

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YAPAY ZEKÂ VE ROBOTİK ANABİLİM DALI

**PISA MATEMATİK OKURYAZARLIĞININ GRİ KURT
OPTİMİZASYON ALGORİTMASI İLE PERFORMANS DEĞERLENDİRMESİ**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Ecrin Nüda BAK
DANIŞMAN: Dr. Öğr. Üyesi Sanem ŞEHRİBANOĞLU

VAN-2022

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YAPAY ZEKÂ VE ROBOTİK ANABİLİM DALI

**PISA MATEMATİK OKURYAZARLIĞININ GRİ KURT OPTİMİZASYON
ALGORİTMASI İLE PERFORMANS DEĞERLENDİRMESİ**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Ecrin Nüda BAK

VAN-2022

KABUL VE ONAY SAYFASI

Yapay Zekâ ve Robotik Anabilim Dalı'nda Dr. Öğr. Üyesi Sanem ŞEHRİBANOĞLU danışmanlığında, Ecrin Nüda BAK tarafından sunulan “PISA Matematik Okuryazarlığının Gri Kurt Optimizasyon Algoritması ile Performans Değerlendirmesi” isimli bu çalışma Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili hükümleri gereğince 15/04/2022 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile başarılı bulunmuş ve Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan : Prof. Dr. Rıdvan SARAÇOĞLU

İmza:

Üye : Doç. Dr. Yılmaz KAYA

İmza:

Üye : Dr. Öğr. Üyesi Sanem ŞEHRİBANOĞLU

İmza:

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 15/04/2021 tarih ve 2021/45-I sayılı kararı ile onaylanmıştır.

İmza

Enstitü Müdürü

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Ecrin Nüda BAK



ÖZET

PISA MATEMATİK OKURYAZARLIĞININ GRİ KURT OPTİMİZASYON ALGORİTMASI ile PERFORMANS DEĞERLENDİRMESİ

BAK, Ecrin Nüda
Yüksek Lisans Tezi, Yapay Zekâ ve Robotik Anabilim Dalı
Tez Danışmanı: Dr. Öğr. Üyesi Sanem ŞEHRİBANOĞLU
Mayıs 2022, 67 sayfa

Bu tez çalışmasında, birçok alanda kullanılabilen optimizasyon problemlerinden meta-sezgisel algoritmalarından biri olan Gri Kurt algoritması incelenmiştir. Tezin uygulama kısmında üç yılda bir tekrarlanan PISA (Uluslararası Öğrenci Değerlendirme Programı) araştırmasının Türkiye 2018 verileri kullanılarak öğrencilerin matematik okuryazarlığında, öğrencilerin başarılarında etkisi olan değişkenlerin belirlenmesi amaçlanmıştır. Önceki çalışmalardan farklı olarak verinin sınıflandırmasında öznitelik seçimi için meta-sezgisel algoritmalarından Gri Kurt algoritması kullanılmış olup önemi ve etkisi detaylıca açıklanmıştır. Değerlendirme için yazılım ve programlama dili kullanılarak lojistik regresyon ile karşılaştırılmıştır.

Anahtar kelimeler: Genetik Algoritma, Gri Kurt Algoritması, İkili Gri Kurt Optimizasyonu, Lojistik Regresyon, Matematik Okuryazarlığı, Meta-sezgisel Algoritmalar, Özellik Seçimi, PISA

ABSTRACT

PERFORMANCE EVALUATION OF PISA MATHEMATICS LITERACY WITH GRAY WOLF OPTIMIZATION ALGORITHM

BAK, Ecrin Nüda
MSc., Artificial Intelligence and Robotics
Supervisor: Asstt. Prof. Dr. Sanem ŞEHRİBANOĞLU
May 2022, 67 pages

In this thesis, the Gray Wolf algorithm, which is one of the meta-heuristic algorithms that can be used in many areas, is examined. In the application part of the thesis, it is aimed to determine the variables that have an effect on the students' mathematical literacy and success by using the Turkey 2018 data of the PISA (International Student Assessment Program) research, which is repeated every three years. Unlike previous studies, the Gray Wolf algorithm, one of the meta-heuristic algorithms, was used for feature selection in the classification of data, and its importance and effect were explained in detail. It was compared with logistic regression using software and programming language for evaluation.

Keywords: Binary Grey Wolf Optimizer, Gray Wolf Algorithm, Genetic Algorithm, Feature Selection, Mathematics Literacy, Metaheuristic Algorithms, Logistic Regression, PISA



ÖN SÖZ

Yüksek Lisans öğrenim süresi boyunca desteklerini, ilgilerini ve yardımlarını esirgemeyen bana yol gösteren saygıdeğer ve kıymetli danışman hocam Sayın Dr. Sanem ŞEHRİBANOĞLU'na sonsuz teşekkürlerimi sunarım.

Lisansüstü öğrenim süresince şahsıma kazandırmış olduğu tecrübelerden,engin bilgi ve deneyimlerini benle paylaşan Yapay Zekâ ve Robotik Anabilim Dalı Başkanı Sayın Prof. Dr. Rıdvan SARAÇOĞLU' na teşekkürlerimi sunarım.

Çocukluğumdan beri yanımda olan aynı zamanda Yüksek Lisans öğrenim süresi boyunca desteğini, yardımlarını esirgemeyen, moral ve motivasyonumu yüksek tutmama sebebiyet veren arkadaşım Berivan TURAN' a sonsuz teşekkürlerimi sunarım.

Lisansüstü öğrenim süresince şahsıma kazandırmış oldukları tecrübelerden ötürü başta Yapay Zekâ ve Robotik Anabilim Dalına, değerli emekleri için Fen Bilimleri Enstitüsüne, sağlamış oldukları imkanlardan dolayı Van Yüzüncü Yıl Üniversitesi ve Mühendislik Fakültesine teşekkür ederim.

Eğitimim süresince maddi ve manevi desteklerini hiç eksik etmeyen her an yanımda olan aileme sonsuz teşekkürlerimi sunarım.

2022

Ecrin Nüda BAK



İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT.....	iii
ÖN SÖZ	v
İÇİNDEKİLER	vii
ÇİZELGELER LİSTESİ.....	ix
ŞEKİLLER LİSTESİ	xi
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ	1
1.1. PISA ve Matematik Okuryazarlığı	3
1.1.1. PISA (Uluslararası Öğrenci Değerlendirme Programı) nedir?	3
1.1.2. Matematik Okuryazarlığı.....	4
1.1.3. PISA (Uluslararası Öğrenci Değerlendirme Programı) nedir?	6
2. KAYNAK BİLDİRİŞLERİ	9
3. MATERYAL VE YÖNTEM.....	15
3.1. Meteryal.....	15
3.2. Yöntem.....	16
3.2.1. Meta-sezgisel algoritmalar.....	16
3.2.1.1. Evrime dayalı algoritmalar	18
3.2.1.2. Fizik tabanlı algoritmalar.....	21
3.2.1.3. İnsan davranışı ile ilgili algoritmalar	24
3.2.1.4. Sürü tabanlı algoritmalar	27
3.2.2. Gri Kurt Optimizasyon algoritması	28
3.2.2.1. İkili Gri Kurt Optimizasyon modeli 1.....	36
3.2.2.2. İkili Gri Kurt Optimizasyon modeli 2.....	38
3.2.3. K-NN	39
3.2.4. Lojistik regresyon	40
3.2.4.1. Lojistik Regresyon Matematiksel Modeli.....	42
4. BULGULAR.....	45
5. TARTIŞMA VE SONUÇ	53
KAYNAKLAR	57

	Sayfa
ÖZGEÇMİŞ	67



ÇİZELGELER LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. Yıllara göre PISA uygulamalarına ilişkin özet bilgiler	5
Çizelge 1.2. PISA ve Türkiye'nin matematik okuryazarlığı ortalamaları	5
Çizelge 3.1. Evrime dayalı algoritmalar ve yılı	18
Çizelge 3.2. Fizik tabanlı algoritmalar ve yılları	22
Çizelge 3.3. İnsan davranışı ile ilgili algoritmalar ve yılı	25
Çizelge 3.4. Sürü tabanlı algoritmalar ve yılı	28
Çizelge 4.1. BGWO' nun 30 kez çalıştırma sonucundaki performansı	45
Çizelge 4.1. BGWO' nun 30 kez çalıştırma sonucundaki performansı (devamı) .	46
Çizelge 4.2. BGWO1 ve BGWO2' nun farklı k değerleri için performansı	46
Çizelge 4.3. Matematik okuryazarlığında ön plana çıkan değişkenler	48
Çizelge 4.4. Model Katsayılarının Omnibus Testleri.	49
Çizelge 4.5. Model özeti	50
Çizelge 4.6. Lojistik Regresyon Sonucu Elde Edilen Sınıflandırma Tablosu	50
Çizelge 4.7. Lojistik regresyon analizi sonuçları	51

ŞEKİLLER LİSTESİ

Şekil	Sayfa
Şekil 1.1. Türkiye'nin 2003-2018 yılları matematik ortalama puanları	7
Şekil 3.1 Meta-sezgisel algoritmaların sınıflandırması	18
Şekil 3.2. Gri kurdun hiyerarşisi (baskınlık yukarıdan aşağıya azalır)	29
Şekil 3.3. GWO 'nun konum güncellemesi	30
Şekil 3.4. 2D ve 3D konum vektörleri ve olası sonraki.....	31
Şekil 3.5. GWO'da pozisyon güncelleme	33
Şekil 3.6. Av aramaya karşı ava saldırmak	34
Şekil 3.7. Lojistik Regresyon ve Lineer Regresyon modeli	41
Şekil 4.1. BGWO2' nin k=3 sınıflandırma tablosu	47
Şekil 4.2. BGWO2' nin k=5 sınıflandırma tablosu	47
Şekil 4.3. BGWO2' nin k=11 sınıflandırma tablosu	48



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklama

α	En uygun çözüm
β	İkinci en iyi çözüm
δ	Üçüncü en iyi çözüm
ω	En zayıf çözüm
$\vec{A}$	Katsayı vektörü
$\vec{C}$	Katsayı vektörü
t	Geçerli yinelemeyi gösterir
$\vec{D}$	Av ve kurt arasındaki vektör mesafesi
$\vec{X}(t)$	Kurdun sabit konumu
$\vec{X}_p$	Avın konumu
$\vec{X}$	Gri bir kurdun konum vektörünü gösterir
$\vec{X}(t + 1)$	Gri kurdun bir sonraki konumu

Kısaltmalar

Açıklama

AOA	Aritmetik Optimizasyon Algoritması
AOA	Arşimet Optimizasyon Algoritması
APO	Yapay Fizik Optimizasyon Algoritması
AVOA	Afrika Akbabaları Optimizasyon Algoritması
AI	Yapay Zekâ
ALO	Karınca Aslan İyileştiricisi
BOA	Kelebek optimizasyon algoritması
EDM	Eğitimsel Veri Madenciliği

Kısaltmalar

Açıklama

EMA	Döviz Piyasası Algoritması
BGWO	İkili Gri Kurt Optimizasyon
BGWO1	İkili Gri Kurt Optimizasyon Modeli 1
BGWO2	İkili Gri Kurt Optimizasyon Modeli 2
BSA	Geri İzleme Arama Optimizasyon Algoritması
BSO	Beyin Fırtınası Optimizasyon Algoritması
CapSA	Capuchin Arama Algoritması
CSA	Bukalemun Sürüsü Algoritması
CVO	Korona Virüsü Optimizasyon Algoritması
DA	Yusufçuk Algoritması
DDA	Diferansiyel Gelişim Algoritması
EKK	En Küçük Kareler
EMA	Döviz Piyasası Algoritması
ESA	Elektro-Arama Algoritması
ESA	Bul-Düzeltil-Bitir-İstismar-Analiz Algoritması
ES	Evrimsel stratejileri
EVOA	Mısır Akbabası Optimizasyon Algoritması
GA	Genetik Algoritma
GOA	Çekirge Optimizasyon Algoritması
GCO	Grup Danışmanlığı Optimizasyonu
GSK	Bilgi Paylaşımına Dayalı Algoritma
GTO	Yapay Goril Birlikleri Optimize Edici Algoritması
GWO	Gri Kurt Algoritması
HGS	Açlık Oyunları Arama Optimizasyon Algoritması
HHO	At Sürüsü Optimizasyon Algoritması
HHO	Harris Şahinleri Optimization Algoritması
KGMO	Kinetik Gaz Molekül Optimizasyonu
K-NN	K en yakın komşu
JA	Jaya Algoritması
LAPO	Yıldırım Eklenti Prosedürü Optimizasyonu

Kısaltmalar

Açıklama

LCA	Lig Şampiyonası Algoritması
MEB	Millî Eğitim Bakanlığı
MOAF	Diz Noktası Odaklı Çok Amaçlı Yapay Flora Optimizasyon Algoritması
MVO	Multi-Verse Optimizer
MS	Meta-sezgisel
ML	Maksimum Olabilirlik Tahmini
OECD	Ekonomik İş birliği ve Kalkınma Örgütü
PBO	Pity Böceği Optimizasyon Algoritması
PISA	Uluslararası Öğrenci Değerlendirme Programı
PSO	Parçacık sürü optimizasyonu
ROA	Remora Optimizasyon Algoritması
RSA	Sürüngen Arama Algoritması
SO	Yılan Optimizasyonu Algoritması
SFO	Sinerjistik Fibroblast Optimizasyonu
SFSA	Stokastik Fraktal Arama Algoritması
SCA	Sinüs-Kosinüs Algoritması
SCA	Su Döngüsü Algoritması
SPSS	Sosyal Bilimler İstatistik Paketi
TEO	Termal Değişim Optimizasyonu
TSA	Tanjant Arama Algoritması
VPL	Voleybol Premier Lig Algoritması
WEO	Su Buharlaştırma Optimizasyonu
WOA	Balina Optimizasyon Algoritması



1. GİRİŞ

Meta sezgisel (MS) algoritmalar, matematiksel olarak çözülemeyen ya da çözülmesi zaman alan zor problemlerin çözümünde en iyi metodun bulunmasında kullanılmaktadır. Geçmişten günümüze kadar birçok optimizasyon problemlerinin çözümünde kolaylık sağlamış olup bilim insanlarının ortak kullandığı yöntemlerden biri haline gelmiştir. Türev gerektirmediğinden ve uygulama kolaylığından dolayı mühendislik uygulamalarında da kullanılmaktadır. MS algoritmalar; pazarlama, işletme, yönetim, akıllı trafik sistemleri, sağlık hizmetleri ve tıp gibi farklı sektörlerdeki bazı gerçek sorunları çözmek için de uygulanmaktadır (Faris ve ark., 2018).

Yüksek boyuttaki veriyi ölçmede kolaylık sağlamak, alakasız ölçümleri ya da özellikleri ölçmek için doğadan ilham alan MS algoritmalar genellikle tercih edilir. Yüksek boyutlu verinin arama alanı arttıkça, hesaplaması hem zaman alıcı hale gelir hem de pahalıya mal olur. Bu yüzden gereksiz veriyi yok etmek ve ölçmek için bu çalışmada PISA matematik okuryazarlığı verisinde öznitelik seçme tekniği kullanılmaktadır (Momanyi ve ark., 2021; Al-Tashi ve ark., 2020).

Matematiğin çok özel ve kesin bir dili vardır ve öğrencilerin matematik okuryazarlığı yapabilmeleri için kelimeleri, sembolleri ve argümanları formüle etme yollarını anlayarak o dilde net bir şekilde iletişim kurabilmeleri gerekir (PISA, 2018). Öğrencilerin matematikle ilgilenmeden önce, kelimeleri anlamaları ve bu kelimeleri kullanarak “okuyabilmeleri” ve “yazabilmeleri” gerekir. Matematik dersinde okuma, öğrencilerin bir denklemi 'çözmesinden' bir ders kitabındaki paragrafları okumaya ve bir problemin ne istediğini anlamaya kadar çeşitli şekillerde olabilir. Nasıl ingilizce roman okuyabilmek için yeterli ingilizce kelime hazinesine sahip olmak bir ön koşulsa, disiplinde ilerlemek için matematiksel bir kelime hazinesine sahip olmak gerekir. Matematik dilini bilmek ve anlamak önemlidir çünkü matematik her yerdedir. Matematik, fizik, felsefe, uzay vb. birçok konu ile ilgilenir, yaşadığımız dünyayı anlamamızı sağlar bunun içinde bilimi iyice kavramak gerekir (Edelman ve Hutchison, 2014).

Matematik okuryazarlığı, “bireyin düşünen, üreten ve eleştiren bir vatandaş olarak bugün ve gelecekte karşılaşılabilecek sorunların çözümünde matematiksel düşünme ve karar verme süreçlerini kullanarak çevresindeki dünyada matematiğin oynadığı rolü anlama ve

tanıma kapasitesi” olarak tanımlanabilir (OECD, 2013). Matematik okuryazarlığı, öğrencilerin çeşitli durumlarda matematiksel problemlerin çözümlerini formüle ederek çözümleri ve yorumları dikkate alarak ortaya çıkan fikirleri etkili bir şekilde analiz etme, akıl yürütme ve iletme yeteneği ile ilgilidir (OECD 2009). Matematik okuryazarlığını geliştirmek, öğrencileri bilişsel olarak teşvik eden ve aynı zamanda gerçek dünyada pratik deneyimler toplamalarına izin veren bir öğrenme ortamı gerektirir. Bunu başarmak için, öğrencilere deney yapma, sözlü tartışmalara maruz kalma ve model oluşturma vb. faaliyetlere katılma fırsatı verilmelidir. Bu da bilimin matematik eğitimi ile bütünleşmesine ve uyum sağlamasına katkı sağlar (Höfer ve Beckmann, 2009).

Eğitimsel Veri Madenciliği (EDM), eğitim ortamında veri madenciliği tekniklerini kullanan disipline verilen isimdir. Eğitimde başarıyı artırmak ve öğrencilerin öğrenme sürecinde yaşadıkları durumları daha iyi değerlendirmek için eğitim veri tabanlarından faydalı bilgileri tahmin etmeye yardımcı olan bir araştırma alanıdır (Jalota ve Agrawal, 2019). Eğitim bilimlerinde öğrencilerin başarı durumlarını etkileyen etmenlerin belirlenmesi eğitimciler ve eğitim politika yapıcıları için önemli konular arasında yer almaktadır. Bu nedenden dolayı dünya çapında ülkeler arasında yapılan PISA çalışmaları büyük önem arz etmektedir. PISA çalışma sonuçları hem ülkelerin dünya çapında kendi konumlarını görebilmeleri hem de ülke içindeki öğrencilerin gelişim süreçlerini takip edilebilmesi açısından önemli bir yere sahiptir.

Bu çalışmada alışla gelen bilimsel yöntemlerden farklı olarak yapay zekanın alt dallarından olan meta-sezgisel yöntemlerden faydalanmıştır. Çalışmada verinin sınıflandırmasında, veri kümesi içerisinde hangi özelliklerin sonuç üzerinde etkili olduğunu belirlemek için makine öğrenme algoritması kullanılmıştır. Ayrıca Gri Kurt algoritmasının öznitelik seçimi (Feature selection) özelliği kullanılarak öne çıkan değişkenleri/öznitelikleri belirleyerek matematik okuryazarlık verisi ile ilgili sınıflandırma işlemlerinde daha iyi performans elde edilmiştir. Algoritma sadece sınıflandırma performansında değil, aynı zamanda özellik indirgemede de üstünlüğünü göstermektedir.

Algoritmanın başarısı, öğrencilerin matematik okuryazarlığını geliştirmek, matematik okuryazarlığının gelişimine katkıda bulunarak terminoloji, kavramlar, beceriler ve temsiller arasında bağlantılar kurmalarına yardımcı olacaktır. Algoritmanın önemi ve etkisi ileriki bölümlerde detaylıca açıklanmıştır.

1.1. PISA ve Matematik Okuryazarlığı

1.1.1. PISA (Uluslararası Öğrenci Değerlendirme Programı) nedir?

OECD tarafından düzenlenen PISA sınavları sosyal ve ekonomik hayata tam katılım için gerekli olan temel bilgi ve becerileri ne ölçüde edindiklerini değerlendiren, dünyanın her yerinden 15 yaşındaki öğrencilerin katıldığı üç yıllık bir ankettir. Öğrencilerin matematik, okuma ve fen alanlarındaki bilgi ve becerilerini ölçen uluslararası düzeyde bir araştırmadır. PISA değerlendirmeleri sadece zorunlu eğitimlerinin sonuna yaklaşan öğrencilerin öğrendiklerini tekrar edip edemeyeceklerini tespit etmez; ayrıca öğrencilerin öğrendiklerini nasıl kullanacaklarını, nasıl sonuçlar elde edeceklerini ve bilgilerini alışılmadık ortamlarda, okul içinde ve dışında ne kadar iyi uygulayabileceklerini incelerler (PISA, 2015).

