanıcıların doğrudan DAG 4m teleskop AO sistemine erişmeden simülasyonlar gerçekleştirmelerine olanak tanıyan bir platform olarak değerlendirilebilir. Yazılımın ve kullanıcı ara yüzünün sunduğu fonksiyonellik, kullanıcıların farklı atmosferik koşullarda sistem performansını değerlendirebilmesine imkan tanımaktadır. Ayrıca, DAG 4m teleskop AO sistemi simülasyonları, kullanıcıların veya personelin eğitim süreçlerine yardımcı olacağı düşünülmektedir.

Özellikle yazılımın DAG-MAM sistemi ile entegrasyonu özelliği sayesinde, DAG 4m teleskop AO sistemi anlık meteorolojik verilerle uyumlu olarak çalışmakta ve bu veriler kullanılarak optik sisteminin tahmini Strehl oranı hesaplanabilmektedir. Strehl oranı, optik sistemin teorik maksimum performansa ne kadar yakın olduğunu gösteren bir ölçüttür ve bu tahmin, sistemin atmosferik türbülans gibi dış faktörlerden ne derece etkilendiğini anlamada önemli bir belirteçtir. Bu özellik, DAG 4m teleskop AO sistemi için önemli bir avantaj sağlamaktadır, çünkü sistemin performansını etkileyen faktörlerin daha hassas bir şekilde tahmin edilmesine ve buna uygun düzeltmelerin yapılmasına olanak tanımaktadır.

Bu tezde geliştirilen model, sentetik ve gerçek verilerin birlikte kullanıldığı bir eğitim sürecini desteklemektedir. DAG'dan alınacak gerçek görüntülerle beslenecek model eğitimi ile öncesinde sentetik verilerle ardından gerçek verilerle doğrulama yapılarak daha yüksek doğruluk oranları elde edebilir. Bu yöntem, modelin gerçek dünya koşullarında daha etkili ve güvenilir sonuçlar vermesini sağlamaktadır.

Modelin hem sentetik hem de DAG 4m teleskop optik sistemlerinin üreteceği veriler ile eğitilebilmesi, farklı optik yapılandırmaların test edilmesine ve bu yapılandırmaların DAG AO sistemi üzerindeki etkilerinin önceden analiz edilmesine olanak tanıyacaktır. Bu özellik, yeni projelerin önerilmesinde, değerlendirilmesinde veya mevcut projelerin optimize edilmesi gerektiğinde büyük bir avantaj sunacaktır.

Tez çalışmasında elde edilen bulgular, DAG 4m Teleskop AO sistemine yönelik gelecekte yapılacak projeler için bir rehber niteliğindedir. Sunduğumuz bulgulardan görülebileceği üzere, geliştirdiğimiz model dalga cephesi ölçüm algoritmasının Gerchberg-Saxton algoritmasına göre aynı donanımlarda çalışmasına rağmen benzer doğruluk değerlerinde ve çok daha kısa zamanında sonuç üretebilmektedir. Adaptif optik gibi atmosferik ve astronomik koşulların birim zamanda çok hızlı değiştiği karmaşık ortamda hızlı ve doğru ölçüm almak gözlemin önemli faktörlerdir. Bu perspektiften bakıldığında model ile analiz yapmak ciddi bir avantaj oluşturmaktadır. Simülasyon aracılığıyla elde edilen sonuçlar, potansiyel projelerin başarısını tahmin etmek için kullanılabilir. Örneğin, DAG 4m teleskop AO sisteminin farklı atmosferik koşullar altında nasıl performans göstereceğini anlamak için simülasyonlar yapılabilecek ve bu simülasyon sonuçları, projelerin başlangıç aşamasında tercih kararlarının alınmasına yardımcı olabilecektir. Ayrıca, modelin tahmin yetenekleri, DAG 4m teleskop AO sisteminin performansını optimize etmek için kullanılabilir ve böylece daha iyi gözlem sonuçları elde edilmesine katkıda bulunabilir.