1997 OECD tarafından başlatılan PISA, hükümetler tarafından 15 yaşındaki öğrenci başarısını düzenli olarak ve uluslararası kabul görmüş ortak bir çerçeve içinde ölçerek eğitim sistemlerinin sonuçlarını izleme taahhüdünü temsil etmektedir. Yetişkin yaşamıyla ilgili beceriler hakkındaki yargıları yansıtan yenilikçi yollarla, eğitim hedeflerinin tanımlanması ve uygulanmasında politika diyalogu ve iş birliği için yeni bir temel sağlamayı amaçlamaktadır. PISA değerlendirmesi, müfredattaki değişiklikleri yansıtan tutum, bilgi ve becerilerini ölçmek için geniş bir yaklaşım benimseyerek, günlük görevlerde ve zorluklarda bilginin kullanımına yönelik okul temelli yaklaşımın ötesine geçmektedir. PISA, okuma, matematik ve bilim alanlarını yalnızca öğrencilerin belirli konu bilgilerini yeniden üretip üretemeyecekleri açısından değil, aynı zamanda öğrendiklerinden çıkarım yapıp yapamayacakları ve bilgilerini yeni durumlarda uygulayıp uygulayamayacakları açısından da kapsar. PISA’da kullanılan matematik testleri oluşturulurken öğrencilerin gerçek yaşam durumlarına odaklanılmakta, sorunları çözmeye matematik becerileri üzerinde durulmakta olup okul iç ve okul dışı ortamlarda ne kadar iyi kullandıklarını inceler (OECD, 2019b; 2021).

PISA 2018 raporuna göre, ülkemizdeki öğrencilerin okuma, matematik ve fen kategorisinde yine OECD ortalamasının altında kalmış fakat önceki yıllara göre daha başarılı olmuştur. (OECD, 2019).

1.1.2. Matematik okuryazarlığı

PISA 2018 Matematik Okuryazarlığı Tanımı: “Bireyin matematiği çeşitli bağlamlarda formüle etme, kullanma ve yorumlama kapasitesidir. Matematiksel akıl yürütmeyi ve fenomeni açıklamak ve tahmin etmek için matematiksel kavramları, prosedürleri, gerçekleri ve araçları kullanmayı içerir. Bireylerin matematiğin dünyada oynadığı rolü fark etmelerine ve yapıcı, bağlı ve düşünceli vatandaşların ihtiyaç duyduğu sağlam temellere dayanan yargı ve kararları almalarına yardımcı olur ” (PISA, 2012).

Matematik okuryazarlığı, matematik bilgisinin günlük yaşamda uygulanması olarak kabul edilir ve bu nedenle birçok karşılaştırmalı uluslararası eğitim standardında bulunur (Holenstein ve ark., 2020).

Matematik okuryazarlığının gelişimi, öğrencilerin yaşadıkları dünyayı daha iyi anlayan yetenekli eleştirel düşünürler ve problem çözücüler olmalarını sağlar. Ancak, çoğu zaman öğrenciler matematiksel ilkeleri anlayamaz ve bunları gerçek hayattaki durumlara uygulayamaz. Birçok üniversite matematik sınıfında, dersler yalnızca soyut kavramlara ve rutin alıştırmalara odaklanır. Matematik diline erişmek için okuma şarttır, ancak birçok üniversite öğrencisi, matematiğin nasıl çalıştığına dair daha derin bir anlayış kazanmak için soyut kavramlarda gezinmek için okuryazarlık becerilerinden yoksundur. Matematikte okumak sadece basit ve doğrusal anlamayı içermez; süreç, çok çeşitli düşünme ve muhakeme becerileri gerektirir. Okuma sürecinin her aşamasında öğrencilerin kelimeleri, sembolleri ve kavramları anlamaya ihtiyacı vardır; sorunları analiz etmek, problemleri çözmek için içerik bilgisini ve matematiksel modelleri uygular (Rojas ve Benakli, 2020).

Matematik okuryazarı bir öğrenci, yapıcı, bağlı ve düşünceli vatandaşların ihtiyaç duyduğu sağlam temellere dayanan yargı ve kararları vermek için matematiğin dünyada oynadığı rolü kabul eder (PISA, 2021).

PISA, yaptığı sınav içeriğinde tüm dünya ülkelerin kullandığı ortak müfredatı uygulamaktadır. Yapılan her uygulamada matematik, fen ve okuma alanlarından yalnızca birine ağırlık verilmektedir. Matematik okuryazarlığına 2012 yılında ağırlık verilirken, 2015 yılında fen, 2018 yılında ise daha çok ağırlık verilen alan okuma becerileri olmuştur.

Çizelge 1.1. Yıllara Göre PISA Uygulamalarına İlişkin Özet Bilgiler

Yıllar	2000	2003	2006	2009	2012	2015	2018
Alanlar	Okuma	Matematik	Fen	Okuma	Matematik	Fen	Okuma
Katılan ülke sayısı	43	41	57	65	65	72	79
Uygulama Şekli	Kâğıt kalem Testi	Kâğıt kalem Testi	Kâğıt kalem Testi	Kâğıt kalem Testi	Kâğıt-kalem Testi/Bilgisayar Tabanlı Uygulama	Bilgisayar Tabanlı Uygulama	Bilgisayar Tabanlı Uygulama

Çizelge 1.2. PISA ve Türkiye'nin matematik okuryazarlığı ortalamaları

Yıllar	2003	2006	2009	2012	2015	2018
Türkiye Ortalaması	423	424	445	448	420	454
Türkiye'nin matematik okuryazarlığı sıralamaları	33	43	41	44	50	42
OECD'nin matematik okuryazarlığı Ortalamaları	500	498	496	494	590	489
Türkiye'den Katılan Öğrenci sayısı	4855	4942	4996	4848	5895	6890
Ülkelerin Ortalaması	488	484	465	470	461	459


PISA uygulamasına ilişkin puanlar, ağırlıklı alanlar, katılan ülke sayıları, Türkiye matematik okuryazarlığı ortalamaları, katılan öğrenci sayısı, OECD matematik okuryazarlığı ortalamaları, uygulama şekillerini sunmak için PISA 2000, 2003, 2006, 2009, 2012, 2015 ve 2018 raporları incelenerek Çizelge 1.1. ve Çizelge 1.2. oluşturulmuştur. Yukarıda verilen Çizelge 1.1.'de PISA uygulamasının yıllara göre özet bilgileri içermekte, yıllara göre PISA'ya katılan ülke sayısı, uygulama şekilleri ve ağırlık verilen alanlar gösterilmektedir. Çizelge 1.2.'de Türkiye'nin yıllara göre matematik okuryazarlığı ortalamaları, OECD'nin matematik okuryazarlığı ortalamaları, Türkiye'den katılan öğrenci sayısını göstermektedir.

1.1.3. PISA matematik okuryazarlığı Türkiye sonuçları

PISA, üç yılda bir 15 yaşındaki öğrencilerin matematik, fen ve okuma becerilerini değerlendirir. PISA 2018 uygulamasına Türkiye’de İstatistiki Bölge Birimleri Sınıflandırması Düzey 1’e göre 12 bölgeyi temsil eden 186 okul ve 6890 öğrenci katılmıştır. Katılan okullardaki 15 yaş grubu öğrencilerin %43.7’si Anadolu Lisesi, %31.1’i Mesleki ve Teknik Anadolu Lisesi ve %13.7’si Anadolu İmam Hatip Lisesinde eğitim almaktadır. Fen Liseleri, Sosyal Bilimler Liseleri, Çok Programlı Anadolu Liseleri ve Anadolu Güzel Sanatlar Liselerinde eğitim alan öğrenciler, PISA 2018 Türkiye örnekleminin %11.2’sini oluşturmaktadır.

2018’de PISA’ya katılan 79 ülkenin matematik okuryazarlığı alanında aldığı puanlar 325 ile 591 arasında değişti. Türkiye’nin matematik alanındaki ortalama puanı 454, OECD ülkeleri arasındaki matematik alanındaki ortalama puanı ise 489 olarak hesaplanmıştır. Türkiye PISA uygulamasına ilk 2003 yılında katılmıştır. Türkiye matematik alanında 79 katılımcı ülke arasında 42. sırada yer alırken, OECD’ye katılan 37 ülke arasından ise matematik alanında 33. sırada yer almaktadır. Ülkemiz matematik alanında 36 ülkeden daha yüksek performans göstermiştir, bunlardan dördü OECD ülkesidir. 2003 ve 2012 yılları arasında matematik okuryazarlığında ortalama puanda artış eğiliminde olan Türkiye 2015 yılında düşüş göstermiştir. Ülkemiz 2003’ten bu yana PISA 2018 uygulamasında matematik alanında ortalama puanda en yüksek düzeye ulaşmıştır. Türkiye, PISA 2018 uygulamasında matematik ortalama puanını PISA 2015 uygulamasına göre en çok artıran ülke olmuştur.

Aşağıdaki Şekil 1.1.’de PISA uygulamasının Türkiye matematik okuryazarlığının yıllara göre değişimi gösterilmektedir.



Şekil 1.1. Türkiye'nin 2003-2018 yılları matematik ortalama puanları.



2. KAYNAK BİLDİRİŞLERİ

Mirjalili tarafından 2014 yılında ortaya atılan Gri Kurt Optimizasyon Algoritması, doğadaki gri kurtların liderlik hiyerarşisi ve grup avı mekanizmasına dayandırılarak önerilen; doğadan ilham alan başarılı MS bir algoritmadır. Algoritma birçok optimizasyon problemlerinde kullanılmaktadır. Aynı zamanda öznitelik seçimi içinde gri kurt algoritmasının birçok geliştirilmiş versiyonu ile çalışmalar bulunmaktadır.

Emary ve ark. (2016) çalışmalarında, özellik seçme görevi için GWO'nun bir ikili versiyonu olan İkili Gri Kurt Optimizasyonu (BGWO) sınıflandırma amacıyla optimal öznitelik alt kümesini seçmek için önermişlerdir. Çalışmada, sınıflandırıcı olarak KNN sınıflandırıcısı kullanmışlardır (Emary ve ark. 2016).

Too ve ark. (2018) çalışmasında, EMG sinyalleri sınıflandırmasında öznitelik seçimi için yeni bir rekabetçi ikili gri kurt optimize edici (CBGWO) önermektedir. Önerilen yöntemin başarısını değerlendirmek için CBGWO ikili gri kurt optimizasyonu (BGWO1 ve BGWO2), genetik algoritma ve ikili parçacık sürü optimizasyonu ile karşılaştırılır. Sonuçlar algoritmanın sadece sınıflandırmada değil aynı zamanda özellik indirgemedede performansının üstünlüğünü göstermektedir (Too ve ark. (2018).

Zhao ve arkadaşları (2019) çalışmasında, yüksek boyutlu veriyi sınıflandırmak ve özellik seçimi için gri kurt optimize edici algoritmasına ilham vermek için kuantum hesaplamayı kullandı. Öznitelik seçimi için GWO 'nun diğer bir versiyonu olan kuantum hesaplama ve belirsiz simetri kaba kümesine (QCGWORS) dayalı bir gri kurt optimize edici önerdi. Sınıflandırma doğruluğu, QCGWORS'un performans oranını değerlendirmek için çapraz doğrulama yöntemi ölçülerek hesaplandı. QCGWORS'u 13 veri kümesi ve diğer öznitelik seçim algoritmaları üzerinde test edip karşılaştırarak, deneysel sonuçlar, QCGWORS'un veri kümelerinin sınıflandırma doğruluğunu alanında çok önemli bir rol oynadı (Zhao ve ark., 2019).

Tashi ve arkadaşları (2020) çalışmasında, hidrokarbon rezervuar verilerinin sınıflandırılmasında, öznitelik seçimi için İkili Gri Kurt Optimizasyonu (BGWO) önermektedir. ABD petrol ve gaz sahalarından elde edilen büyük rezervuarı geri kazanmak için ilk kez GWO algoritması uygulanmaktadır. Seçilen özellikleri değerlendirmek için KNN sınıflandırıcısı kullanılır. Ayrıca, önerilen yöntemin

performansını değerlendirmek deneysel sonuçlar Balina Optimizasyon algoritması (WAO) ve Dragonfly Algoritması adlı algoritma ile karşılaştırılır. Önerilen yöntem, gerçek petrol ve gaz problemlerini çözmek için büyük bir potansiyel göstermektedir (Tashi ve ark., 2020).

Al-Wajih ve ark. (2020) çalışmasında, yüksek boyuttaki veriyi sınıflandırmak için öznitelik seçimini kullandı. Öznitelik seçimi için GWO'nun ikili versiyonu olan BGWO'yu önerdi. Hata oranının değerini hesaplamak için, öklid mesafesi ile KNN algoritması kullanılmaktadır. Öznitelik seçim algoritmasının etkinliğini belirlemek için dört veri setini kıyaslamaktadır (Al-Wajih ve ark., 2020).

Momanyi ve Segera, (2021) tarafında Gri Kurt Optimize ediciye bir arama alanında keşfetme ve daha iyi çözümler bulma yeteneğini geliştirmek için yeni bir ana-bağımlı ikili gri kurt optimize edici (MSBGWO) tanıtıldı. Çalışmada, MSBGWO'nun özellik seçimin performansını test etmek için beş yüksek boyutlu biyomedikal veri seti kullanılır. Daha sonra elde edilen deneysel sonuçlar ikili gri kurt optimizasyonu (BGWO1 ve BGWO2), ikili sürü optimizasyonu algoritması, sinüs-kosinüs algoritması, diferansiyel evrim ve ikili genetik algoritma ile karşılaştırıldı (Momanyi ve Segera, 2021).

Eğitim bilimlerinde öğrencilerin başarılarını etkileyen değişkenleri belirlemek amacıyla farklı çalışmalara yer verilmiştir.

Chiu ve Xihua (2008) çalışmasında, 41 ülkede öğrenci matematik başarıları üzerindeki aile faktörünü ve motivasyon etkilerini incelemektedir. Analizler sonucunda öğrenci ailelerinin sosyoekonomik statüsü yüksek olanların daha yüksek puan aldıklarını tespit edilmiştir. Kardeş sayısının az olduğu, daha fazla kitap okuyan, kültürel iletişim içinde olanların, matematiğe daha fazla ilgi duyanların, daha fazla çaba sarf eden, yüksek öz yeterliliğe sahip olan öğrencilerin daha başarılı olduklarını belirlemişlerdir (Chiu ve Xihua,2008).

Breen ve ark. (2010)'da yaptıkları çalışmada, İrlanda'da üçüncü seviye birinci sınıf öğrencilerine PISA testi uygulanmıştır. Yapılan testte öğrencilerin matematik okuryazarlık alanına ilişkin öz-yeterlilikleri incelenmiştir. Matematikteki başarılarını ölçmek için öz yeterlilik ve amaç faktörlerini belirleyen anketler uygulandı. Yapılan testler sonucunda öğrencilerin altıncı seviye testlerinde zorlandıkları ve öz yeterlilik değişkeninde anlamlı bir ilişki olmadığı bulunmuştur (Breen ve ark., 2010).

Demir ve Kılıç (2010) yaptıkları çalışmada, PISA 2003 Türkiye verilerini kullanarak öğrencilerin matematik okuryazarlığı başarısını etkileyen değişkenleri incelemektedir. Çalışmada cinsiyet, matematik başarısı, zevk, okul yerleri, okul moralleri, öğrenme stratejiler ve ilgi gibi matematik okuryazarlığı başarısını etkileyen değişkenleri, çok değişkenli istatistiksel teknikleri kullanarak incelemektedir. Regresyon analizinde Bernoulli modeli kullanılarak katsayılar tahmin edilmektedir. Sonuçlar incelendiğinde cinsiyet, matematiğe ilgi ve lokasyon değişkenlerin matematik başarısında başarılı bir etkiye sahip olurken öğrenme stratejisinde başarısız bir etkiye sahip olduğu gösterilmektedir (Demir ve Kılıç, 2010).

Kitsantas ve ark. (2010) ‘da matematik öz-yeterliği ile matematik başarısı arasındaki ilişkinin matematik ödevine harcanan zamanla nasıl hafifletildiğini incelemek için ABD'nin 2003 PISA verileri kullanılmıştır. Elde ettikleri sonuçlar en küçük kareler yöntemi, çoklu regresyon ve çok değişkenli varyans analizine (MANOVA) dayanıyordu. Matematik ödevine harcanan zaman miktarının etkisinin küçük olmasına ve matematik öz-yeterliği ile harcanan zaman arasında etkileşim etkisi olmadığını gösterdi. Matematik ödevinde, matematik öz yeterliği, cinsiyet, ırk, matematik ödevine harcanan zaman ve matematikle ilgili eğitimin mevcudiyeti gibi bireysel öğrenci farklılıklarını kontrol ettikten sonra matematik başarısındaki toplam varyasyonun %20'sini açıklamayı başardı. Bulgular, analiz yöntemine bakılmaksızın, öğrencilerin ve okulların demografik özelliklerini kontrol ettikten sonra bile öz yeterliliğin matematik başarısının önemli bir yordayıcısı olduğunu göstermiştir. İkincil bir bulgu ise, açıkça iç içe geçmiş bir yapıya sahip veriler için çoklu regresyon modellerinin kullanılmasının, etki boyutu için yanlış tahminler üretmesidir. Bu bulguların eğitimsel etkileri tartışılmıştır (Kitsantas ve ark., 2010).

Ozgen ve Bindak (2011) yaptıkları çalışmada, matematik okuryazarlığına ilişkin öz-yeterlilik değişkenini incelemişler. Araştırma 712 lise öğrencisi üzerinden yürütülmüştür. Verilerin toplanmasında anket ve matematik okuryazarlığı öz-yeterlilik ölçeği kullanılmıştır. Verilerin analizinde çoklu regresyon yöntemi, t-testi ve varyans analizi kullanılmıştır. Yapılan araştırma ve bulgular sonucunda öz-yeterliliğin matematik okuryazarlığı üzerinde pozitif etki gösterdiği gözlemlenmiştir.

Liu ve Wilson (2009) çalışmalarında, 2003 PISA verilerini kullanarak Hong Kong ve Amerika Birleşik Devletleri'nin matematik başarısını cinsiyet değişkeni üzerinden

değerlendirmeye almışlardır. Yapılan karşılaştırmada her iki ülkede erkek öğrencilerin daha çok karmaşık çoktan seçmeli sorularda üstün performans sergiledikleri, kız öğrencileri ise cebir, olasılık ve yeniden üretim sorularında daha başarılı oldukları gözlemlenmiştir. Hong Kong öğrencileri, cinsiyet değişkeninde Amerika Birleşik Devletleri'nde akranları olan öğrencilere göre daha büyük fark göstermişler. Aynı zamanda karmaşık matematiksel akıl yürütmeyi ölçen sorularda Hong Kong'lu öğrencilerin daha başarılı oldukları görülmüştür (Lio ve Wilson, 2009).

Cheema ve Galluzzo (2013) 'te, PISA 2003 öğrenci anketinin 4.733 gözlemden oluşan ABD bölümü, matematik başarısını cinsiyet, ırk ve sosyoekonomik durum gibi demografik değişkenler ve matematik kaygısı ve matematik öz-yeterlik ölçülerini dikkate almıştır. Sonuçlar, matematik başarısında kalıcı ırksal ve sosyoekonomik boşlukların varlığını doğrulamış hem kaygının hem de öz yeterliğin matematik başarısındaki farklılığı açıklamaya önemli ölçüde katkıda bulunduğunu göstermiştir. Cinsiyet farkının matematik başarısının önemli yordayıcısı olmadığını göstermiştir. (Cheema ve Galluzzo, 2013).

Lakshmi ve ark. (2013) yaptıkları çalışmada, nicel verileri analiz etmek ve bireyin performansını verimli bir şekilde tahmin etmek için yaptıkları çalışmada sınav puanları, kabul yaşı, ebeveyn geçmişi ve cinsiyet gibi faktörlerin önemliolarak belirlediler. Genetik algoritma kullanılarak öğrencilerin performansını etkileyen en iyi parametreyi tahmin edilip, aynı zamanda nicel parametrelerin öğrencinin akademik performansı üzerindeki etkisini de analiz etmişlerdir (Lakshmi ve ark., 2013).

Taşkın ve Tuğrul (2013)'te yaptıkları çalışmada, okul öncesi öğretmen adaylarının matematik okuryazarlığını öz yeterlik inançlarını çeşitli değişkenlere göre incelemişler. Araştırmalarını Türkiye'de bir devlet üniversitesinde 202 öğretmen adayı üzerinden yürütmüşlerdir. Çalışmada "Kişisel Bilgi Formu" ve "Matematik Okuryazarlığı Öz Yeterlilik Ölçeği" kullanılmıştır. Çalışmanın istatistiksel analizinde Bağımsız Örneklem T-testi ve tek yönlü ANOVA ve tanımlayıcı istatistikler kullanılmıştır. Sonuç olarak üniversitede matematikle ilgili bir ders alan adayların matematik okuryazarlığında öz yeterlilik inançlarını olumlu yönde etkilediğini göstermektedir (Taşkın ve Tuğrul; 2013).

Thein (2016)'da yaptığı çalışmada, PISA 2009 ve 2012 yıllarına ait veriyi kullanarak Malezyalı öğrencilerin matematik okuryazarlıklarındaki performanslarını

cinsiyet ve sosyoekonomik açılardan araştırmaktadır. Sonuçlar incelendiğinde, PISA 2012'de matematik okuryazarlığında kızların erkeklerden yaklaşık sekiz puan daha yüksek puan aldıklarını ortaya koydu. Öğrenci ve okul düzeyinde sosyoekonomik durum kontrol edildikten sonra kız ve erkek öğrenciler eşit performans gösterdi. Yüksek sosyoekonomik statü ortalamasına sahip okullar, hem PISA 2009 hem de PISA 2012'de matematik okuryazarlığı açısından düşük sosyoekonomik statüye sahip okullardan daha iyi performans gösterdiğini belirlediler (Thein, 2016).

Aksu ve Güzeller (2016)'da yaptıkları çalışmada, başarılı ve başarısız öğrencilerin derse yönelik motivasyon, tutum, ilgi, kaygı, öz yeterlilik ve çalışma disiplini değişkenlerine göre matematik okuryazarlığını sınıflandırmak, ayrıca değişkenlerin sınıflandırma üzerindeki etkisini belirlemeyi amaçlamışlardır. Çalışmada Türkiye PISA verileri kullanılmış ve verilerin analizi için bir karar ağacı tekniği olan CHAID analizi ve veri madenciliği kullanılmıştır. Başarılı ve başarısız öğrencilerin sınıflandırılmasında en önemli duysal özellikler öz yeterlik algısı, derse yönelik tutum ve çalışma disiplini olarak belirlenmiştir. Karar ağacı ile elde edilen doğru sınıflandırma yüzdesinin, CHAID analiz yöntemi ile elde edilen değere çok yakın olduğu görülmüştür. Araştırmadan elde edilen bulgular, Türkiye örneğinde matematik okuryazarlığında öncelikle öz yeterlik, derse yönelik tutum, kaygı ve çalışma disiplini üzerinde yoğunlaşması gerektiğinin, bu alanlarda yapılacak düzenlemelerle öğrencilerin başarı durumlarının değiştirilebileceği ve PISA sınavlarında Türkiye'nin daha üst sıralarda yer alabileceği düşünülmektedir. Bu sonuçlar, CHAID analizinin veri madenciliğinde kullanılan karar ağacı yöntemlerine alternatif bir yöntem olarak düşünülebileceğini ifade edilmiştir (Aksu ve Güzeller, 2016).

Mutluer ve Büyükkıdık (2017) çalışmalarında, PISA'nın 2012 Türkiye verileri kullanılarak matematik okuryazarlığının, matematikten zevk alma, matematik ile ilgili okuma yapma, anne baba eğitim durumu, matematik dersini dört gözle bekleme, matematik ilgisi, öz öğrenme/ hızlı öğrenme, pes etme, matematiğe ilgi gibi değişkenler ile lojistik regresyon modeli kullanılarak hangi doğruluk düzeyinde sınıflandığı belirlenmiştir. Matematik okuryazarlığının sınıflandırmasında, verilerin analizi sonucunda kullanılan değişkenlerin anlamlı etkisi olduğu görülmüştür. Yapılan lojistik regresyon analizi sonucunda %85,2 oranında doğruluk gözlemlenmiştir. (Mutluer ve Büyükkıdık, 2017).

Cheema (2018)'de yaptığı çalışmada, Yunanistan'dan geniş çaplı bir anket kullanarak matematik öz yeterliği ile matematik okuryazarlığı arasındaki ilişkiyi incelemiştir. Yunan lise öğrencileri arasında matematik öz yeterliği ile matematik okuryazarlığı arasında güçlü bir ilişki olduğunu ayrıca bu ilişkinin cinsiyet, ailenin eğitimi, ailenin mesleği sınıf, yaş, gibi öğrenci düzeyindeki farklılıklar kontrol edildikten sonra bile devam ettiğini göstermektedir. Ailenin sosyoekonomik durumu, kültürel varlıklar ve evdeki eğitim imkanları ve okul türü, okul büyüklüğü, öğrenci-öğretmen oranı ve okul düzeyindeki sosyoekonomik durum gibi okul düzeyindeki farklılıklara değinmiştir (Cheema, 2018).

Bezek Güre ve ark. (2020) yaptıkları çalışmada, Rastgele Orman ve Çok Katmanlı Algılayıcı Yapay Sinir Ağları gibi veri madenciliği yöntemlerini ele alarak kullanarak PISA 2015 Matematik okuryazarlığına etki eden faktörleri belirlemişlerdir. Araştırma kapsamında neden sonuç ilişkisi derin öğrenme düzeyinde veri madenciliği yöntemleri kullanılarak araştırılmıştır. PISA 2015 testine giren öğrencilerin matematik testinden aldıkları puanlar ve kurumsal olarak bağımlı değişkenlerle bağlantılı olduğu düşünülen bağımlı değişkenler ve 25 değişken yordayıcı olarak analize dahil edilmiştir. Analiz sonucunda, Random Forest yönteminin bir takım performans göstergeleri açısından daha küçük hatalarla öngöründe bulunduğu belirtilmiştir. Rastgele orman yönteminin önemli bulduğu değişkenler sırasıyla öğrencilerin Türkçe başarı düzeyi, anne eğitim düzeyi, motivasyon düzeyi, epistemolojiye olan inanç, öğretmenlerin ilgi düzeyi ve sınıf disiplin ortamı ve kaygı değişkenleridir (Bezek Güre ve ark., 2020).

Sağlam ve ark. (2020) yaptıkları çalışmada, PISA 2018 uygulamasına katılan öğrencilerin matematik okuryazarlığı, fen ve okuma puanlarına etkisi olan duygusal faktörlerin veri madenciliği yöntemleri ile incelemiştir. Puanların öğrencilerin hayatında bir anlam bulma, hayatından memnun olup olmama, mutlu ve üzgün olma gibi değişkenlerle olan ilişkilerini incelemiştir. Korelasyon analizi, karar ağaçları kullanılarak ilişkiler ortaya çıkarılmıştır. Yapılan araştırma sonucunda öğrencilerin mutluluk oranı artıkça ülkedeki matematik okuryazarlığı, okuma ve fen puanlarında artış gözlemlendiği, üzgün olan öğrencilerin puanlarında ise düşüş gözlemlenmiştir. (Sağlam, 2020).

3. MATERYAL VE YÖNTEM

3.1. Materyal

Bu çalışmada, PISA 2018 Türkiye örnekleme ait matematik okuryazarlığı verileri kullanılmıştır. Veriler, PISA'nın resmî sitesindeki paylaşıma açık veri dosyalarından internet aracılığı ile elde edilmiştir. Eksik ve hatalı veriler çalışmadan çıkarıldıktan sonra toplamda 15 yaşındaki 6 bin 859 öğrenciden elde edilen puanlar kullanılmıştır.

PISA verilerin sınıflandırmasında, öznitelik seçiminde GWO algoritmasının ikili versiyonu olan BGWO kullanılmaktadır. Algoritmaların her birinde popülasyon boyutu 10 ve yineleme sayısı 100 olarak ayarlanmıştır. Hızlı ve basit olması nedeniyle uygunluk değerlendirmesinde öklid mesafesine sahip bir KNN sınıflandırıcısı kullanılmakta olup k sırasıyla 3,5 ve 11 alınmıştır.

Araştırmada belirlenen bağımlı değişken matematik okuryazarlığıdır. Matematik okuryazarlığı değişkeni, PISA 2018 Türkiye örnekleme ait öğrenci anketi, öğrenci verilerinden elde edilen indeksler ve matematik testinden elde edilen puanlardan (PV1MATH, PV2MATH, PV3MATH, PV4MATH, PV5MATH, PV6MATH, PV7MATH, PV8MATH, PV9MATH, PV10MATH) yararlanmıştır. Her bir öğrenci için tek tek matematik puan ortalamaları (PVMATH) belirlenmiştir. Daha sonra tüm öğrencilerin matematik puan ortalamaları dikkate alınarak Türkiye örnekleme ait medyan değeri (MED=447.96) hesaplanmıştır. Matematik puan ortalamaları medyan değerine eşit ve üzerinde olanlar öğrenciler 1(Başarılı), medyan değerinin altında olanlar öğrenciler ise 0 (yani Başarısız) olarak MEDMATH ismiyle yeni bir değişken olarak tekrardan kodlanmıştır. İndeksler öğrencilere sorulan birkaç sorunun birleşiminden elde edilen değişkenlerdir. Veri setindeki eksik indisler temizlendikten sonra verinin %20 si test %80'i eğitim verisi olarak ayrılmıştır. Bu çalışmada 66 tane indeks, 3 değişken (ST001D01T, ST003D02T, ST004D01T) olmak üzere 69 tane bağımsız değişken kullanılmıştır. Bu analiz değerlendirilmesinde kullanılan değişkenlerin alfabetik olarak isimleri şunlardır; ADAPTIVITY, ATTIMM, ATTLNACT, AUTICT, AWACOM, BEINGBULLIED, BELONG, BSMJ, COGFLEX, COMPETE, COMPICT,

CULTPOSS, DIRINS, DISCLIMA, DISCRIM, DURECEC, EMOSUPS, ENTUSE, ESCS, EUDMO, FISCED, GCAWARE, GCSELFEEFF, GFOFAIL, GLOBMIND, HEDRES, HISCED, HISEI, HOMEPOS, HOMESCH, ICTCLASS, ICTHOME, ICTOUTSIDE, ICTRES, ICTSCH, INTCULT, INTICT, JOYREAD, LMINS, MASTGOAL, METASPAM, METASUM, MISCED, MMINs, PARED, PERCOMP, PERCOOP, PERFEED, PERSPECT, PISADIFF, REPEAT, RESILIENCE, RESPECT, SCREADCOMP, SCREADDIFF, SMINS, SOIAICT, ST001D01T, ST003D02T, ST004D01T, STIMREAD, SWBP, TEACHINT, TEACHSUP, TMINs, UNDREM, USESCH, WEALTH ve WORKMAST.

GWO uygulamaları sonucunda bu 69 değişkenler içinden 21 tane değişken ön plana çıkmıştır. Ön plana çıkan bu değişken lojistik regresyon analizine tabi tutularak, bu değişkenlerin anlamlı olup olmadıkları sınanmıştır. Uygulamada değerlendirme için MATLAB yazılım ve programlama dili kullanılarak lojistik regresyon ile karşılaştırılmıştır.

3.2 Yöntem

3.2.1. Meta-sezgisel Algoritmalar


İlk defa Fred W. Glover tarafından 1986 senesinde ortaya atılan meta sezgisel terimi, “meta” sözcüğü ile “heuristic” sözcüğünün bir araya getirilmesi ile meydana gelmektedir. Yunancada ön ek olan meta kelimesi ‘üst’ manasına gelirken, ‘heuristic’ kelimesi ise türkçemize ‘sezgisel’ olarak geçmektedir. “Heuristic” sözcüğünün gerçek kökeni ise “heuriskein” sözcüğünden gelmektedir. “Heuriskein” bulmak ve keşfetmek manasına gelir (Blum ve Roli, 2003: 271).

Son yıllarda, gerçek dünya sorunlarının giderek artan karmaşıklığı ve zorluğu, daha güvenilir optimizasyon tekniklerine, özellikle de Meta-Sezgisel optimizasyon algoritmalarına ihtiyaç duyulmasına neden oldu. MS algoritmalar, kesin metotlar ile çözülemeyen ya da çok zaman alan zor problemlere yakın bir çözüm elde eden algoritmalarlardır. Genel olarak rastgele oluşturulan birey kümesi çözüm kümesini aramaya başlar. Amaç, daha iyi çözümler bulmak için olası çözümleri değerlendirir ve bunlar üzerinde bir dizi işlem gerçekleştirirler (Reeves, 1995).

Her MS algoritmanın iyi sonuçlar üretebilmesi için esinlendiği yapıya uygun geliştirilen parametreleri bulunmaktadır. MS algoritmalarından optimal sonuçların elde edilebilmesi, parametrelerin probleme uygun şekilde uyarlanması ile gerçekleşmektedir (Hertz ve Widmer, 2003). Arama uzayında en iyi sonucu bulmaktan ziyade en hızlı ve en kolay şekilde çözüme ulaşılmaya çalışılır. Arama uzayı üst seviyede arama yapan, yerel arama tekniklerinden, karmaşık öğrenme tekniklerine kadar yayılım göstermektedir (Yang, 2011; Talbi, 2009).

MS teknikler belirli bir probleme özgü olmayıp, zor ve karmaşık olan birçok problemin çözümünde kullanılmaktadır. MS algoritmalar, adından da anlaşılacağı gibi, doğası gereği her zaman sezgiseldir. Bu gerçek onları kesin yöntemlerden ayırır (Sörensen ve Glover, 2013). MS bir yöntemle kesin bir yöntemi birleştirmenin sonucunun mutlaka sezgisel bir yöntem olması gerekmez. MS yöntemler, kesin yöntemlerin performansını iyileştirmek için kesin yöntemlerle entegre edilebilir (Friden ve ark., 1990; Glover, 1990; Puchinger ve ark., 2009).

Değişken bileşenlere sahip algoritmalar, geçmişte daha çok sezgisel olarak adlandırılırken, son zamanlarda literatürde MS olarak anılmaktadır. Aslında MS algoritmalar, doğadan esinlenen klasik sezgisel algoritmaların geliştirilmiş hali olarak görülebilir (Glover, 1986; Glover ve Kochenberger, 2003; Laporte ve ark., 2000). Genel olarak MS yöntemler Evrime Dayalı Algoritmalar, Fizik Tabanlı Algoritmalar, İnsan Davranışı ile İlgili Algoritmalar, Sürü Tabanlı Algoritmalar olmak üzere Şekil 3.1'deki gibi dört farklı kategoride değerlendirilmektedir (Agrawal ve ark, 2021).



Şekil 3.1. Meta-sezgisel algoritmaların sınıflandırması.

3.2.1.1. Evrime dayalı algoritmalar

Doğadaki canlıların davranışlarından esinlenerek ortaya çıkan algoritmalar. Doğal evrimin ilkelerini taklit ettikleri için evrimsel algoritmalar (Glover ve Sörensen, 2015). Literatürde en çok kullanılan ve bilinen algoritmalarından bazıları; Genetik Algoritmalar (Goldberg, 1989), Diferansiyel Gelişim Algoritması (Storn ve Price, 1997), Corona Virüsü Optimizasyonu (Salehan ve Deldari, 2021), Remora Optimization Algoritması (Jia ve ark.,2021), Evrimsel Stratejiler (Rechenberg ve Schwefel, 1970), Geri İzleme Arama Optimizasyon Algoritması (Civicioglu, 2013), Sinerjistik Fibroblast Optimizasyonu (Subashini ve ark. 2017), Stokastik Fraktal Arama Algoritması (Salimi, 2015), Remora Optimizasyon Algoritması (Jia, 2021) vb. algoritmalar. Evrime dayalı algoritma isimleri, kısaltması ve yılı Çizelge 3.1.'de gösterilmektedir.

Çizelge 3.1. Evrime dayalı algoritmalar ve yılı

Algoritma	Kısaltması	Yıl
Korona Virüsü Optimizasyonu	CVO	2021
Remora Optimizasyon Algoritması	ROA	2021
Sinerjistik Fibroblast Optimizasyonu	SFO	2017
Stokastik Fraktal Arama Algoritması	SFSA	2015
Geri İzleme Arama Optimizasyon Algoritması	BSA	2013
Diferansiyel Gelişim Algoritması	DDA	1995
Genetik Algoritmalar	GA	1975

Genetik Algotimalar (Genetic Algorithm-GA), 1975 yılında Holland tarafından geliştirilen biyolojik tabanlı bir algoritmadır. GA muhtemelen en çok bilinen evrimsel algoritmadır. Literatürde en çok bu algoritma baz alınıp, diğer birçok algoritmanın temelinde de kullanılmaktadır. GA'lar, problemin sonucuna ulaşabilmek için geniş bir çözüm kümesi içindeki çözüm olabilecek adayları seçmeye çalışan arama algoritmalarıdır. GA'ların arama stratejileri doğal evrime dayanır. GA'lar optimum sonuca ulaşmak için çözüm adaylarının bulunduğu bir nüfusu sürekli geliştirerek doğal seçilimi taklit ederler. Canlıların çevrelerine uyum sağlamaları genetik yapılarının değişmesiyle olur. GA'larda, bir birey popülasyonu, uygun mutasyon, çapraz geçiş ve seçim operatörleri kullanılarak geliştirilir. Darwin'in doğal seleksiyon ve en uygun olanın

hayatta kalması ilkelerine dayanarak, gelecek nesillere umut vaat eden genetik bilgiler yayılır ve optimizasyon sorununa çözümler sunulur (Holland,1975).

Diferansiyel Gelişim Algoritması (Differential Development Algorithm-DDA): 1995 yılında Price ve Storn tarafından DDA tanıtıldı. Evrimsel algoritmanın kavramlarını takip eden mekanizma ve operatörleri bakımından GA' ya uzanan popülasyon tabanlı sezgisel bir optimizasyon yöntemidir (Mayer ve ark., 2005). GA'da olduğu gibi mutasyon, çaprazlama ve seçim operatörleri DDA' da kullanılmaktadır (Shiakolas ve ark., 2005). DDA'nın GA' dan farkı değişkenlerin gerçek değerleri ile kullanılmasıdır. GA'da ise kodlamada gerçek değerler kullanılmaktadır. DDA'da kromozomlar tek tek operatörlere tabi tutularak, içinden gelişigüzel seçim yapılan üç kromozomdan yeni bir birey oluşturulmaktadır. Mevcut bireyle yeni oluşturulan bireyin uyum gösterme seviyeleri kıyaslanarak uygunluk oranı yüksek olan, yeni oluşturulan birey daha sonraki popülasyona aktarmaktadır (Hrstka ve Kucerova, 2004).

Korona Virüsü Optimizasyon Algoritması (Corona Virus Optimization-CVO): CVO algoritması 2019 'un sonlarında ortaya çıkan korona virüsü pandemisinden esinlenerek önerilen yeni bir optimizasyon algoritmasıdır. 2019'un sonlarından bu yana hızla yayılan, COVID-19 olarak adlandırılan enfeksiyondan/virüsten adını almıştır. Virüs bir kişiden birkaç kişiye kolayca bulaşarak bir salgına neden olabilir. Yeniden bulaşma olasılığı, süper yayılma hızı, sosyal mesafe önlemleri veya seyahat hızı gibi ilgili terimler, korona virüs aktivitesini mümkün olduğunca doğru bir şekilde simüle etmek için modele dahil edilmiştir. CVO algoritması, virüsün belli başlı davranışları ve özellikleri dikkate alınarak, birkaç sürekli matematiksel fonksiyon kullanılarak optimizasyon problemlerine uygulanmaktadır. CVO algoritması bazı diğer optimizasyon algoritmaları ile

karşılaştırıldığında iki önemli avantajı bulunmaktadır. İlk avantajı, giriş parametreleri hastalık istatistiklerine göre ayarlanmıştır. Bu avantaj sayesinde rastgele değerler ile başlanmamış olur. İkinci bir avantajı ise değerler ayarlanmadan birkaç güncellemeden sonra işlem sonlanır. Elde edilen deneysel sonuçlar CVO algoritmasının güvenilir, makul ve kabul edilebilir bir performansa sahip olduğunu göstermektedir (Salehan ve Deldari, 2021).