Geliştirilen model, mevcut çalışmada simülasyon verileri ile eğitilmiştir. DAG 4m Teleskop sisteminden elde edilecek veriler ile modelin yeniden eğitilmesi, sistemin gerçek dünyadaki koşulları daha iyi öğrenmesini ve adaptif optik sistemleri için daha hassas ve güvenilir tahminler üretmesini sağlayacaktır. Bu süreçte, gözlem verilerinin çeşitliliğini artırarak modelin genelleme kabiliyetini güçlendirmek ve daha karmaşık optik sistemlere uyum sağlamasını sağlamak öncelikli hedefler arasındadır. Ayrıca, modelin performansını artırmak için farklı derin öğrenme mimarilerinin ve hiperparametre optimizasyon tekniklerinin incelenmesi de gelecekteki araştırmaların önemli bir parçasını oluşturacaktır. Bunun yanı sıra, geliştirilen yaklaşımın farklı adaptif optik sistemlerine entegre edilmesi ve genişletilebilir bir kontrol altyapısı sunması hedeflenmektedir.

Sonuç olarak, bu tez çalışması, DAG 4m teleskop AO sistemi için makine öğrenimi ve derin öğrenme tekniklerinin uygulanabilirliğini göstermiş olup, bu tekniklerin AO sistemlerinin performansını optimize etmek için kullanılabilirliğini ortaya koymuştur. Geliştirilen model ve yazılım, DAG AO sisteminin daha iyi anlaşılmasını, optimize edilmesini ve gelecekteki projelerin başarısını artırmasını sağlayacak önemli araç olarak görülmektedir.

KAYNAKLAR

- Abdulkadyrov, M. A., Semenov, A. P., Belousov, S. P., Vladimirov, N. M., Ignatov, A. N., Patrikeev, V. E., Keskin, O., 2018. Production of M1, M2 and M3 for DAG project (Belgium, Russia): current status. In *Advances in Optical and Mechanical Technologies for Telescopes and Instrumentation III* (Vol. 10706, pp. 887-900). SPIE
- Alcor-system Cyclope Seeing Monitor (SM) (2024). <https://www.alcor-system.com/new/SeeingMon/Cyclope.html>
- ALPAO Deformable Mirrors (DMs) (2024). <https://www.alpao.com/wp-content/uploads/2021/03/Deformable-Mirrors-and-Modal-datasheet-rev-2021a.pdf>
- Ando, H. (2002, September). Subaru Telescope: status report. In *Large Ground-based Telescopes* (Vol. 4837, pp. 821-830). SPIE.
- Balbay R., Şatır, O., Yeşilyaprak, C., İlker, A., Mamur, A., Arabacı, H., Temir, İ., Eastern Anatolia Observatory (DAG) – Turkish State Meteorological Service (TSMS) Automated Weather Observing Systems, 10th International Symposium on Atmospheric Sciences, <https://www.atmosfer.itu.edu.tr/atmos2022/abstracts/>
- Balbay, R., Kaba, K., Fişek, S., Yeşilyaprak, C. (2024). Evaluation of PWV products derived from satellite-based and radiosonde retrievals for the eastern anatolia observatory (DAG). *Experimental Astronomy*, 58(1), 2.
- Balbay, R., Tugrul Tezcan, C., Shaemoni Niaei, M., Satır, O., Yeşilyaprak, C. (2020). DAG-MAM: Eastern Anatolia Observatory Meteorological and Astronomical Monitoring System. *Astronomical Data Analysis Software and Systems XXIX*, 527, 567.
- Bishop, C. M., Bishop, H. (2023). *Deep learning: Foundations and concepts*. Springer Nature.
- Bolbasova, L. A., Andrakhanov, A. A., Shikhovtsev, A. Y., The application of machine learning to predictions of optical turbulence in the surface layer at Baikal Astrophysical Observatory, *Monthly Notices of the Royal Astronomical Society*, Volume 504, Issue 4, July 2021, Pages 6008–6017, <https://doi.org/10.1093/mnras/stab953>
- Bowen, I. S. (1967). *Astronomical optics*. *Annual Review of Astronomy and Astrophysics*, vol. 5, p. 45, 5, 45
- Bradt, H. (2003). *Astronomy Methods*. *Astronomy Methods*, 458.
- Davies, R., Kasper, M. (2012). *Adaptive Optics for Astronomy*. In *Annual Review of Astronomy and Astrophysics* (Vol. 50, Issue 1, pp. 305–351). Annual Reviews. <https://doi.org/10.1146/annurev-astro-081811-125447>
- Deng, L. (2016). *Deep learning: from speech recognition to language and multimodal processing*. *APSIPA Transactions on Signal and Information Processing*, 5, e1.
- Fowler, J., and Landman, R., (2023). *Tempestas ex machina: A review of machine learning methods for wavefront control*. <https://arxiv.org/abs/2309.00730>
- Ge, Z., Song, Z., Ding, S. X., Huang, B., *Data Mining and Analytics in the Process Industry: The Role of Machine Learning*. in *IEEE Access*, vol. 5, pp. 20590-20616, 2017, <https://doi.org/10.1109/ACCESS.2017.2756872>
- Gerchberg, R. W. (1972). A practical algorithm for the determination of plane from image and diffraction pictures. *Optik*, 35(2), 237-246.