Evrimsel Stratejiler (Evolutionary Strategies -ES): Rechenberg ve Schwefel'in tarafından 1970 yılında Berlin Teknik üniversitesi'nde geliştirildi ve Avrupa'da kapsamlı bir şekilde incelendi. Sürekli, ayrık, kombinatoryal arama uzayları kısıtlamasız,

kısıtlamalı ve karışık arama uzayları dahil olmak üzere tüm optimizasyon alanlarında uygulanabilir. ES'ler davranışsal ya da fenotip seviyede çalışırken evrimsel algoritmalar ise genotip seviyesinde çalışır. Kodlamadaki küçük bir değişiklik, bireyde küçük bir değişikliğe yol açar. Aynı şekilde, kodlamada daha büyük bir değişiklik yapılırsa bireyde daha büyük bir değişikliğe sebep olur. Fenotip üzerindeki yoğunlaşma nedeniyle, bireyler genellikle evrimleşmekte olan her şeyi doğrudan kodlar, örneğin, bir bireyin gerçek bir sayı veya aslında bir dizi gerçek sayı olması olağandışı değildir. Evrimsel algoritmalarda olduğu gibi, operatörler bir döngü içinde uygulanır. Döngünün yinelenmesine nesil denir. Bir sonlandırma kriteri karşılanana kadar nesiller dizisine devam edilir (Rechenberg ve Schwefel, 1970).

Geri İzleme Arama Optimizasyon Algoritması (Backtracking Search Algorithm-BSA): 2013 yılında Civcivoğlu tarafından önerilen evrimsel bir algoritmadır. BSA'da birey popülasyonu, başlatma, seçim, mutasyon, çaprazlama ve seçim operatörlerinden oluşur. BSA da potansiyel çözümleri temsil eden başlangıç popülasyonuna dayanır. Buradaki hedef yineleme sürecinde fonksiyonu minimuma indirmeye çalışmaktır. BSA, arama yönü matrisinin oluşturulmasında kullanılmak üzere rastgele seçilmiş bir önceki nesilden bir popülasyonu depoladığı bir belleğe sahiptir. Bunun sayesinde BSA'nın hafızası geriye dönerek daha önceki nesillerden aldığı tecrübelerden yararlanmasını sağlar (Civcivoğlu, 2013).

Sinerjistik Fibroblast Optimizasyonu (Synergistic Fibroblast Optimization-SFO): 2017 yılında Subashini ve arkadaşları tarafından, dermal yara iyileşme sürecinde fibroblast hücresel organizmasının entelektüel davranışından ilham alarak geliştirilen evrimsel bir hesaplama algoritmasıdır. SFO, hücre dışı matristen oluşur, sürekli kolajen biriktirme birimine sahiptir. Kollajen tarafından salgılanan normal doku yaralı bölgeye uygulanır. Farklılaşma, çoğalma, iltihaplanma, göç, yeniden yönlendirme, hizalama, işbirlikçi, hedef odaklı, etkileşim, yenilenme, kendi kendine adaptasyon ve evrim gibi fibroblast hücresel organizmanın çeşitli özellikleri, bir buluşsal optimizasyon algoritması olan SFO'nun tasarımı ve geliştirilmesi için motive edilmiştir. SFO Optimal çözüm için n boyutlu arama uzayı kullanılır (Subashini ve ark., 2017).

3.2.1.2. Fizik tabanlı algoritmalar

Doğadaki fiziki olaylardan esinlenerek geliştirilmişlerdir. Bu algoritmalar, bireylerin arama uzayı çevresinde eylemsizlik kuvveti, ışık kırılma kanunu, moleküler dinamik ve yerçekimi kuvveti gibi fizik yasalarını ve kavramlarını kullanarak aralarında bağlantı kurduğu doğadaki fiziksel olayları taklit eder. Fizik Tabanlı Algoritmalarından literatürde en çok kullanılanlardan bazıları; Tanjant Arama Algoritması (Layeb,2022), Aritmetik Optimizasyon Algoritması (Abualigah ve ark., 2021), Arşimet Optimizasyon Algoritması (Hashim ve ark. 2020), Diz noktası odaklı çok amaçlı yapay flora Optimizasyon Algoritması (2020), Yıldırım Eklenti Prosedürü Optimizasyonu Algoritması (Foroughi ve ark., 2017), Bul-Düzelt-Bitir-İstismar-Analiz Algoritması (Kashan ve ark., 2019), Elektro-Arama Algoritması (Tabari, ve Ahmad, 2017), Termal Değişim Optimizasyonu (Kaveh ve Dadras, 2017), Sinüs-Kosinüs algoritması (Mirjalili, 2016), Su Buharlaştırma Optimizasyonu (Kaveh ve Bakhshpoori, 2016), Multi-Verse Optimizer (Mirjalili ve ark., 2016), Kinetik Gaz Molekül Optimizasyonu (2012), Su Döngüsü Algoritması (Eskandar ve ark. 2012), Yapay Fizik Optimizasyon Algoritması (Xie ve ark., 2009) vb. algoritmalar. Fizik tabanlı algoritma isimleri, kısaltması ve yılı Çizelge 3.2.'de gösterilmektedir.

Çizelge 3.2. Fizik Tabanlı algoritmalar

Algoritma isimleri	Kısaltması	Yıl
Tanjant Arama Algoritması	TSA	2021
Aritmetik Optimizasyon Algoritması	AOA	2021
Arşimet Optimizasyon Algoritması	AOA	2020
Diz Noktası Odaklı Çok Amaçlı Yapay Flora Optimizasyon Algoritması	MOAF	2020
Bul-Düzeltil-Bitir-İstismar-Analiz Algoritması	ESA	2019
Termal Değişim Optimizasyonu	TEO	2017
Elektro-Arama Algoritması	ESA	2017
Yıldırım Eklenti Prosedürü Optimizasyonu Algoritması	LAPÖ	2017
Multi-Verse Optimizer	MVO	2016
Su Buharlaştırma Optimizasyonu	WEO	2016
Sinüs-Kosinüs Algoritması	SCA	2016
Kinetik Gaz Molekül Optimizasyonu	KGMO	2014
Su Döngüsü Algoritması	SCA	2012
Yapay Fizik Optimizasyon Algoritması	APO	2009

Tanjant Arama Algoritması (Tangent Search Algorithm-TSA): TSA Algoritması 2021 yılında Layep tarafından önerilen Fizik Tabanlı yeni bir optimizasyon algoritmasıdır. Algoritma daha iyi çözümler elde etmek için matematiksel model kullanır. TSA algoritmasının en iyi çözümü bulmak ve yerel minimumlardan kaçınmak için keşif ve kullanım arasında iyi bir dengeyi koruma avantajına sahiptir. Ayrıca, yerel minimumlarda takılı kalmamak için yeni bir kaçış uygulayarak üstün bir başarı göstermektedir. Yakınsama kapasitesini artırmak için bu algoritmaya uyarlanabilir bir değişken adım boyutu da entegre edilmiştir. TSA'nın performansı üç test sınıfı ile değerlendirilir (Layeb, 2022).

Aritmetik Optimizasyon Algoritması (Arithmetic Optimization Algorithm-AOA): Abualigah ve ark. tarafından 2021 yılında önerilen MS bir algoritmadır. Algoritma temel matematik operatörlerinden (toplama çıkarma, çarpma, bölme) ilham alarak aritmetik problemlerin çözümünde kullanılmaktadır. Aritmetik, sayılar teorisinin temel bir bileşenidir. Cebir, analiz, geometri ile modern matematiğin önemli

bölümlerinden biridir. Aritmetik operatörler arama uzayında belirli kriterlere tabi olan en iyi elemanı seçmek için matematiksel olarak modellenir ve uygulanır (Abualigah ve ark., 2021).

Arşimet Optimizasyon Algoritması (Archimedes Optimization Algorithm-AOA): AOA fizik kanunu Arşimet Prensibi'nden ilham alınarak tasarlanmıştır. Kısmen veya tamamen sıvıya batırılmış bir nesneye yukarı doğru uygulanan kaldırma kuvveti ilkesini taklit eder, yer değiştiren sıvının ağırlığı ile orantılıdır. Performansı değerlendirmek için önerilen AOA algoritması, CEC'17 test paketi ve dört mühendislik tasarım problemi üzerinde test edilmiştir (Hashim ve ark., 2020).

Bul-Düzeltil-Bitir-İstismar-Analiz Algoritması (Find-Fix-Finish-Exploit-Analyze -F3EA): F3EA, 2019 yılında Kashan ve arkadaşları tarafından önerilen fizik tabanlı MS bir algoritmadır. Önerilen algoritma, savaşta yok edilecek nesnelerin veya tesislerin seçilmesine yönelik hedefleme sürecini taklit eder. F3EAD döngüsü (Bul, Düzeltil, Bitir, Sömür ve Analiz Et), drone saldırıları ve özel kuvvet operasyonları gibi tipik olarak ölümcül eylemlerle sonuçlanan operasyonlar bağlamında batılı ordularda yaygın olarak kullanılan alternatif bir istihbarat döngüsüdür. Döngünün aşamalarının temel bir özeti aşağıdaki gibidir:

Bul: Kişi ya da konumu belirler.

Düzeltil: Bu aşamada, savaş alanında hedefin kesin konumu belirlenir ve iz altında tutulur.

Bitir: Hedefleri yok etmek için harekete geçme sürecini tanımlar.

İstismar: Bu aşama, hedef alandan bilgi toplama, hassas hedef site kullanımı, savaş hasarı değerlendirmesi vb. içerir.

Analiz: Hedeflere yönelik saldırıların sonuçlarının değerlendirilmesi ile ilgili bir değerlendirme adımını belirtir. Analiz adımı popülasyonu günceller (Kashan ve ark., 2019).

Yıldırım Eklenti Prosedürü Optimizasyonu Algoritması (Lightning Attachment Procedure Optimization-LAPO): 2017 yılında Nematollahi tarafından önerilen LAPO Algoritması, yıldırım tutturma işleminden esinlenerek optimizasyon problemlerine uygulanmaktadır. Önerilen yaklaşım, aşağı lider hareketi, yukarı doğru lider yayılımı, yıldırım aşağı liderinin öngörülemez yörüngesi ve yıldırımın dal sönme özelliği dahil olmak üzere yıldırım tutturma prosedürünü taklit eder (Nematollahi, 2017).

Termal Değişim Optimizasyonu (Thermal Exchange Optimization-TEO):

TEO Algoritması 2017 yılında Kaveh ve Dadras tarafından fizik ilkelerine dayanarak oluşturulan bir optimizasyon algoritmasıdır. Algoritma, Newtonun soğuma yasasına göre çalışır. Newton'un Soğuma Yasası, nesnenin sıcaklığının zamana bağlı değişim hızının, bir orantı sabitiyle beraber ortam ve cisim sıcaklıkları arasındaki farkla da doğru orantılı olduğu biliniyor. Her cismin sıcaklığı kendi konumudur, yeni sıcaklıklar ise yeni pozisyon olarak belirlenir. Algoritmada her ajan bir soğutucu nesne olarak belirlenir ve başka bir ajanı çevre olarak ilişkilendirerek aralarında bir ısı transferi ve ısı alışverişi sağlanır. Nesnenin yeni sıcaklığı, yeni konum olarak kabul edilir (Kaveh ve Dadras, 2017).

Su Döngüsü Algoritması (Water Cycle Algorithm-SCA): 2012 Eskandar ve arkadaşları tarafından ortaya atılan algoritma doğadan ilham alır ve su döngüsü sürecine dayanır. Kısıtlı problemleri çözmek amacıyla önerilen optimizasyon ve mühendislik algoritmasıdır. Bu algoritma yeryüzündeki akarsu ve ırmakların denizlere akışının nasıl olduğunu ve su döngüsü sürecinin gözlemlenmesini temel alır (Eskandar ve ark. 2012).

Sinüs-Kosinüs Algoritması (Sine-Cosine Algorithm-SCA): 2016 yılında Mirjalili tarafından önerilen Sinüs-Kosinüs algoritması popülasyon bazlı bir MS bir algoritmadır (Mirjalili, 2016). Başlangıçta algoritma rastgele bir dizi çözüm ile optimizasyon sürecini başlatır, sonra uygunluk fonksiyonu ile en iyi bireysel çözümü seçer. Daha sonra ilk popülasyondaki her birey için pozisyon güncelleme yaparak en iyi çözüme ilişkin olarak konumunu günceller (Mirjalili, 2016).

Yapay Fizik Optimizasyon Algoritması (Artificial Physics Optimization - APO): Yerçekimsel arama algoritması ile benzer bir işleyiş izlemektedir. Xie ve arkadaşları tarafından yerçekimi kanunu örnek alınarak tavsiye edilmiş bir algoritmadır. APO'daki her parçacık, kütlesi, konumu ve hızı olan fiziksel bir birey olarak ele alınır. Algoritmada parçacıklar kütle olarak kendinden büyük olanları iterken, daha küçük olanları da kendine doğru çekmektedir (Xie ve ark., 2009).

3.2.1.3. İnsan davranışı ile ilgili algoritmalar

İnsan davranışı ile ilgili algoritmalar, sosyal tabanlı algoritmalar olarak da bilinmektedir. Sosyal hayattaki hadiselerden esinlenerek, insanların sosyal yaşamdaki

davranışlarını ilham alınarak geliştirilmiş algoritmalarıdır. Bu algoritmalarından bazıları; Afrika Akbabaları Optimizasyon Algoritması (Abdullahzade, 2021), Bilgi Paylaşımına Dayalı Algoritma (Mohamed ve ark., 2020), Voleybol Premier Lig Algoritması (Moghdani ve Salimifard, 2018), Jaya Algoritması (Rao, 2016), Döviz Piyasası Algoritması (Ghorbani ve Babaei, 2014), Grup Danışmanlık Optimizasyonu (Eita ve Fahmy, 2014), Lig Şampiyonası Algoritması (Kashan, 2014), Beyin Fırtınası Optimizasyon Algoritması (Zhan ve ark., 2012) vb. algoritmalarıdır. İnsan davranışı ile ilgili algoritma isimleri, kısaltması ve yılı Çizelge 3.3.'de gösterilmektedir.

Çizelge 3.3. İnsan davranışı ile ilgili algoritmalar ve yılı

Algoritma isimleri	Kısaltması	Yıl
Afrika Akbabaları Optimizasyon Algoritması	AVOA	2021
Bilgi Paylaşımına Dayalı Algoritma	GSK	2020
Voleybol Premier Lig Algoritması	VPL	2018
Jaya Algoritması	JA	2016
Döviz Piyasası Algoritması	EMA	2014
Grup Danışmanlığı Optimizasyonu	GCO	2014
Lig Şampiyonası Algoritması	LCA	2014
Beyin Fırtınası Optimizasyon Algoritması	BSO	2012

Afrika Akbabaları Optimizasyon Algoritması (African Vultures Optimization Algorithm-AVOA): 2021 yılında Abdullahzade tarafından önerilen yeni bir MS algoritmadır. Algoritma, Afrika akbabalarının yaşam tarzlarından esinlenip, Afrika akbabalarının yiyecek arama ve gezinme davranışlarını taklit ederek optimizasyon problemlerine uygulanmaktadır. AVOA'nın uygulanabilirliğini ve kara kutu yapısını sergilemek için, on bir mühendislik tasarım problemi için en uygun çözümleri bulmak için kullanılmıştır. Çeşitli deneyler yapılarak, birçok mühendislik uygulamalarında kullanılan algoritma, optimizasyon problemlerinin çoğundan daha iyi performans göstermektedir (Abdullahzade, 2021).

Kazanma-Paylaşma Bilgi Tabanlı Algoritma (Gaining-Sharing Knowledge Based Algorithm-GSK): GSK Algoritması Mohamed ve arkadaşları tarafından yakın zamanda önerilen, bilgi paylaşımına dayalı bir MS algoritmadır. GSK algoritması, iki ana

aşama aracılığıyla insanda bilgi edinme ve bilgiyi paylaşma sürecinden esinlenmektedir. Genç aşama ve kıdemli aşama. Arama sürecini başlatmak için bu iki aşama matematiksel olarak modellenir. Yapılan analizler ve deneysel sonuçlar algoritmanın üstünlüğünü ve etkinliğini kanıtlamaktadır (Mohamed ve ark., 2020).

Lig Şampiyonası Algoritması (League Championship Algorithm-LCA): LCA gerçek hayattaki zor optimizasyon problemlerini çözmek için sanal ligdeki birkaç haftalık takımların oynadıkları maçların taklitlerini yapan bir MS algoritmadır. Başta oluşturulan lig takımları kendi aralarında rastgele seçilmektedir. Takımlar ilerleyen haftaki maçları kazanmak için önceki haftaların maçlarını izler. Ayrıca güçlerini artırmak için oyuncu transferi yaparlar. Haftalık maç sonuçları kaybeden veya kazanana göre belirlenir. Sezon sonunda en iyi takım global çözüm olarak belirlenir. (Kashan, 2014).

Voleybol Premier Lig Algoritması (Volleyball Premier League Algorithm-VPL): VPL Algoritması bir voleybol ligindeki takımlar arasındaki etkileşimli davranışı taklit eder. Algoritması global optimizasyon problemlerini çözmek için voleybol metaforunu kullanır, ayrıca maçtaki koçluk sürecini de taklit eder. Önerilen algoritma, tek modlu, çok modlu ve sabit boyutlu çok modlu fonksiyonlar olmak üzere üç gruba ayrılan 23 iyi bilinen test fonksiyonu üzerinde kıyaslanmıştır. VPL kullanılarak elde edilen çözümler optimal çözümler olarak kabul edilmektedir (Moghdani ve Salimifard, 2018).

Döviz Piyasası Algoritması (Exchange Market Algorithm-EMA): EMA hisse senetlerinin borsada işlem görme prosedüründe esinlenen MS bir algoritmadır. Hisse senetlerinin borsada kullanıcılar tarafından nasıl alınıp satıldığının değerlendirilmesi, bu evrimi bir optimizasyon algoritması olarak oluşturmuştur. Önerilen algoritmada, tek bir yineleme içinde piyasanın iki durumu yaşadığı varsayılır. Birinci durum piyasada salınım yoktur, ikinci durumda da ise piyasada salınım vardır. Algoritmada her iterasyondan sonra, bireylerin uygunluğu araştırılmakta ve insanlar sahip oldukları değere göre sıralanmaktadır. İlk durumda algoritma başarılı olan bireyleri işe almaktadır. İkinci durumda ise uygun bireyler aranmaktadır. Bu algoritmada, rasgele sayıların üretimi ve organizasyonu, küresel optimum nokta çıkarmada yüksek kapasiteye yol açan iki emici operatör ve iki arama operatörünün varlığı nedeniyle en iyi şekilde gerçekleştirilir. EMA, sonuçları sürekli problemlerde global optimum noktaları bulmada büyük bir yeteneğe sahiptir (Ghorbani ve Babaei, 2014).

Beyin Fırtınası Optimizasyon Algoritması (Brain Storm Optimization Algorithm-BSO): İnsanın yaratıcı problem çözme becerisi ve belli bir konuda fikir üretip, geliştirme sürecinden esinlenerek geliştirilen bir optimizasyon algoritmasıdır. Önerilen fikirler arsından en iyi çözümün elde edildiği algoritma optimal çözüm olarak kabul edilmektedir (Zhan ve ark., 2012).

3.2.1.4. Sürü tabanlı algoritmalar

Doğada sürü halinde yaşayan canlıların davranışlarında esinlenen algoritmadır. Sürü Tabanlı Algoritmalar, Hayvan Tabanlı Algoritmalar olarak da geçmektedir. Sürü Tabanlı Algoritmanın en çok bilinen algoritması, Parçacık Sürü Optimizasyonudur (Kennedy ve Eberhart, 1995). Literatürde en çok bu algoritma baz alınıp, diğer birçok algoritmanın temelinde de kullanılmaktadır. Diğer Sürü Tabanlı Algoritmalarımızdan bazıları; Yılan Optimizasyon Algoritması (Hashim ve Hussien, 2022), Açlık Oyunları Arama Optimizasyon Algoritması. (Yang ve ark., 2021), Sürüngen Arama Algoritması (Abualigah ve ark., 2021), Yapay Goril Birlikleri Optimize Edici Algoritması (Abdullahzade ve ark., 2021), Bukalemun Sürüsü Algoritması (Braik, 2021), Capuchin Arama Algoritması (Braik ve ark., 2021), At Sürüsü Optimizasyon Algoritması (MiarNaeimi ve ark., 2021), Balina Optimizasyon Algoritması (Rana ve ark., 2020), Kara Dul Optimizasyon Algoritması (Hayyolalam ve Kazem, 2020). Kelebek Optimizasyon Algoritması (Arora ve Sinhg, 2019), Harris hawks Optimizasyon Algoritması (Asghar, 2019), Pity Beetle Optimizasyon Algoritması (Nikos Kallioras, 2018), Çekirge Optimizasyon Algoritması (Serami ve ark., 2017), Yusufçuk Algoritması (Mirjalili, 2016), Karınca Aslan İyileştiricisi (Mirjalili, 2015), Gri Kurt Algoritması (Mirjalili, 2014), Mısır Akbabası Optimizasyon Algoritması (Sur ve ark., 2013) vb. birçok algoritma bulunmaktadır. Sürü tabanlı algoritma isimleri, kısaltması ve yılı Çizelge 3.4.'de gösterilmektedir.