- Gonsalves, R. A., Phase retrieval and diversity in adaptive optics. *Opt. Eng.* 21, 829–832 (1982).
- Goodfellow, I. (2016). Deep learning.
- Guyon, O., Limits of Adaptive Optics for High-Contrast Imaging 2005. *The Astrophysical Journal*, Volume 629, 2005 ApJ 629 592, <https://doi.org/10.1086/431209>
- HCIPy (2024) <https://github.com/ehpor/hcipy>
- Hickson, P. Atmospheric and adaptive optics. *Astron Astrophys Rev* 22, 76 (2014). <https://doi.org/10.1007/s00159-014-0076-9>
- Hochreiter, S. (1997). Long Short-term Memory. *Neural Computation* MIT-Press.
- Keskin, O., Jolissaint, L., Bouxin, A., Yesilyaprak, C. (2022, August). TROIA adaptive optics system for DAG telescope: assembly and laboratory performance prior to on-sky assessment. In *Adaptive Optics Systems VIII* (Vol. 12185, pp. 567-578). SPIE.
- Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Laj, P., Klausen, J., Bilde, M., Plass-Duelmer, C., Pappalardo, G., Clerbaux, C., Zardini, A. A. (2009). Measuring atmospheric composition change. *Atmospheric environment*, 43(33), 5351-5414.
- LeCun, Y., Bengio, Y. Hinton, G. Deep learning. *Nature* 521, 436–444 (2015). <https://doi.org/10.1038/nature14539>
- Liang, W., Tao, C., Xudong, L., Peifeng, W., Xinyue, L., Jianlu, J. (2016). Performance measurement of adaptive optics system based on Strehl ratio. *The Journal of China Universities of Posts and Telecommunications*, 23(3), 94-100.
- Liaudat, T. I., Starck, J. L., Kilbinger, M. (2023). Point spread function modelling for astronomical telescopes: a review focused on weak gravitational lensing studies. *Frontiers in Astronomy and Space Sciences*, 10, 1158213.
- Linhai, H., Rao, C. (2010). Wavefront sensorless adaptive optics: a general model-based approach. *Optics express*, 19(1), 371-379.
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*., 9(1), 381-386.
- Meher, S. K., Panda, G. (2021). Deep learning in astronomy: a tutorial perspective. *The European Physical Journal Special Topics*, 230(10), 2285-2317.
- Mugnier, L. M., Blanc, A., Idier, J. (2006). Phase diversity: a technique for wave-front sensing and for diffraction-limited imaging. *Advances in Imaging and Electron Physics*, 141, 1-76.
- Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons. b*, 4(51-62), 56.
- Nelson, J. E., Mast, T. S. (1990, July). Construction of the keck observatory. In *Advanced Technology Optical Telescopes IV* (Vol. 1236, pp. 47-55). SPIE.
- Nelson, J., Sheinis, A. (n.d.). Modern Optical Design. In *NATO Science Series II: Mathematics, Physics and Chemistry* (pp. 37–48). Kluwer Academic Publishers. https://doi.org/10.1007/1-4020-3437-7_04
- Neptune from the VLT with and without adaptive optics (no date) www.eso.org. Available at: <https://www.eso.org/public/images/eso1824b/> (Accessed: 30 August 2024).