Çizelge 3.4. Sürü tabanlı algoritmalar ve yılı

Algoritma	Kısaltması	Yıl
Yılan Optimizasyonu Algoritması	SO	2022
Açlık Oyunları Arama Optimizasyon Algoritması	HGS	2021
Sürünge Arama Algoritması	RSA	2021
Yapay Goril Birlikleri Optimize Edici Algoritması	GTO	2021
Capuchin Arama Algoritması	capSA	2021
Bukalemun Sürüsü Algoritması	CSA	2021
At Sürüsü Optimizasyon Algoritması	HHO	2021
Balina Optimizasyon Algoritması	WOA	2020
Kara Dul Optimizasyon Algoritması	BWO	2020
Kelebek optimizasyon algoritması	BOA	2019
Harris Şahinleri Optimization Algoritması	HHO	2019
Pity Böceği Optimizasyon Algoritması	PBO	2018
Çekirge Optimizasyon Algoritması	GOA	2017
Yusuçuk Algoritması	DA	2015
Karınca Aslan İyileştiricisi	ALO	2015
Gri Kurt Algoritması	GWO	2014
Mısır Akbabası Optimizasyon Algoritması	EVOA	2013
Parçacık Sürü Optimizasyonu Algoritması	PSO	1995

3.2.2. Gri kurt optimizasyon algoritması (Gray Wolf Optimizer-GWO)

Mirjalili tarafından 2014 yılında ortaya atılan algoritma, doğadaki gri kurtların liderlik hiyerarşisi ve grup avı mekanizmasına dayandırılarak önerilen; doğadan ilham alan başarılı MS bir algoritmadır. Gri kurtlar genellikle sürü halinde yaşarlar. Gruptaki birey sayısı ortalama olarak 5–12'dir. Liderlik hiyerarşisinde alfa, beta, delta ve omega gibi dört tür gri kurt kullanılır. Toplumsal hiyerarşide en üstte alfa kurtları yer alır. Alfa kurtları kurt grubunda en baskın ve sürüye hâkim olan lider kurtlardır. Alfa çoğunlukla avlanma, uyuma yeri, uyanma zamanı vb. konularda karar vermekten sorumludur. Hiyerarşide ikinci sırada bulunan kurtlar beta kurtlardır. Beta kurtlar alfa kurtların

yardımcılığını üstlenir, alfa kurttan gelen emirleri diğer kurtlara iletir ve dönüş sağlayarak iletişim ağını yürütürler. Alfa kurdun yerinden uzaklaşması ya da yaşlanması durumunda beta kurt onun yerine geçer. Liderlik hiyerarşisinde en alt sırada bulunan kurtlar omega kurtlardır. Düşük seviyede bulunan omega kurtları her zaman baskın olan alfa kurtlar seçer. Omega, sürüde önemli bir birey değil gibi görünebilir, ancak omeganın kaybolması durumunda sürülerin iç savaşlar ve sorunlarla karşı karşıya kaldığı gözlemlenmiştir. Bunun nedeni, tüm kurtların omega(lar) tarafından şiddet ve hüsrana yol açmasıdır. Bu, tüm paketin tatmin edilmesine ve baskınlık yapısının korunmasına yardımcı olur. Bazı durumlarda omega aynı zamanda sürüdeki bebek bakıcısıdır. Omega kurtlar, avlanma sırasında son beslenen kurtlardır. Üçüncü sırada bulunan diğere bir kurt grubunda delta kurtlardır. Delta kurtları alfa ve betalara boyun eğmek zorunda kalırken, omega'ya hükmederler (Mirjalili ve ark., 2014). Gri kurdun hiyerarşisi Şekil 3.2.'de gösterildiği gibidir.



Şekil 3.2. Gri kurdun hiyerarşisi (baskınlık yukarıdan aşağıya azalır) (Mirjalili,2014).

Gri kurtların avlanma tekniği ve sosyal hiyerarşisi, optimizasyonu gerçekleştirmek ve GWO'yu tasarlamak için matematiksel olarak modellenmiştir. Sosyal hiyerarşide, en iyi çözüm alfa (α) olarak kabul edilir, ardından ikinci ve üçüncü sırada yer alan en iyi çözümler beta (β) ve delta (δ) dır. Geri kalan çözümlerde omega (ω) olarak adlandırılır ve sürüdeki en zayıf kurtlar olarak bilinir.

Matematiksel model ve algoritma

GWO'nun matematik modellenmesi dört ayrı aşamada gerçekleşir. Sosyal hiyerarşi, izleme, kuşatma ve saldıran avın matematiksel modelleri olarak ayrılmaktadır.


a) Sosyal Hiyerarşi (Social hierarchy)

Matematiksel modelde, en iyi çözüm α , sıradaki ikinci en uygun çözümümüz β ve üçüncü en uygun çözüm δ olarak belirtilir. Diğer çözümlerin hepsinin ω olduğu tahmin edilmektedir. Tüm ω 'lar, arama (optimize etme) ve avlanma sırasında bu üç gri kurt tarafından yönlendirilecektir ve α , β ve δ 'yi Şekil 3.3.'te gösterildiği gibi çevrelemesi gerekir. Gri kurtlar birlikte yaşar ve gruplar halinde avlanır. Arama ve avlanma süreci üç aşamadan meydana gelmektedir;

1-Bir av bulunursa, önce onu izler, kovalar ve yaklaşır.

2-Av kaçarsa, gri kurtlar avın peşine düşer, etrafını sarar ve hareket etmeyi bırakana kadar onu taciz eder.

3-Av yorulduğunda saldırı başlar (Mirjalili, 2014).



Şekil 3.3. GWO 'nun konum güncellemesi (Mirjalili, 2014).

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (3.1)$$

$$\vec{X}(t+1) = \vec{X}_p - \vec{A} \cdot \vec{D} \quad (3.2)$$

Denklem (3.1) ve denklem (3.2)'de gösterilen t Geçerli yinelemeyi gösterir, $\vec{A}$ ve $\vec{C}$ katsayı vektörleridir, $\vec{X}_p$ avın konum vektörüdür, $\vec{X}$ gri bir kurdun konum vektörünü gösterir. $\vec{X}(t+1)$ Kurdun bir sonraki yeri, $\vec{X}(t)$ kurdun sabit konumu, $\vec{X}_p$ avın konumu, $\vec{D}$ av ve kurt arasındaki vektör mesafesi.

$\vec{A}$ ve $\vec{C}$ katsayı vektörleri aşağıdaki gibi hesaplanır.


$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (3.3)$$

$$\vec{C} = 2\vec{r}_2 \quad (3.4)$$

$\vec{r}_1$ ve $\vec{r}_2$ $[0,1]$ aralığında rastgele oluşturulmuş bir vektör, a : parametresinin değerleri doğrusal olarak azaldığı bir vektördür, koşu sırasında 2'den 0'a doğru azalır.

$$A = 2 - 2\left(\frac{t}{\max_t}\right) \quad (3.5)$$

t burada yineleme sayını $\max_t$ ise maksimum yineleme sayısıdır.



Şekil 3.4. 2D ve 3D konum vektörleri ve olası sonraki konumları (Faria, 2018).

Şekil (3.4.) ‘teki kavram aynı şekilde n boyutlu bir arama uzayı içinde genişletilebilir. Burada amaç kurtların (alfa, beta, delta) avın konumunu tahmin etmeleri ve diğer kurtlar ile avın etrafını sararak konumlarını rastgele güncellemeleridir.

b) Avcılık (Hunting)

Avlanma genelde alfa kurdu tarafından yönetilir. Diğer kurtlar arada ava katılabilir. Arama uzayında optimum avın konumu belli değildir. Ancak kurtların avlanma davranışı, en iyi çözüm alfa olmak üzere beta ve delta hakkında da bilgiye sahip olmak üzere matematiksel olarak simüle eder. Optimizasyon sırasında, şu ana kadar ulaşılan en iyi üç çözüm sırasıyla α , β ve δ olduğu varsayılır ve her ω kurdun α , β ve δ 'ye göre konumunu aynı anda aşağıdaki gibi günceller

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \quad (3.6)$$

$$\vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \quad (3.7)$$

$$\vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (3.8)$$

Burada X_1 , X_2 ve X_3 aşağıdaki gibi hesaplanır.

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}(\vec{D}_\alpha) \quad (3.9)$$


$$\vec{X}_2 = \vec{X}_\beta - \vec{A}(\vec{D}_\beta) \quad (3.10)$$

$$\vec{X}_3 = \vec{X}_\delta - \vec{A}(\vec{D}_\delta) \quad (3.11)$$

Böylece liderler, omega kurtlarını en uygun konuma doğru ilerlemeye yönlendirir. Matematiksel olarak kurdun yeni konumu Denklem (3.12)'daki gibi güncellenir.

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (3.12)$$


Şekil 3.5., bir arama aracısının konumunu 2B arama uzayında alfa, beta ve deltaya göre nasıl güncellediğini gösterir. Arama uzayındaki alfa, beta ve delta konumları ile tanımlanan bir daire içinde nihai konumun rastgele bir yerde olacağı gözlemlenebilir. Yani ilk üç kurt avın konumunu tahmin eder ve diğer kurtlarda avın çevresinde konumlarını gelişi güzel şekilde günceller (Mirjalili, 2014).



Şekil 3.5. GWO'da pozisyon güncelleme (Mirjalili,2014).

c) Ava Saldırma (Attacking Prey)

GWO algoritması çoğunlukla alfa, beta ve deltanın konumuna göre arama yapar. Kurtlar avı aramak için birbirinden ayrılırlar. Av yorulup, konumu belirlendikten sonra kurtlar birleşip saldırı işlemini gerçekleştirir. Ava saldırma işleminin matematiksel modellemesi ise $\vec{A}$ değerine göre gerçekleşir. Gri kurdun avına yaklaşması ya da uzaklaşması bu değere göre belirlenir. $\vec{A} \in [-1,1]$ aralığında ise arama ajanının bir sonraki konumu, mevcut konumu ile avın konumu arasındaki herhangi bir konumda olabilir, $\vec{A}$ değeri yinelemeler boyunca r_i değişkenine bağlı olarak 2' den 0' a düşürülür. $\vec{A}$ değerimiz $|A| > 1$ olduğunda gri kurtlar daha uygun bir av bulma umuduyla avdan uzaklaşır $|A| < 1$ olduğunda ise gri kurtlar ava yaklaşır. Bu işlem GWO algoritmasının yerel minimumlara takılmasını engeller (Mirjalili,2014).



Şekil 3.6. Av aramaya karşı ava saldırmak (Mirjalili, 2014).

d) Av arama (Search for prey)

Gri kurtlar çoğunlukla alfa, beta ve deltanın bulunduğu konuma göre arama yapar. Av aramaya çıktıklarında ayrı ayrı giderler saldırı gerçekleştiğinde ise birleşirler. Diverjansı matematiksel olarak modellemek için, $\vec{A}$ arama ajanını avdan ayrılmaya zorlamak için 1'den büyük veya -1'den küçük rastgele değerler alır. A parametresi sırasıyla keşif ve yararlanmayı vurgulamak için 2'den 0'a düşürülür. $A < 1$ olduğunda aday çözümler ava uzaklaşır, $A > 1$ olduğunda ise ava doğru yaklaşır. GWO algoritmasını diğer bir bileşeni olan $\vec{C}$ vektörü $[0,2]$ aralığında rastgele değerler almaktadır. $\vec{A}$ vektörü doğrusal olarak azalırken $\vec{C}$ vektöründe böyle bir azalma olmadığını söylemekte fayda var. $\vec{C}$ Vektörü doğada yaklaşan avın önüne geçen engeller olarak kabul edilebilir. Normalde doğada olan engeller kurtların yollarına çıkarak onların avlarına daha rahat ve hızlı bir şekilde yaklaşmalarına engel olmaktadır. Bu durumda vektörümüz $\vec{C} > 1$ olduğunda gri kurtların avlarına yaklaşmalarına engel olmakta, $\vec{C} < 1$ olduğunda ise av için rastgele ağırlıklar sağlar. $\vec{C}$ vektörünün yaptığı, kurdun bulunduğu yere göre avına rastgele bir ağırlık verebilir ya da kurtların ava ulaşmasını güçleştirebilir. Bunun tersi de olabilir kurtlara ulaşmayı kolaylaştırabilir. Keşfi yalnızca ilk tekrarlarında değil, aynı

zamanda son tekrarlar da önemini belirtmek için kasıtlı olarak $\vec{C}'$ nin her zaman rastgele değerler almasını bekleriz. Bu vektör, özellikle son tekrarlar da, yerel optimum durgunluk durumunda çok faydalıdır. Güncellemeler boyunca alfa, beta ve delta kurtları avın bulunduğu konumunu tahmin eder. Her aday çözüm, avdan olan mesafesini günceller. GWO Algoritmasında avlanma, son kriterler sağlandığında sonlandırılır (Mirjalili,2014). GWO algoritması kodu aşağıda gösterildiği gibidir.

Gri Kurt Popülasyonu Başlat $X_i = (i = 1, 2, \dots, n)$

a, A, C parametrelerini ata

Her bir ajanın uygunluk değerini hesapla

$X_\alpha, X_\beta, X_\delta$ değerlerini bul

X_α = Popülasyondaki en iyi konuma sahip ajan

X_β Popülasyondaki en iyi ikinci konuma sahip ajan

X_δ = Popülasyondaki en iyi üçüncü konuma sahip ajan

While ($t < \text{Maksimum İterasyon sayısı}$)

for Her bir ajan

Mevcut arama ajanların konumlarını Denklem 3.12 ile güncelle.

end for

a, A ve C parametrelerini güncelle

Her bir ajanın uygunluk değerini hesapla

X_α, X_β ve X_δ parametrelerini hesapla

$t = t + 1$

end while

return X_α

Genel olarak, GWO sürekli optimizasyon problemlerini çözmek için tasarlanmıştır. Özellik seçimi gibi ikili optimizasyon sorunları için GWO'nun ikili versiyonu gereklidir. Son zamanlarda, Emary ve ark. (2016) tarafından özellik seçimi problemlerini çözmek için GWO'nun ikili versiyonu olan, İkili Gri Kurt Optimizasyon Modeli 1 (BGWO1) ve İkili Gri Kurt Optimizasyon Modeli 2 (BGWO2) önerdi (Too ve ark., 2018; Emary ve ark., 2016).

Özellik seçimi, önemli özellikleri tanımlamanın ve gereksiz olanları veri kümesinden kaldırmanın bir yolunu sağlar. Özellik seçimi hedefleri, veri boyutunun azaltılması, tahmin performansının iyileştirilmesi ve farklı makine öğrenimi uygulamalarında iyi veriyi seçmesidir. Çalışmada özellik seçiminde özellikler 0 ya da 1 olmak üzere ikili olarak ifade edilmektedir. Seçilen özellikler 1 olarak ifade edilirken, seçilmemiş özellik ise 0 olarak ifade edilmektedir. Örneğin; bir $A = (1,0,0,0,1,1,0,1,1,0)$ sonucu elde edildiğinde, burada birinci, beşinci, altıncı, sekizinci ve dokuzuncu özelliklerin seçildiğini gösterir (Too ve ark., 2016) BGWO1 ve BGWO2'nin çalışması aşağıda açıklanmıştır.

3.2.2.1. İkili Gri Kurt optimizasyon modeli 1 (BGWO1)

İlk yaklaşım için BGWO1, kurdun konumunu aşağıdaki gibi güncellemek için çaprazlama operatörünü kullanır:

$$X(t + 1) = crossover(Y_1, Y_2, Y_3), \quad (3.13)$$

Buradaki (Y_1, Y_2, Y_3) , çözümler arasındaki çaprazlama işlemidir. Y_1, Y_2, Y_3 sırasıyla α, β ve δ kurtlarının hareketinden etkilenen ikili vektörlerdir. Y_1, Y_2, Y_3 aşağıdaki denklemlerdeki gibi hesaplanır:

$$Y_1^d = \begin{cases} 1, & \text{if } (X_\alpha^d + bstep_\alpha^d) \geq 1, \\ 0, & \text{otherwise} \end{cases} \quad (3.14)$$

Denklem (3.14) da verilen X_α^d ifadesi alfanın konumu, d arama uzayı, $bstep_\alpha^d$ ifadesi ise ikili adımı temsil eder.

$$bstep_\alpha^d = \begin{cases} 1, & \text{if } cstep_\alpha^d \geq r_3 \\ 0, & \text{otherwise} \end{cases}, \quad (3.15)$$

Denklem (3.15) de verilen r_3 $[0, 1]$ aralığında rastgele bir değer alan vektördür, $cstep_\alpha^d$ ise sürekli önemli adım büyüklüğünü ifade eder ve denklem (3.16)'de ki gibi bulunur.

$$cstep_{\alpha}^d = \frac{1}{1 + \exp(-10(A_1^d \cdot D_{\alpha}^d - 0.5))} , \quad (3.16)$$

Denklem (1.16) deki A_1^d ve D_{α}^d ifadesi (3.3) ve (3.6) denklemleri uygulanarak belirlenir.

$$Y_2^d = \begin{cases} 1, & \text{if } (X_{\beta}^d + bstep_{\beta}^d) \geq 1 \\ 0, & \text{otherwise} \end{cases} , \quad (3.17)$$

Denklem (3.17) da verilen X_{β}^d ifadesi betanın konumu, $bstep_{\beta}^d$ ifadesi ise ikili adımı temsil eder.

$$bstep_{\beta}^d = \begin{cases} 1, & \text{if } cstep_{\beta}^d \geq r_4 \\ 0, & \text{otherwise} \end{cases} , \quad (3.18)$$

Denklem (3.18) de verilen r_4 $[0, 1]$ aralığında rastgele bir değer alan vektördür, $cstep_{\beta}^d$ ise sürekli önemli adım büyüklüğünü ifade eder ve denklem (3.19)'de ki gibi bulunur.

$$cstep_{\beta}^d = \frac{1}{1 + \exp(-10(A_1^d \cdot D_{\beta}^d - 0.5))} , \quad (3.19)$$

Denklem (1.19) deki A_1^d ve D_{α}^d ifadesi (1.3) ve (1.7) denklemleri uygulanarak belirlenir.

$$Y_3^d = \begin{cases} 1, & \text{if } (X_{\delta}^d + bstep_{\delta}^d) \geq 1 \\ 0, & \text{otherwise} \end{cases} , \quad (3.20)$$

Denklem (1.20) da verilen X_{δ}^d ifadesi betanın konumu, $bstep_{\delta}^d$ ifadesi ise ikili adımı temsil eder.

$$bstep_{\delta}^d = \begin{cases} 1, & \text{if } cstep_{\delta}^d \geq r_5 \\ 0, & \text{otherwise} \end{cases} , \quad (3.21)$$

Denklem (3.21) de verilen r_5 $[0, 1]$ aralığında rastgele bir değer alan vektördür, $cstep_{\delta}^d$ ise sürekli önemli adım büyüklüğünü ifade eder ve denklem (3.22)'de ki gibi bulunur.

$$cstep_{\beta}^d = \frac{1}{1 + \exp(-10(A_1^d \cdot D_{\beta}^d - 0.5))}, \quad (3.22)$$

Denklem (3.22)'te ki A_1^d ve D_{β}^d ifadesi (1.3) ve (1.8) denklemleri uygulanarak belirlenir. Y_1, Y_2 ve Y_3 elde edildikten sonra kurdun yeni konumu çaprazlama işlemi kullanılarak aşağıdaki gibi güncellenir:

$$X^d(t+1) = \begin{cases} Y_1^d, & \text{if } r_6 < \frac{1}{3} \\ Y_2^d, & \text{if } \frac{1}{3} \leq r_6 < \frac{2}{3} \\ Y_3^d, & \text{otherwise} \end{cases} \quad (3.23)$$

Denklem (3.23) de verilen d, arama uzayının boyutudur ve $r_6, [0, 1]$ aralığında düzgün dağılmış rastgele bir sayıdır.

Başlangıçta, gri kurt popülasyonu rastgele başlatılır, ardından her bir kurdun uygunluğu hesaplanır. Sırasıyla en iyi çözümler α, β ve δ olarak tanımlanır. Y_1, Y_2 ve Y_3 sırayla her kurt için ayrı olarak hesaplanır. Sonrasında Y_1, Y_2 ve Y_3 aralarında çaprazlama uygulanarak kurdun yeni konumu belirlenmiş olur. Böylece α, β ve δ konumları güncellenir. Algoritma kriter sağlanıncaya kadar tekrarlanır (Too ve ark., 2018).

3.2.2.2. İkili Gri Kurt optimizasyon modeli 2 (BGWO2)

İkinci yaklaşım için, BGWO2, Denklem (3.24)'da gösterildiği gibi konumu ikili bir vektöre dönüştürerek kurdun konumunu günceller.

$$X^d(t+1) = \begin{cases} 1, & \text{if } S\left(\frac{X_1^d + X_2^d + X_3^d}{3}\right) \geq r_7 \\ 0, & \text{otherwise} \end{cases} \quad (3.24)$$

Denklem (3.24) de verilen d arama uzayının boyutudur, $r_7 [0, 1]$ aralığında rastgele bir vektördür ve S sigmoid fonksiyondur, sigmoid fonksiyonu denklem (3.27)'de gösterildiği şekilde ifade edilebilir:

$$S(x) = \frac{1}{1+\exp(-10(x-0.5))} \quad , \quad (3.25)$$

Öncelikle, rastgele kurtların başlangıç popülasyonu başlatılır. Daha sonra kurtların uygunluğu değerlendirilir. Üç lider kurt α , β ve δ uygunluk durumuna göre seçilir. Her kurt için, X_1 , X_2 , X_3 değerleri sırasıyla hesaplanır. Ardından denklem (3.24) uygulanarak gri kurdun yeni konumu güncellenir. Daha sonra kurtların uygunluğu değerlendirilir ve α , β ve δ konumları güncellenir. Algoritma, kriter sağlanana kadar tekrarlanır (Too ve ark., 2018).

3.2.3. K-NN

K en yakın komşu (K-Nearest Neighbors) algoritması, uygulaması kolay olan, basit bir denetimli makine öğrenmesi algoritmasıdır. Algoritma çok yönlüdür. Herhangi bir model kullanmadan, sınıflandırma, arama ve regresyon problemlerin çözümünde kullanılmaktadır. İsminden de anlaşılacağı üzere, komşularına bakarak tahminlemede bulunan bir algoritmadır. Algoritma test verisi ile eğitim verisi arasındaki mesafeyi hesaplayarak ve her değer için, ilgili değere en yakın komşu kümesi üzerinden bir sınıflayıcı oluşturarak değerleri sınıflandırır. Sınıflandırma için en yakın k komşusu alınır, özellik seçiminde k en yakın eğitim örneklerinden oluşur. K değerini belirlemenin bir yolu bulunmamaktadır, en iyi k değerini belirlememiz için bazı değerleri denemek gerekir. Literatür incelendiğinde k için en çok tercih edilen değer 5'tir. k=1 veya k=2 gibi çok düşük bir değer alındığında k değeri gürültülü olabilir ve modelde aykırı değerlerin etkilerine yol açabilir. k için büyük değerler iyidir, ancak bazı zorluklar bulabilir, bu zorluklardan biri çok zaman almasıdır. Sonuçları tahmin etmek için algoritmada eşitlik durumu olmasın diye k değeri çoğunlukla tek sayı seçilir. Örneğin; k değeri 4 alındığında, modelin 0 ve 1 tahmininde en yakın iki komşusu 0, diğer en yakın iki komşusu 1 ise, uygun olmayan bir durum ortaya çıkabilir. K-NN'de genel olarak öklid mesafesi kullanılsa da daha farklı ölçümlerde mevcuttur. K-NN algoritmasında sıklıkla kullanılan diğer ölçümlerden bazıları Manhattan mesafesi, Minkowski mesafesi, Chebyshev mesafesi, Hamming mesafesi, Mahalanobis mesafesi, Haversine mesafesi, Levenshtein mesafesi, Sørensen-dice mesafesi, Jaccard mesafesi vb. mesafeler kullanılmaktadır (Sahu ve ark., 2018; Too ve ark., 2018; Nutanong ve ark, 2010).

Sınıflandırıcıların performansını değerlendirmek için farklı ölçüler mevcuttur. Bu çalışmada doğruluk ölçütü kullanılmıştır. Doğruluk, genel sınıflandırıcı performansını değerlendirmek için hesaplanır. Doğru sınıflandırılan test örneklerinin test edilen örnek sayısına oranı olarak tanımlanır, (Alfeilat ve ark., 2019).

$$Accuracy = \frac{TP+FN}{TP+FP+TN+FN}, \quad (3.26)$$

Denklem (3.26)'de verilen TN ifadesi gerçek negatif, negatif olarak tanımlanan negatif örneklerin sayısı, TP ifadesi gerçek pozitif, pozitif olarak tanımlanan örneklerin sayısı, FN ifadesi yanlış pozitif, pozitif olarak tanımlanan negatif örnek sayısı, FN ifadesi yanlış negatif, negatif olarak tanımlanan pozitif örneklerin sayısıdır (Momanyi ve Segera; 2021).


3.2.4. Lojistik Regresyon (Logistic Regression)

Lojistik regresyon, iki olası sonucu olan sınıflandırma problemlerinin olasılıklarını modelleyen, veri kümesini analiz etmek için kategorik tipte bağımlı değişken ile bağımsız değişken(ler) arasındaki ilişkiyi inceleyen istatistiksel bir yöntemdir. Sınıflandırma problemleri için doğrusal regresyon modelinin bir uzantısıdır. Kategorik veya sayısal verilerin sınıflandırılmasında kullanılır. Bağımsız değişken ile bağımlı değişkenler arasında kategorik veri oluşması durumunda neden-sonuç ilişkisini incelemektedir. Burada amaç, rastgele bir değişkenin olasılığını modellemektir. Algoritma doğası gereği denetimli olduğundan tahminleri yapmak için etiketli veri kümesini kullanır. Girdilerin ağırlıkları toplamı 0 ile 1 arasında eşleşebilen değerler alabilen sigmoid fonksiyonundan geçer, eşleşme sonucu sigmoid eğrisi veya S-eğrisi olarak adlandırdığımız eğri elde edilir (Akgun, 2012; Lee, 2005; Boateng ve Abaye, 2019; De Cock ve ark., 2021).

Lojistik regresyon belirli bir bağımsız değişken kümesini kullanarak kategorik bağımlı değişkenlerin değerlerini tahmin eder ve doğruluk tahmini için Maksimum Olabilirlik Tahmini (ML) yöntemi kullanılır. Çıktı olarak 0 veya 1, evet ya da hayır, kadın veya erkek gibi sayısal ya da kategorik iki değer alır. Bağımsız ve bağımlı değişkenler

arasında doğrusal bir ilişki olması beklenilmez. Lojistik regresyonda bağımlı değişken Bernoulli dağılımını takip eder (Boateng ve Abaye, 2019; Schober ve Vetter, 2021).

Lojistik regresyon, istatistik alanında sınıflandırma problemlerini öğrenmek için geliştirilmiş denetimli bir makine öğrenme algoritmasıdır. Girdiler (x), bir çıktı değerini (y) tahmin etmek için katsayı değerleri veya ağırlıklar doğrusal olarak birleştirilir. Lojistik regresyon Şekil 3.8.' de gösterilmektedir.



Şekil 3.7. Lojistik Regresyon ve Lineer Regresyon Modeli (Sen, 2020).

Lojistik regresyon 3 temel yöntem başlığı altında toplanabilir; İkili (binary), sıralı (ordinal) ve çoklu (multinomial) lojistik regresyon yöntemleri.

a) İkili Lojistik Regresyon (Binary Logistic Regression): Bağımlı değişken kadın-erkek, evet-hayır, kazandı-kaybetti, 0 ya da 1 gibi ikili sınıflardan oluşuyorsa bu durumda ikili lojistik regresyon kullanılır. İkili lojistik regresyonda, sonuçlar kolaylık olsun diye "0" veya "1" olarak kodlanır, böylece daha basit yorumlanmış olur. İkili lojistik regresyonun amacı, bir dizi tahmin ediciye dayalı olarak sonuç kategorilerinden birine düşme olasılığını değerlendirmektir (Wright,1995). İkili Lojistik Regresyon modellerindeki değişkenler, Bernoulli dağılımı göstermektedir. Bağımsız değişkenler;

kategorik ise “faktör değişken”, sürekli ise “ortak değişken” (covariate) olarak adlandırılmaktadır (Schober ve Vetter, 2021).

İkili lojistik regresyon modelini elde etme için 3.27 denklemi ele alınır. 3.27 denklemi doğrusal olup bağımlı değişken kesikli, bağımsız değişken ise sürekli. Logit dönüşümü yapılarak denklem 3.28’ deki gibi ikili lojistik regresyon modeli elde edilir.

$$E\left(\frac{Y}{X}\right) = \beta_0 + \beta_1 X_i \quad (3.27)$$

$$P(Y) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}} = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x)}} \quad (3.28)$$

b) Çoklu Lojistik Regresyon (Multinomial Logistic Regression): Bağımlı değişkenimiz ikiden fazla sınıftan oluşuyorsa çoklu regresyon modeli kullanılır. Çoklu regresyon ikili regresyonun genişletilmiş halidir.

c) Sıralı Lojistik Regresyon (Ordinal Logistic Regression): Bu analiz çeşidinde bağımlı değişken sıralı kategorilerden oluşur. Örneğin insan değişkenini ele alırsak; bebek, çocuk, genç ve yaşlı şeklinde bir sıraya göre sınıflara ayrılıyorsa bu sıralı kategorik bir değişken olarak tanımlanır.

3.2.4.1. Lojistik Regresyon Matematiksel Modeli

İki düzeyli lojistik regresyon modellerinde kategorik bağımlı değişken (Y), bağımsız değişken değerlerine bağlı olarak (X) değişkeni kullanılarak, bağımsız değişkende bir olgunun gerçekleşmesi ya da riskli durumun oluşması (Y=1) ile kodlanır ve gerçekleşmemesi ya da risksiz durumun oluşması da (Y=0) ile kodlanır. Matematiksel ifadesi aşağıdaki biçimde tanımlanabilir (Hosmer ve Lemeshow, 1989).

$$P = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_n X_n)}} = \frac{e^{(\beta_0 + \beta_1 X_1 + \dots + \beta_n X_n)}}{1 + e^{(\beta_0 + \beta_1 X_1 + \dots + \beta_n X_n)}} \quad (3.29)$$

β_0 : sabit terim; $\beta_1, \beta_2, \dots, \beta_n$: regresyon katsayıları; $X_1, X_2, \dots, X_n$ bağımsız değişkenler n: bağımsız değişken sayısı;

$$Z_i = \beta_0 X_{1i} + \beta_1 X_{1i} + \dots + \beta_n X_{ni} = X_i \beta \quad (3.30)$$

olarak tanımlanan denklem (3.30) açıklayıcı değişkenlerin doğrusal kombinasyonları verilen denklem (3.29)'da yerine yazıldığında, P olasılığı,

$$P = \frac{1}{1 + e^{-Z_i}} = \frac{e^{Z_i}}{1 + e^{Z_i}} \quad (3.31)$$

denklem (3.31)'te parametre değerlerinin tahmininde doğrusal model elde etmek için logaritması alınıp lojit (logit) dönüşüm yapılarak, olasılık değeri $-\infty$, $+\infty$ arasında tanımlı hale getirilir. Denklem (3.32) ile verilen biçimde ifade edilebilir.

$$\text{Lojit}(P) = \left(\ln \frac{P}{1-P} \right) = \ln e^{Z_i} = Z_i = \beta_0 + \beta_1 X_{1i} + \dots + \beta_n X_{ni} \quad (3.32)$$

Denklemin sol tarafı “lojit” olarak isimlendirilir. Aynı ifadenin “Lojistik Regresyon” olarak ifadesi denklem (3.7) ile verilmektedir.

$$P = \frac{e^{\beta_0 + \beta_1 X_{1i} + \dots + \beta_n X_{ni}}}{1 + e^{\beta_0 + \beta_1 X_{1i} + \dots + \beta_n X_{ni}}} \quad (3.33)$$

Denklem (3.33)'de verilen ifadede P: İncelenen olayın gözlenme olasılığı belirtir.

Odds Ratio (OR): Lojistik regresyonda kullanılan $\text{odds(OR)} = \exp(\beta)$ değerine eşittir.

Odds: Odds oranı, iki farklı grupta meydana gelen bir olayın karşılaştırılmasıdır. Odds başarı ya da görülme olasılığının “P”, başarısızlık ya da görülmemeye olasılığına “1-P” oranıdır. Odds değeri $(0, +\infty)$ arasında değerler alırken, aynı olasılığın lojit değeri $-\infty$ ile $+\infty$ arasında değerler alır. Odds oranı denklem (3.34) te verilmektedir.

$$\text{Odds} = P/(1-P) \quad (3.34)$$

Odds oranı, modeldeki diğer tahmin değişkenlerini hesaba kattıktan sonra, bir tahmin değişkeninde bir birimlik bir değişiklik verildiğinde bir sonuç kategorisinde olma şansını

gösterir. Birden büyük olan olasılık oranları, tahmin değişkeninde bir puanlık bir artış göz önüne alındığında, temel sonuç kategorisine düşme olasılığının daha yüksek olduğunu gösterir. Birden küçük oranlar, bir tahmincinin değeri bir puan artırıldığında referans sonuç kategorisine düşme olasılığının daha düşük olduğunu gösterir (Wright,1995).

Lojistik regresyon analizi sonucunda elde edilen modelin uygun olup olmadığı “model ki-kare” testi ile, her bir bağımsız değişkenin modelde varlığının anlamlı olup olmadığı ise Wald istatistiği ile test edilir. Paralellik varsayımı W istatistiği ile test edilir. Wald ki-kare istatistiği t değerlerinin karesine eşittir (Hosmer ve Lemeshow, 1989).

$$t = \frac{\hat{\beta}}{SH_{\hat{\beta}}} , \quad t^2 = \text{Wald} \quad (3.35)$$

Denklem (3.35) da ki β değerleri katsayılar olup, deneğin bir işi ya da diğerini yapma ihtimalini belirlemede kullanılır. β üstündeki işaretler ilişkinin yönünü gösterir. Wald ist.= $\left(\frac{B}{S.E}\right)^2$ ile bulunur.

4. BULGULAR

Bu çalışmada, PISA verilerin sınıflandırmasında, öznitelik seçiminde GWO algoritmasının ikili versiyonu olan BGWO kullanılmıştır. Algoritmaların her birinde popülasyon boyutu 10 ve yinleme sayısı 100'e ayarlanmıştır. Hızlı ve basit olması nedeniyle uygunluk değerlendirmesinde öklid mesafesine sahip bir KNN sınıflandırıcısı kullanılmaktadır. Çalışmada, her bir öznitelik seçim algoritması, k=3, k=5 ve k=11, değerleri için 30 kez çalıştırılmıştır. BGWO'nun 30 kez çalışma süresince elde edilen en iyi çözümün Çizelge 4.1. de görülebileceği gibi, önerilen BGWO tarafından en yüksek sınıflandırma doğruluğu farklı k değerleri için ortalamaları alınarak 0.2669 olarak bulunmuştur.

Çizelge 4.1. BGWO' nun 30 kez çalıştırma sonucundaki sınıflandırma doğruluğu

	k=3		k=5		k=11	
	BGWO1	BGWO2	BGWO1	BGWO2	BGWO1	BGWO2
1	0.3107	0.3085	0.2830	0.2699	0.3100	0.2516
2	0.3275	0.2823	0.3166	0.2903	0.3115	0.2451
3	0.2961	0.3027	0.3005	0.2728	0.2874	0.2684
4	0.3275	0.2786	0.3187	0.2670	0.2888	0.2735
5	0.3348	0.2947	0.3224	0.2801	0.3093	0.2473
6	0.3290	0.2976	0.3122	0.2867	0.3136	0.2648
7	0.2983	0.2845	0.3202	0.2815	0.2991	0.2713
8	0.3209	0.2954	0.2998	0.2837	0.2823	0.3056
9	0.3166	0.2961	0.3078	0.2640	0.3166	0.2567
10	0.3107	0.2910	0.3136	0.2750	0.3100	0.2633
11	0.3005	0.2859	0.3034	0.2779	0.3063	0.2640
12	0.3115	0.2859	0.3158	0.2939	0.3078	0.2713
13	0.3012	0.2939	0.2998	0.2713	0.2961	0.2750
14	0.3253	0.2888	0.2881	0.2743	0.3071	0.2582
15	0.3151	0.2954	0.2881	0.2713	0.2983	0.2560
16	0.3034	0.2735	0.3005	0.2947	0.2750	0.2691
17	0.3063	0.2801	0.3005	0.2801	0.3005	0.2713
18	0.3056	0.2867	0.2998	0.2823	0.2903	0.2684
19	0.3144	0.3049	0.3075	0.2888	0.2969	0.2677
20	0.3158	0.2859	0.2910	0.2918	0.2925	0.2524
21	0.3224	0.2991	0.3209	0.2735	0.3071	0.2706

Çizelge 4.1. BGWO' nun 30 kez çalıştırma sonucundaki sınıflandırma doğruluğu(devam)

22	0.2925	0.2983	0.3115	0.2743	0.2670	0.2706
23	0.3355	0.3180	0.2910	0.2772	0.3209	0.2932
24	0.3020	0.2743	0.2896	0.2662	0.3049	0.2648
25	0.3370	0.2918	0.3056	0.2772	0.2761	0.2743
26	0.3370	0.2954	0.2991	0.2823	0.2983	0.2735
27	0.3195	0.3005	0.3020	0.2560	0.2910	0.2721
28	0.3224	0.2932	0.3005	0.2881	0.2896	0.2516
29	0.3151	0.2910	0.3093	0.2918	0.2699	0.2684
30	0.3231	0.2808	0.3144	0.2830	0.2954	0.2662
Ortalama	0.3159	0.2918	0.3044	0.2789	0.2973	0.2669


Çalışmada k'nın 3, 5 ve 11 değerleri için elde edilen sonuçlar Çizelge 4.2. de gösterilmektedir. Çizelge 4.2. de görüldüğü üzere en iyi performans k=11 değeri BGWO2 için %76 olarak bulunmuştur.

Çizelge 4.2. BGWO1 ve BGWO2' nun farklı k değerleri için sınıflandırma sonuçları

	BGWO1		BGWO2	
	Uygunluk Değeri	Peformans	Uygunluk değeri	Performans
K=3	0.2725	%71	0.2735	%73
K=5	0.2830	%72	0.2560	%75
K=11	0.2670	%74	0.2451	%76


Bu çalışmada Tablo 4.2.'deki sonuca göre en iyi performans k=11 ve BGWO2'de elde edildiğinden dolayı, k=11 ve GWO2'nin sonucunda öğrencilerin matematik puanlarına göre sınıflandırmalarda ön plana çıkan 21 değişken olduğu belirlenmiştir. Bu değişkenler ST004D01T, HISCED, DURECEC, REPEAT, ESCS, METASPAM, HOMEPOS, TEACHSUP, DIRINS, EMOSUPS, PISADIFF, PERCOMP, RESILIENCE, GCSELFEEFF, ATTIMM, COGFLEX, AWACOM, DISCRIM, HOMESCH, COMPICT, ICTCLASS'dır.

Önerilen algoritmanın k=3 değeri için öznitelik seçim yönteminin en iyi sınıflandırma doğruluğu Şekil 4.1'de görüldüğü üzeredir.




Şekil 4.1. BGWO2' nin k=3 sınıflandırma tablosu.

Önerilen algoritmanın k=5 değeri için öznitelik seçim yönteminin en iyi sınıflandırma doğruluğu Şekil 4.2'de görüldüğü üzeredir.



Şekil 4.2. BGWO2' nin k=5 sınıflandırma tablosu.

Önerilen algoritmanın $k=11$ değeri için öznitelik seçim yönteminin en iyi sınıflandırma doğruluğu Şekil 4.3'te görüldüğü üzeredir.