- Niu, K., Tian, C. (2022). Zernike polynomials and their applications. *Journal of Optics*, 24(12), 123001.
- NumPy (2024). <https://numpy.org/about/>
- Nüvü Hnü 128 (2024). <https://www.nuvucameras.com/products/hnu-128/>
- NVIDIA CUDA (2024). <https://developer.nvidia.com/about-cuda>
- Özdemir, S., Yeşilyaprak, C., Aktuğ, B., Öztürk, D., Coker, D., Balbay, R. (2018). Precipitable water vapor (PWV) estimations from the site of the Eastern Anatolia Observatory*(DAG), a new astronomical observatory in Turkey. *Experimental Astronomy*, 46, 323-336
- P. P. Shinde and S. Shah, A Review of Machine Learning and Deep Learning Applications. 2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBE), Pune, India, 2018, pp. 1-6, <https://doi.org/10.1109/ICCUBE.2018.8697857>
- Pedrotti, F. L., Pedrotti, L. M., Pedrotti, L. S. (2018). *Introduction to optics*. Cambridge University Press.
- Pirnay, O., Albart, P., Bastin, C., Ville, J., Gabriel, E., Leseur, T., Lousberg, G. P., Méant, L., Orban, S., Tortolani, J. M., Amalfi, M., Marchiori, G., Rampini, F., Busatta, A., Yeşilyaprak, C., Keskin, O., DAG 4m telescope: optics completion, on-site integration and test. *Proc. SPIE 12182, Ground-based and Airborne Telescopes IX*, 121824A, <https://doi.org/10.1117/12.2632248>
- Por, E. H., Haffert, S. Y., Radhakrishnan, V. M., Doelman, D. S., van Kooten, M., Bos, S. P. (2018). High Contrast Imaging for Python (HCIPy): an open-source adaptive optics and coronagraph simulator. In *Adaptive Optics Systems VI* (Vol. 10703, pp. 1112-1125). SPIE.
- PostgreSQL (2024). <https://www.postgresql.org/about/>
- PyQt (2024). <https://riverbankcomputing.com/software/pyqt/intro>
- Python (2024). <https://www.python.org/about/>
- PyTorch (2024). <https://pytorch.org/features/>
- Quirrenbach, A. (2004). *The Effects of Atmospheric Turbulence on Astronomical Observations*.
- Rao, C., Zhong, L., Guo, Y., Li, M., Zhang, L., Wei, K. (2024). Astronomical adaptive optics: a review. In *PhotonIX* (Vol. 5, Issue 1). Springer Science and Business Media LLC. <https://doi.org/10.1186/s43074-024-00118-7>
- Ronneberger, O., Fischer, P., Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Medical image computing and computer-assisted intervention—MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III* 18 (pp. 234-241). Springer International Publishing, 21, 829–832 (1982).
- Rousset, G., Lacombe, F., Puget, P., Hubin, N. N., Gendron, E., Conan, J. M., Rigaut, F. J. (1998). Design of the Nasmyth adaptive optics system (NAOS) of the VLT. In *Adaptive optical system technologies* (Vol. 3353, pp. 508-516). SPIE.
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., Hassabis, D. (2016). Mastering the game of Go with deep neural networks and tree search. *nature*, 529(7587), 484-489.