Şekil 4.3. BGWO2' nin $k=11$ sınıflandırma tablosu.

Çizelge 4.3. Matematik okuryazarlığında ön plana çıkan değişkenler

Değişken adı	Açıklama	Değişken adı	Açıklama
ESCS	Ekonomik,sosyal ve kültürel durum	EMOSUPS	Ebeveynlerin duygusal desteği
HOMEPOS	Ev eşyaları	ENTUSE	Boş zamanda BİT kullanımı
ST004D01T	Cinsiyet	PERCOMP	Okulda rekabet edebilirlik algısı
HISCED	Ebeveynlerin en yüksek eğitimi	COMPICT	Algılanan BİT yeterliliği
DURECEC	Öğrencinin okul öncesi eğitimi	RESILIENCE	Öz yeterlik
REPEAT	Sınıfta kalma	ICTCLASS	Derslerde ders ile ilgili BİT kullanımı
METASPAM	Güvenilirliği değerlendirme	GCSELFEEFF	Küresel sorunlarla ilgili Öz-yeterlik
AWACOM	Kültürlerarası iletişim farkındalığı	PISADIFF	PISA testinin zorluk algısı
TEACHSUP	Derslerinde Öğretmen desteği	DISCRIM	Sınıflarda Disiplin İklimi
DIRINS	Öğretmen yönlendirmeli öğretim	COGFLEX	Bilişsel esneklik/uyarlanabilirlik
ATTIMM	Öğrencilerin göçmenlere yönelik tutumları		

Çizelge 4.3. te öne çıkan indislerden, öğrencilerin ailelerinin sosyo ekonomik düzeylerinde belirleyici olan ailenin sosyo ekonomik ve kültürel düzeyini belirten (ESCS), cinsiyet (ST004D01T), ebeveynlerin en yüksek eğitim seviyesi indeksi

(HISCED) ön plana çıkmıştır. Ailenin sahip olduğu mal varlığı temsil eden ev eşyaları (HOMEPOS), öğrencinin rekabet edebilir algısı (PERCOMP), öğrencinin okul öncesi eğitimi (DURECEC), sınıf tekrarlama durumu (REPEAT), derslerinde öğretmen desteği (TEACHSUP), öğretmen yönlendirmeli öğretim (DIRINS) öne çıkanlar arasındadır. Ayrıca üst biliş PISA tarafından üç başlık altına toplanmaktadır; bunlardan güvenilirliği değerlendirmek (METASPAM) öne çıkmıştır. Öğretmen yönlendirmeli öğretim (DIRINS), öğrenci tarafından algılanan aile desteği (EMOSUPS), zor durumda kaldığı zaman genellikle kendi çözüm yolumu bulabilme, zor zamanların üstesinden gelme, kendi başarılarından gurur duyması ile ilgili öz-yeterlilik (RESILIENCE) değişkeni öne çıkmıştır. BİT aşinalık ile ilgili üç değişken, dijital cihazların okul dışında okul çalışmaları için, okuldaki etkinlikler için ne sıklıkla kullanıldığı ve okul dışında boş zaman etkinlikleri ile ilgilidir. İlgili indeksler; boş zaman BİT kullanımı (ENTUSE), algılanan BİT yeterliliği (COMPICT), bilişsel esneklik/uyarlana bilirlilik (COGFLEX), derslerde ders ile ilgili BİT kullanımı (ICTCLASS), yine öğrencilerin okumaya olan tutumları (PISADIFF), sınıflardaki disiplin iklimi (DISCRIM) değişkenleri ön plana çıkmıştır. Küresel sorunlarla ilgili öz-yeterlilik (GCSELFEEFF), öğrencilerin göçmenlere yönelik tutumları (ATTIMM), kültürlerarası iletişim farkındalığı (AWACOM), bu değişkenler dikkate alınarak yapılan lojistik regresyon analizinde ise Enter yöntemi uygulanmış ve sonuçlar aşağıdaki Çizelge 4.4., Çizelge 4.5., Çizelge 4.6. ve Çizelge 4.7.'deki gibidir.

Çizelge 4.4. Model Katsayılarının Omnibus Testleri

		ki-kare	df	Sig.
Adım 1	Adım	2259.427	21	.000
	Block	2259.427	21	.000
	Model	2259.427	21	.000

Çizelge 4.4.'teki Omnibus testinde ($p < 0.05$) olduğundan başlangıç model ile amaçlanan model arasında anlamlı bir fark olduğu görülmektedir. Yani bağımsız değişkenler bağımlı değişken üzerinde anlamlı bir fark oluşturmaktadır.

Çizelge 4.5. Model özeti

Adım1	-2 Log likelihood	Cox ile Snell R Square	Nagelkerke R Square
	7249.166 ^a	.280	.281

Çizelge 4.5.'teki model özeti, yordayıcı değişkenler analize girdiğinde yordanan değişkendeki varyansın ne kadarını açıkladığını Nagellerke Square ve Cox ile Snell Square ile açıklanmaktadır. Araştırmadaki model matematik çalışmadaki değişkenliğin %37.4' ini açıklamaktadır.

Çizelge 4.6. Lojistik Regresyon Sonucu Elde Edilen Sınıflandırma Tablosu

	Gözlemlenen durum	Tahmin Edilen PVMATH		Doğru sınıflandırma yüzdesi
		0	1	
Adım 1	PVMATH 0	2478	952	72.2
	1	928	250	72.9
	Doğru sınıflandırma yüzdesi			72.6

Çizelge 4.6.'daki Lojistik Regresyon Sonucunda başarısız sınıflandırılma yüzdesi %72.2 iken başarılı grubun doğru sınıflandırma yüzdesi ise %72.9 olarak bulunmuştur. Türkiye verilerinin tümü sınıflandırıldığında doğru sınıflandırma yüzdesinin %72.6 olduğu olarak bulunmuştur. Çizelgedeki sonuçlara göre elde edilen denklemin doğru sınıflandırma oranı %72.6 olup KNN sınıflandırma performansına yakındır.

Modele alınan değişkenlerin kestirilen katsayıları, standart hataları ve odds oranları Çizelge 4.7.'de verilmiştir. Lojistik regresyon sonucunda Çizelge 4.7.'de öne çıkan 5 değişken (EMOSUPS, DURECEC, HOMEPOS, TEACHSUP ve RESILIENCE) haricinde model anlamlı çıkmış olup matematik okuryazarlığı üzerinde anlamlı etkiye sahiptir. Sınıflama için kullanılacak denklem aşağıdaki şekilde elde edilmiştir.

$$\hat{y} = 2.163 - 0.651 \text{ ST004D01T} - 0.152 \text{ HISCED} - 2.2448 \text{ REPEAT} + 0.598 \text{ ESCS} + 0.590 \text{ METASPAM} - 0.247 \text{ DIRINS} - 0.382 \text{ PISADIFF} + 0.069 \text{ PERCOMP} - 0.031 \text{ RESILIENCE} - 0.196 \text{ ATTIMM} - 0.097 \text{ COGFLEX} + 0.242 \text{ AWACOM} - 0.195 \text{ DISCRIM} - 0.235 \text{ HOMESCH} + 0.120 \text{ COMPICT} + 0.140 \text{ ICTCLAS} \quad (4.1)$$

Çizelge 4.7. Lojistik regresyon analizi sonuçları

Değişkenler	B	S.E.	Wald	df	Sig.	Exp(B)
ST004D01T	-.651	.063	107.371	1	.000	.522
HISCED	-.152	.033	20.521	1	.000	.859
DURECEC	-.074	.040	3.315	1	.069	.929
REPEAT	-2.448	.182	181.357	1	.000	.086
ESCS	.598	.075	63.216	1	.000	1.819
METASPAM	.590	.033	328.010	1	.000	1.804
HOMEPOS	.058	.052	1.260	1	.262	1.060
TEACHSUP	.013	.038	.109	1	.741	1.013
DIRINS	-.247	.036	46.924	1	.000	.782
EMOSUPS	.023	.031	.565	1	.452	1.023
PISADIFF	-.382	.033	130.993	1	.000	.683
PERCOMP	.069	.029	5.760	1	.016	1.071
RESILIENCE	-.031	.031	1.026	1	.311	.969
GCSELFEFF	.251	.030	68.723	1	.000	1.285
ATTIMM	-.196	.034	33.539	1	.000	.822
COGFLEX	-.097	.033	8.471	1	.004	.907
AWACOM	.242	.032	56.195	1	.000	1.274
DISCRIM	-.195	.030	41.576	1	.000	..23
HOMESCH	-.235	.033	51.013	1	.000	.791
COMPICT	.120	.031	14.768	1	.000	1.127
ICTCLASS	.140	.030	22.272	1	.000	1.150
Constant	2.163	.187	134.365	1	.000	8.700

Çizelgede ($\text{Exp}(\beta)$) değerleri verilmiş, bu değerler üstel lojistik regresyon katsayılarıdır. PERCOMP (Okulda rekabet edebilirlik algısı) değişkenini ele alındığında ($p < 0,05$) olduğundan anlamlı çıkmıştır. Aynı şekilde ekonomik, sosyal ve kültürel durum, cinsiyet, ebeveynlerin en yüksek eğitimi, öğrencinin okul öncesi eğitim, sınıf tekrarlama, güvenilirliği değerlendirme, kültürlerarası iletişim farkındalığı, derslerinde öğretmen desteği, öğretmen yönlendirmeli öğretim, öğrencilerin göçmenlere yönelik tutumları, ebeveynlerin duygusal desteği, algılanan BİT yeterliliği, öz yeterlik, derslerde ders ile ilgili BİT kullanımı, küresel sorunlarla ilgili öz-yeterlik, PISA testinin zorluk algısı, sınıflarda disiplin iklimi, bilişsel esneklik/uyarlanabilirlik bağımsız değişkenlerin anlamlı etkisi olduğu görülmektedir. EMOSUPS (öğrenci tarafından algılanan aile desteği), DURECEC (öğrencinin okul öncesi eğitimi), HOMEPOS (ev eşyaları), TEACHSUP (Derslerinde Öğretmen desteği) ve RESILIENCE (Öz yeterlik) ($p > .05$) olduğundan anlamlı çıkan değişkenler arasında yer almamaktadır. Ters kodlamadan dolayı negatif

ıkan ebeveynlerin ve annenin eđitiminde, ebeveynlerin eđitim dzeyi ykseldike matematik bařarısına etkisi olduđu řeklinde yorumlanmaktadır. Bir bařka ifadeyle ekonomik, sosyal ve kltrel durum arttıka matematik okuryazarlıđı puanı da artar. Diđer deđiřkenler sabit kalmak kořuluyla ESCS bir birimlik artıř, matematik performansında bařarı olasılıđını 1.819 kat artıracaktır. Aynı řekilde diđer deđiřkenlerin etkisi kontrol altında tutulduđuunda REPEAT (sınıf tekrarlama) deđiřkenindeki bir birimlik artıř, matematik okuryazarlıđında, -2.457 puan dřře sebep olur. Diđer deđiřkenlerin etkisi kontrol altında tutulduđuunda đrencinin cinsiyet deđiřkeni kızlar aleyhine 651 puan farkı vardır. đrencilerin cinsiyetleri 0 Kadın, 1 Erkek olarak kodlanmıřtır. Bu durumda erkeklerin matematik bařarılarında kadın đrencilere gre -.651'lik daha dřk performans gsterdiđi ifadesi kullanılabilir. Aynı řekilde diđer deđiřkenler sabit kalmak řartıyla METASPAM (gvenirliđi deđerlendirmek) deđiřkeni matematik performansında bařarı olasılıđını .590 kat artıracaktır. .023, PERCOMP (okulda rekabet edebilirlik algısı) ,069, AWACOM (kltrlerarası iletiřim farkındalıđı) .242, COMPICT (algılanan BİT yeterliliđi) .120, ICTCLASS (derslerde ders ile ilgili BİT kullanımı) .140 puan matematik okuryazarlıđında artıř olacaktır. izelge 4.7.'deki Wald deđerleri, regresyon katsayısının standart hataya blmnden sonra elde edilen deđerin karesinin alınması ile hesaplanmıřtır.

5. TARTIŞMA ve SONUÇ

Matematik okuryazarlığı bireylerin hem günlük hem de iş hayatlarında gereksinim duydukları, değişim gösteren bir toplumla başa çıkmanın anahtarlarından biri olarak görülmektedir (Ojose, 2011). Matematik okuryazarlığı öğrencilerin yaşadıkları dünyayı daha iyi anlamalarını sağlayacak olan eleştirel düşünme ve problem çözümleri üretebilme becerilerini geliştirme olanağı sağlar çünkü matematik okuryazarlığında çeşitli düşünme ve muhakeme becerilerine gereksinim duyulur (Rojas ve Benakli, 2020). Dijital çağda matematik okuryazarlığını anlamaya çalışırken, hem bu okuryazarlığın daha olgun bir kavrayışını hem de okulda nasıl olduğunu ve başarılabilirliğini daha iyi kavramamız gerekmektedir (Kilpatrick, 2001).

Bu kapsamda öğrencilerin matematik puanlarını olumlu ya da olumsuz etkileyen etmenlerin belirlenmesi önemlidir. Kaynakça bölümünde yer verilen çalışmalarda bazı araştırmacılar kuramsal bilgilerden yola çıkarak öğrencilerin matematik puanlarına etki edeceğini düşündükleri değişkenleri kendileri belirlemiştir. Son yıllarda gelişen yapay zekâ optimizasyon çalışmalarında özellik seçimi algoritmaları sayesinde araştırmacılar çalışmalarında kullanacakları değişkenleri kendileri belirlememektedir. Özellik Seçimi algoritmaları, eğitim veri kümesinden alakasız verileri kaldırır. Bu sayede EDM tekniklerinde kullanılan sınıflandırıcıların performanslarının artmasına olanak sağlar (Zaffar ve ark, 2017).

Bu çalışmada PISA 2018 yılı Türkiye örneklem verilerinden öğrencilerin matematik puanlarının sınıflandırma temeline dayandırılarak öğrencilerin başarılarında etkisi olan değişkenlerin belirlenmesi amaçlanmıştır. Bu kapsamda öğrencilerin başarı puanlarını etkileyebilecek olan 115 indisten oluşan veri setleri içinden eksik veriler içeren indisler silindikten sonra 69 değişkene (indeks ve değişken) kadar indirgenmiştir. Daha sonra özellik seçim algoritması olarak meta-sezgisel algoritmalarından olan Gri kurt algoritması kullanılarak öğrencilerin sınıflandırma performanslarında öne çıkan 21 indekse ulaşılmıştır.

Öğrencilerin ailelerinin sosyo ekonomik düzeylerinde belirleyici olan ailenin sosyo-ekonomik ve kültürel düzeyi (ESCS), ebeveynlerin en iyi eğitim düzeylerini (HISCED) temsil eden indislerin ön plana çıktığı görülmektedir. Bizim çalışmamızda ESCS olumlu olarak ön plana çıkmıştır. Cheema ve Galluzzo) (2013) PISA 2003 ABD örnekleminde Matematik Başarısındaki Cinsiyet Farkını Analiz ettikleri çalışmalarında

ESCS kullanmışlardır. Çalışmada matematik başarısında ailenin sosyo-ekonomik ve kültürel düzeyi ön plana çıkmış olup çalışmamızdaki sonuç ile örtüşmektedir. Bernardo (2021) çalışmasında öğrencilerin PISA 2018 Filipinli örnekleminde Sosyoekonomik durumun matematik ve bilimde öğrenme ilişkisini inceledikleri çalışmalarında sosyoekonomik değişkenleri (WEALTH, HOMEPOS ve ESCS) kullanmışlardır. Ebeveynlerin en yüksek eğitim düzeyi indeksi (HISCED), anne ve babanın eğitim düzeyinin öğrenci başarısı üzerinde etkisi anlamlı olarak bulunmuştur. Değişkenin matematik başarısı üzerinde etkisi olduğunu benzer çalışmalarda desteklemektedir (Alomar, 2006).

Cheema (2018) 2012 Yunanistan örnekleminde Matematik öz yeterliliğinin matematik okuryazarlığı üzerindeki etkisi çalışmasında öğrenci düzeyinde (yaş, sınıf, cinsiyet, ebeveyn eğitimi, ebeveyn mesleği, aile zenginliği, kültürel varlıklar ve evde eğitim kaynaklarının mevcudiyeti) okul düzeyinde (okul türü, okul büyüklüğü, öğrenci-öğretmen oranı ve okul düzeyindeki sosyoekonomik durum) değişkenlerini kullanmışlardır. Bizim bulgularımızda bir öğrencinin sosyo-ekonomik düzeyi öğrencilerin başarıları üzerinde etkilidir. Bindak (2018) çalışmasındaki görüşleri çalışmamızdaki sonuçlar ile örtüşmektedir.

Ön plana çıkan okulda rekabet edebilirlik (PERCOMP) öğrencilerin akranlarıyla rekabet etme hıssının bir göstergesidir. Benzer şekilde sınıfta kalma (REPEAT) değişkeni derslere katılımcı olmanın da matematik başarı performansında önemli olduğu görülmüştür. “Bireyin kendi öğrenme süreci hakkında bilgi sahibi olması ve bu süreci doğru şekilde yönlendirebilmesi” üstbiliş olarak tanımlanmaktadır. Bireyin bilişüstü stratejilerini etkili bir şekilde kullanması, öğrenme süreci üzerinde oldukça önemli bir etkisinin olduğu kabul edilmektedir (Arslan, 2020). PISA 2018’de üstbiliş üç başlık altında toplanmıştır. Bizim çalışmamızda da bu üç indeksten güvenilirliği değerlendirmek (METASPAM) ön plana çıkan indislerdendir. Okuma sürecinde birey pek çok zihinsel aktiviteyi gerçekleştirir ve bu aktivitelerin doğru kullanılması onun okuduğunu anlamasına yardımcı olur. Bu sayede okuduğu bilgiyi zamanında ve yeri geldiğinde etkin bir şekilde kullanabilmesine olanak sağlar (Arslan ve Koç, 2015).

Hızla gelişen bilişim ve teknoloji dünyasında BİT önemli bir yere sahiptir. Dijital cihazları ve uygulamaları anlamak ve çalıştırmak için minimum düzeyde BİT okuryazarı olmak gerekmektedir. Çünkü özellikle çocuk ve gençlerin ileride hedeflerine ulaşma ve

topluma katılma becerilerinin anahtarları arasında görülmektedir. Katz ve ark., (2004) BİT okuryazarı öğrencilerin içeriklere daha hızlı hâkim olduklarını, daha iyi problem çözdüklerini ve öğrenme süreçlerinde daha fazla kontrol sahibi olduklarını ifade etmişlerdir. Bu çalışmada BİT kullanımı başlığı altında öne çıkan indisler ise sırasıyla (ICTCLASS) indeksi dokuz maddelik bir ölçekten türetilmiştir. öğrencilerin derslerde kullanılan BİT (dijital cihaz) sıklığı, harcadıkları zaman, (COGFLEX) bilişsel esneklik/uyarlanabilirlik ve (COMPICT) algılanan BİT yeterliliği indisleridir. Okulda kullanılan BİT sıklığı, öğrencilerin matematik başarılarında pozitif bir etkisi olurken bilişsel esneklik matematik başarılarında negatif ve algılanan BİT yeterliliği indisi ise matematik başarılarında pozitif etkisi olduğu tespit edilmiştir. BİT kullanım amacı ve sürelerinin doğru şekilde ayarlanması öğrencilerin başarı performanslarında etkili olacağı düşünülmektedir. Okumayla ilgili davranışlar başlığı altında PISADIFF öğrencilerin okumaya yönelik zorluk algılarını ifade eden indeks olarak ön plana çıkmıştır. Bizim çalışmamızda da öğrencilerin okumaya karşı zorluk hissetmelerinin matematik başarı üzerinde negatif bir etkisi olduğu görülmüştür. Fırat ve Koyuncu (2020) çalışmalarında ise öğrencilerin fen ve matematikte başarılı olabilmesi için önce metin ve sembolleri iyi okuyabilmeleri ve anlamaları gerektiği sonucuna ulaşmışlardır.

DISCRIM, çok kültürlü okul iklimini temsil eden indistir. Öğrencilere, öğretmenlerinin tüm kültürel gruplardan öğrencilere eşit saygı gösterip göstermediğini ifade eder. Böylece klişelerin, önyargıların ve ayrımcılığın yokluğunu ölçer. Bizim çalışmamızda negatif bir etkinin olduğu görülmektedir. Yani olumsuzluğun artmasının öğrencilerin matematik başarı puanları üzerinde olumsuz etkileri olduğunu göstermektedir.