- Sterken, C., Manfroid, J. (1992). Atmospheric turbulence: scintillation and seeing. In: *Astronomical Photometry. Astrophysics and Space Science Library*, vol 175. Springer, Dordrecht. https://doi.org/10.1007/978-94-011-2476-8_7
- Stonex S8-Plus GNSS Receiver (2024). <https://www.stonex.it/project/s8-plus/>
- Sutton, R. S. (2018). *Reinforcement learning: An introduction*. A Bradford Book.
- Swanson, R., Lamb, M., Correia, C., Sivanandam, S., Kutulakos, K. (2018). Wavefront reconstruction and prediction with convolutional neural networks. In *Adaptive Optics Systems VI* (Vol. 10703, pp. 481-490). SPIE.
- Tezcan, C. T., 2024. Doğu Anadolu Gözlemevi (DAG) yerleşkesinin atmosferik türbülans ve görüş gözlemleri ile atmosferik profilinin elde edilmesi. Doktora Tezi, Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Erzurum.
- Townson, M. J., Farley, O. J. D., Orban de Xivry, G., Osborn, J., and Reeves, A. P. (2019), "AOtools: a Python package for adaptive optics modelling and analysis," *Opt. Express* 27, 31316-31329, <https://doi.org/10.1364/OE.27.031316>
- Travouillon, T., Ashley, M. C. B., Burton, M. G., Storey, J. W. V., Loewenstein, R. F. (2003). Atmospheric turbulence at the South Pole and its implications for astronomy. *Astronomy & Astrophysics*, 400(3), 1163-1172.
- VAISALA Weather Transmitter (2024). <https://www.vaisala.com/en/products/weather-environmental-sensors/weather-transmitter-wxt530-series>
- Vanberg, P., O. (2019). Machine learning for image-based wavefront sensing. Yüksek Lisans Tezi. Université de Liège, Belçika. <https://matheo.uliege.be/handle/2268.2/6800>
- Villanueva, G.L., Smith, M.D., Protopapa, S., Faggi, S., Mandell, A.M.: Planetary spectrum generator: an accurate online radiative transfer suite for atmospheres, comets, small bodies and exoplanets. *J. Quant. Spectrosc. Radiat. Transfer* 217, 86–104 (2018). <https://doi.org/10.1016/j.jqsrt.2018.05.023>
- Vorontsov, A.M.; Vorontsov, M.A.; Filimonov, G.A.; Polnau, E. Atmospheric Turbulence Study with Deep Machine Learning of Intensity Scintillation Patterns. *Appl. Sci.* 2020, 10, 8136. <https://doi.org/10.3390/app10228136>
- Wang, K., Zhang, M., Tang, J., Wang, L., Hu, L., Wu, X., Zhao, J. (2021). Deep learning wavefront sensing and aberration correction in atmospheric turbulence. *Photonix*, 2(1), 8.
- Wang, N., Zhu, L., Ma, S., Zhao, W., Ge, X., Gao, Z., Yang, P. (2022). Deep learning-based prediction algorithm on atmospheric turbulence-induced wavefront for adaptive optics. *IEEE Photonics Journal*, 14(5), 1-10.
- Wells, D. C., Greisen, E. W. (1979). FITS-a flexible image transport system. In *Image processing in astronomy* (p. 445).
- Yesilyaprak, C., Keskin, O., Jolissaint L., Eastern Anatolia Observatory (DAG): the status in 2022, towards the first light. *Proc. SPIE 12182, Ground-based and Airborne Telescopes IX*, 121820X (29 August 2022) <https://doi.org/10.1117/12.2630889>
- Yohei Nishizaki, Matias Valdivia, Ryoichi Horisaki, Katsuhisa Kitaguchi, Mamoru Saito, Jun Tanida, and Esteban Vera, Deep learning wavefront sensing. *Opt. Express* 27, 240-251 (2019)
- Zhang, Q., Yu, H., Barbiero, M. *et al.* Artificial neural networks enabled by nanophotonics. *Light Sci Appl* 8, 42 (2019). <https://doi.org/10.1038/s41377-019-0151-0>

Zhao, X., Wang, L., Zhang, Y. *et al.* A review of convolutional neural networks in computer vision. *Artif Intell Rev* 57, 99 (2024). <https://doi.org/10.1007/s10462-024-10721-6>



ÖZGEÇMİŞ

Kişisel Bilgiler
Adı Soyadı: Recep BALBAY
Uyruğu:
Adres:
E-mail:
Eğitim
Lisans:
Yüksek lisans:
Doktora:
Yabancı Dil Bilgisi
Üye Olunan Mesleki Kuruluşlar
Tez Süresince Üretilen Yayınlar