Bilişsel, motivasyonel ve duyuşsal değişkenler ile matematik başarısı arasındaki ilişki, öğrencilerin cinsiyetinden önemli ölçüde etkilenmektedir. Cinsiyet (ST004D01T) değişkeni çalışmamızda istatistiksel olarak anlamlı çıkmış olup Literatürdeki birçok çalışmayı da (Holenstein, 2021; Abin ve ark. 2018; Cheema, 2018; Cheema ve ark. 2013; Kitsantas, 2010) desteklemektedir. Bizim çalışmamızda matematik başarısındaki cinsiyet anlamlı çıkmıştır. García ve ark. (2007), Williams ve ark. (2016) çalışmalarında matematik başarısındaki cinsiyet farkının erkeklerin lehine olduğunu belirtmiştir. Türkiye’de kız veya erkek olmanın okuma başarısı üzerinde etkili olduğuna yönelik ünitelere göre farklılaşan sonuçlar Türkiye evreninde 2000’den bu yana yapılan PISA

araştırmalarında cinsiyet eksenini etrafında hareket edilmesi doğurmaktadır.

Öğrencilerin kültürler arası tutumları iki soru olarak ele alınmıştır. Bizim çalışmamızda öne çıkan indis (ATTIMM) öğrencilerin göçmenlere yönelik tutumlarıdır. Çalışmamızda öne çıkan sonuç literatürdeki birçok çalışmanın (Hu ve Hu, 2021; Lee ve Lee, 2021) görüşlerini desteklemektedir.

Dünya ve diğer kültürler hakkında öne çıkan indis (GCSELFEEFF) küresel konulara ilişkin öz-yeterliliklerdir. Bir öğrencinin birkaç karmaşık konuyu açıklamaya veya yorumlayıp tartışmaya ilişkin öz yeterliliğini ele alır. Bizim çalışmamızda öne çıkan bu indis matematik başarısını artacağı yönündedir. Lee ve Lee (2021) çalışmalarında Doğu Asyalı öğrencilerin ortalama matematik puanlarının eğitim, öğretim veya istihdamda olmayan gençlerin oranı ve Ar-Ge araştırmacılarının sayısı gibi ülke düzeyindeki faktörlerin de yüksek tahmin gücüne sahip olduğu bulunmuştur. Çalışmalarında küresel konulara ilişkin öz-yeterlilik değişkeni anlamlı bulunmuş olup matematik başarısındaki sonuçlar çalışmamızdaki görüşler ile örtüşmektedir.

Öne çıkan diğer bir değişkenimiz (AWACOM) (kültürler arası iletişimsel farkındalık)'dır. İstatistiksel olarak anlamlı yordayıcıların bazılarında meydana gelen artışların matematik başarısını artıracığı yönündedir. Hu ve Hu (2021) çalışmasında matematik başarısında en güçlü iki öğrenci faktörü, ekolojik sistem modelinde mikro sisteme atanan kültürlerarası iletişimin farkındalık ve küresel konulara ilişkin öz-yeterlilik olmuştur. Literatürde birçok araştırma kültürlerarası iletişimin önemini belirtmiştir.

(PERCOMP) rekabet edebilirlik inidisi öğrencilerin rekabet edebilirlik başarı güdüsü hakkında bilgi toplayan üç maddeden oluşmaktadır. Çalışmamızda öne çıkan bu indis matematik başarı puanlarının yükselmesine katkıda bulunabileceği söylenebilir. Özcan ve Bulus (2022) çalışmasında kolektivist ve bireyci ülkeler arasındaki farkın istatistiksel olarak anlamlı olduğunu ifade etmişlerdir.

GWO algoritmasında doğru sınıflandırma yüzdesi %76.5 olarak bulunurken klasik lojistik regresyon sonucunda doğru sınıflandırma yüzdesi %72.6 olarak yakın tahminde bulunmuştur.

Çalışmada PISA 2018 verileri kullanılarak, öne çıkan bazı değişkenlerin matematik okuryazarlığındaki başarısı incelenmiştir. İleride yapılacak çalışmalarda fen okuryazarlığı ve okuma başarısını etkileyen etmenlerin belirlenmesi konusundan Gri Kurt algoritmasından yararlanılabilir. Ayrıca farklı meta sezgisel algoritmalarda kullanılarak

alıřma sonuları ile karřılařtırılabilir.





KAYNAKLAR

- Abin, A. ve ark., 2018. Predicting Mathematics Achievement in Secondary Education: The Role of Cognitive, **Motivational, and Emotional Variable**,1(876).
- Abualigah, L., Elaziz, M. A., Sumari, P., Geem, Z. W., Gandomi, A. H., 2022. Reptile Search Algorithm (RSA): A nature-inspired meta-heuristic optimizer, **Expert Systems with Applications**, 191:0957-4174.
- Abualigah, L., Diabat, A., Mirjalili, S., 2021. The Arithmetic Optimization Algorithm. **Computer Methods in Applied Mechanics and Engineering** 376 (2): 113609.
- Agrawal, P.; Abutarboush, H.F.; Ganesh, T.; Mohamed, A.W., 2021. Metaheuristic Algorithms on Feature Selection: **A Survey of One Decade of Research (2009–2019)**. IEEE Access, 9: 26766–26791
- Akgun, A., 2012. A Comparison of Landslide Susceptibility Maps Produced By Logistic Regression, Multi-Criteria Decision, And Likelihood Ratio Methods: **A Case Study At İzmir, Turkey. Landslides** 9: 93–106.
- Aksu, G., Güzeller, C. O., 2016. Classification of PISA 2012 Mathematical Literacy Scores Using Decision-Tree Method: Turkey Sampling. **Education and Scien**, 41 (185): 101-122.
- Alfeilat, H.A., Hassanat, A., Lasasmeh, Ö., Tarawneh, A.S., Alhasanat, M.B., Salman, H.E., Prasath, S., 2019. Effects of Distance Measure Choice on K-Nearest Neighbor Classifier Performance: **A Review, Mary Ann Liebert, Inc** 7(4):221-248.
- Alomar, B.O., 2006. Personel and Family Paths to Pupil Achievement. **Social Behavior and Personality**, 34 (8): 907–922.
- Al-Tashi, Q., Rais, H. M., Abdulkadir S. J. and Mirjalili, S., 2020. "Feature Selection Based on Grey Wolf Optimizer for Oil & Gas Reservoir Classification," 2020 **International Conference on Computational Intelligence (ICCI)**,211-216, doi:10.1109/ICCI51257.2020.9247827
- Al-wajih, R., Abdulakaddir, S.J., NBA Aziz ve Q. Al-tashi, 2020. "Binary Gray WolfOptimizer with K-Nearest Neighbor for Feature Selection," **International Conference on Computational Intelligence (ICCI)**, 2020, s. 130- 136, doi: 10.1109/ICCI51257.2020.924792
- Asghar Heidari, S. M. (2019). Harris hawks optimization: Algorithm and applications. **Future Generation Computer Systems**, 849–872.
- Arslan, A., 2020. Ortaokul Öğrencilerinin Matematiksel Bilişüstü Farkındalıklarının Çeşitli Değişkenler Açısından Belirlenmesi. **Turkish Journal of Educational Studies**, 7(2):150–169. <https://dergipark.org.tr/tr/download/article-file/1108983>
- Arslan, A., ve Koç, C., 2015. Ortaokul Öğrencilerinin Başarı Yönelimlerinin ve Okuma Stratejileri Bilişüstü Farkındalıklarının İncelenmesi. **Pegem Eğitim ve Öğretim Dergisi**, 5(5): 485–508.
- Arora, S. ve Singh, S. (2019). Butterfly optimization algorithm: a novel approach for global optimization. **Soft Computing**, 23(3):715-734.
- Bezek Güre, Ö., Kayri, M., Erdoğan, F., 2020. Analysis of Factors Effecting PISA 2015 Mathematics **Literacy via Educational Data Mining. Education and Science**, 45(202):393-415.

- Bernardo, A. B. I., 2021. Socioeconomic status moderates the relationship Between growth mindset and learning in mathematics and science: Evidence from PISA 2018 Philippine data. *International Journal of School & Educational Psychology*, 9(2):208–222. <https://doi.org/10.1080/21683603.2020.1832635>
- Bindak, R., 2018. Modeling Students' Achievement in PISA Research with Logistic Regression Analysis. *Ekoist: Journal Ekonometrics and Statistics*, 28(14), 57-74. <https://doi.org/10.26650/ekoist.2018.14.28.0010>
- Blair RB, L. A., 1997. Butterfly Diversity And Human Land Use: *Species Assemblages Along An Urban Gradient. Biol Conserv*, 113–125.
- Blum, C. ve Roli, A., 2003. Metaheuristics in combinatorial optimization: Overview and conceptual comparison, *ACM Computing Surveys-CSUR*, 35 (3):268-308.
- Boateng, E. Y. ve Abaye, D., 2019. A Review of the Logistic Regression Model with Emphasis on Medical Research, *Journal of Data Analysis and Information Processing* 07(04):190-207.
- Breen, S., Clearly, J. ve O'shea, A., 2010. Mathematical literacy and self-efficacy of first year third level students. *MSOR Connections*, 10(2).
- Chandrinou, S., Lagaros. N., (2018). Construction of Currency Portfolios by means of an Optimized Investment Strategy. *Operations Research Perspectives*, 32–44.
- Cheema, J. R., 2018. Effect of math-specific self-efficacy on math literacy: Evidence from a Greek survey. *Research in Education*, 102(1):13–36. <https://doi.org/10.1177/0034523717741914>
- Cheema, J. R., ve Galluzzo, G., 2013. Analyzing the Gender Gap in Math Achievement: Evidence from a Large-Scale US Sample. *Research in Education*, 90(1):98–112.
- Chiu, M., Xihua, Z., 2008. Family and Motivation Effects on Mathematics Achievement: Analyses of Students in 41 Countries. *Learning and Instruction*, 18:321-336.
- Civicioglu, P., 2013. "Backtracking search optimization algorithm for numerical optimization problems," *Applied Mathematics and Computation*, 219(15). 8121–8144.
- Çelik, Y., Yıldız, İ., Karadeniz, A.T., 2019. A Brief Review of Metaheuristic Algorithms Improved in the Last Three Years. *Avrupa Bilim ve Teknoloji Dergisi*, (Özel Sayı), 463-477.
- De Cock, M., Dowsley, R., Nascimento, A.C.A., 2021. High performance logistic regression for privacy-preserving genome analysis. *BMC Med Genomics* 14, 23.
- Demir, İ., Kılıç, S., (2010). Using PISA 2003, Examining the Factors Affecting Students' Mathematics Achievement. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 38 (38):44-54.
- Eita M. A., Fahmy M. M., 2014. Group counseling optimization. *Appl Soft Comput*, (22):585–604.
- Emary, E., Zawbaa, H. ve Hassanien, A., 2016. Binary Grey Wolf Optimization *Approaches For Feature Selection. Neurocomputing*, 172: 371-381.
- Faris H., Aljarah I., Al-Betar M.A., Mirjalili S., 2018. Grey Wolf optimizer: a review of recent variants and applications. *Neural Comput Appl*, 30(2): 413–435.
- Foroughi Nematollahi, A., Rahiminejad, A. Vahid, B., 2017. A novel physical based meta-heuristic optimization method known as Lightning Attachment Procedure Optimization, *Applied Soft Computing*, (59): 596-621.
- Firat, T. ve Koyuncu, İ., 2020. Investigating Reading Literacy in PISA 2018 Assessment. *International Electronic Journal of Elementary Education*, 13(2):263–275. <https://doi.org/10.26822/iejee.2021.189>

- Friden, C., ve ark., 1990. Tabaris: An exact algorithm based on tabu search for finding a maximum independent set in a graph. *Computers & Operations Research*, **17**(5):37-445.
- Ghorbani N., Babaei E., 2014. Exchange Market Algorithm. *Appl Soft Comput*, **19**(1): 77–87.
- Glover F., 1986. Future paths for integer programming and links to artificial intelligence, *Computers and Operations Research*, **13**: 533-549.
- Glover, F., 1990. Tabu search-part II. *ORSA Journal on computing*, **2**(1): 4–32.
- Glover F. and Kochenberger G. A., 2003. Handbook of Metaheuristics, Springer.
- Glover F., Sörensen, K., 2015. Metaheuristics. *Scholarpedia*, **10**(4): 6532.
- García, M. I. B., Tello, F. P. H., Abad, E. V., and Moscoso, S. C., 2007. Actitudes, hábitos de estudio y rendimiento en Matemáticas: diferencias por género. *Psicothema* **19**:413–421.
- Hashim F.A., Hussain K., Houssein E.H., Mabrouk M.S., Al-Atabany W., 2022. Archimedes Optimization Algorithm: A New Metaheuristic Algorithm For Solving Optimization problems *Appl. Intell.* 1-21.
- Hayyolalam, V. ve Kazem, A.A.P., 2020. Black Widow Optimization Algorithm: A Novel Meta-Heuristic Approach For Solving Engineering Optimization Problems, *Engineering Applications of Artificial Intelligence*, **87**: 103249.
- Hertz, A., Widmer, M., 2003. Guidelines for the use of meta-heuristic sin com binatorial optimization, *European Journal of Operational Research*, **151**(2): 247- 252.
- Holenstein, M., Bruckmaier, G. & Grob, A., 2020. Transfer effects of mathematical literacy: an integrative longitudinal study. *Eur J Psychol Educ* **36**:799–825.
- Holland, J.H., 1975. Adaptation in Natural and Artificial Systems, *University of Michigan Press*,
- Hrstka, O., Kucerova, A., 2004. “Improvement of Real Coded Genetic Algorithms Based on Differential Operators Preventing Premature Convergence”, *Advances in Engineering Software*, **35**: 237-246.
- Hu, X. ve Hu, J. A. , 2021. Classification Analysis of the High and Low Levels of Global Competence of Secondary Students: Insights from 25 Countries/Regions. Sustainability, **13**, 11053. <https://doi.org/10.3390/su131911053>
- Jalota, C.ve Agrawal, R., 2019. Analysis of Educational Data Mining using Classification. Machine Learning, Big Data, *Cloud and Parallel Computing*, 243–247.
<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8862214&tag=1>
- Kallioras, N. L., 2018) A New Metaheuristic Inspired By Bark Beetles For Solving Engineering Problems. *Advances in Engineering Software*.
- Kashan, A. H., 2014). League Championship Algorithm (LCA): An algorithm for global optimization inspired by sport championships, *Applied Soft Computing*.**16**:171-200.
- Kashan, A.H., Tavakkoli-Moghaddam R., Gen, M., 2019. Find-Fix-Finish-Exploit-Analyze (F3EA) meta-heuristic algorithm: An effective algorithm with new evolutionary operators for global optimization, *Computers & Industrial Engineering*, (128): 192-218.
- Katz, I. R., Williamson, D. M., Nadelman, H. L., Kirsch, I., Almond, R. G., Cooper, P.L., Redman, M. L., ve Zapata, D. (2004). Assessing Information and Communications Technology Literacy for Higher Education. Annual Meeting of the International *Association for Educational Assessment*

- Kaveh, A. ve Bakhshpoori, T., 2016 Water Evaporation Optimization: A novel physically inspired optimization algorithm, *Computers and Structures* 167:69–85.
- Kaveh A. ve Dadras A., 2017. A novel meta-heuristic optimization algorithm: Thermal exchange optimization, *Advances in Engineering Software*, (110): 69-84.
- Kennedy, J., Eberhart, R. C., 1995. Particle swarm optimization, *Proc. IEEE International Conference on Neural Network*, Perth, WA, Australia.1942-1948.
- Kitsantas, A, Ware, H, Cheema, J., 2010. Predicting mathematics achievement from mathematics efficacy: Does analytical method make a difference? *The International Journal of Educational and Psychological Assessment* 5(1): 25–44.
- Kilpatrick, J., 2001. Understanding mathematical literacy: *The contribution of research. Educational Studies in Mathematics*, 47(1): 101-116.
- Laporte, G., Gendreau, M., Potvin, J. Y., Semet, F., 2000. Classical and modern heuristics for the vehicle routing problem, *International Transactions in Operation Research*, (7): 285-300.
- Lakshmi, T. M., Martin, A. ve Venkatesan, V. P., 2013. An analysis of students performance using genetic algorithm. *Journal of Computer Sciences and Applications* 1(4):75-79.
- Layeb, A., 2022. Tangent Search Algorithm For Solving Optimization Problems. *Neural Comput & Applic*, 1433-3058.
- Lee, S., 2005. Application of logistic regression model and its validation for landslide susceptibility mapping using GIS and remote sensing data journals. *Int J Remote Sens* 26:1477–1491.
- Lee, H. ve Lee, J.W. , 2021. Why East Asian students perform better in mathematics than their peers: An investigation using a machine learning approach. CAMA Working PaperNo.66/2021,Availableat.
SSRN: <https://ssrn.com/abstract=3896033> or <http://dx.doi.org/10.2139/ssrn.3896033>
- Liu, O. L. ve Wilson, M., 2009. Gender differences and similarities in PISA 2003 mathematics: A comparison between the United States and Hong Kong. *International Journal of Testing*, 9 (1): 20-40.
- Mayer, D.G., Kinghorn, B.P., Archer, A.A., 2005. “Differential Evolution – An Easy and Efficient Evolutionary Algorithm for Model Optimisation”, *Agricultural Systems*, 83:315-328.
- Mirjalili S.M. and Lewis A., 2014. "Grey Wolf Optimizer". *Advances in Engineering Software*. 69: 46- 61.
- Mirjalili, S., 2016. Dragonfly algorithm: a new meta-heuristic optimization Technique for solving single-objective, discrete, and multi-objective problems. *Neural computing and applications*, 27(4): 1053-1073.
- Mirjalili, S., 2016. SCA: a sine cosine algorithm for solving optimization problems. *Knowledge-Based Systems*, 96:120-133.
- Mirjalili, S., Mirjalili, S.M. ve Hatamlou, A., 2016. Multi-Verse Optimizer: a nature-inspired algorithm for global optimization. *Neural Comput & Applic* 27, 495–513.
- Mutluer, C., ve Büyükkıdık, S., 2017. Estimation On The Mathematics Literacy With Logistic Regression According To PISA 2012 Data. *Journal of Educational Sciences*, 46(46): 97–112. <https://doi.org/10.15285/maruaebd.273926>

- MiarNaeimi, F., Azizyan, G., & Rashki, M., 2021. Horse herd optimization algorithm: A nature-inspired algorithm for high-dimensional optimization problems. **Knowledge-Based Systems**, 213(2): 106711.
- Moghdani, R. ve Salimifard, K., 2018. Volleyball Premier League Algorithm, **Applied Soft Computing**, (64): 161-185.
- Mohamed, A.W., Hadi, A.A. & Mohamed, A.K., 2020. Gaining-sharing knowledge based algorithm for solving optimization problems: a novel nature-inspired algorithm. **Int. J. Mach. Learn. & Cyber.** 11:1501–1529.
- Momanyi E. ve Seger, D., 2021. A Master-Slave Binary Grey Wolf Optimizer for Optimal Feature Selection in Biomedical Data Classification, **BioMed Research International**.
- Nutanong, S., Zhang, R., Tanin, E. ve ark., 2010. Analysis and evaluation of V*-kNN: an efficient algorithm for moving kNN queries. **The VLDB Journal** 19:307–332.
- OECD, 2013. PISA 2012 assessment and analytical framework: mathematics, reading, science, problem solving and financial literacy. Paris: Author
- OECD, 2019. PISA 2018 Results (Volume I): what students know and can do. <https://doi.org/10.1787/5f07c754-en>
- OECD, 2019b. PISA 2018 assessment and analytical framework. Paris: OECD Publishing. doi: <https://doi.org/10.1787/b25efab8-en>
- OECD, 2021, Mathematics performance (PISA) (indicator). doi: 10.1787/04711c74-en (Accessed on 04 May 2021).
- Ozgen, K., & Bindak, R., 2011. Determination of self-efficacy beliefs of high school students towards math literacy. **Educational Sciences: Theory & Practice**, 11(2): 1073–1089.
- Özcan, B., Bulus, M., 2022. Protective factors associated with academic resilience of adolescents in individualist and collectivist cultures: Evidence from PISA 2018 large scale assessment. **Curr Psychol** 41, 1740–1756. <https://doi.org/10.1007/s12144-022-02944-z>
- Puchinger, J. ve ark. , 2009. Metaboosting: Enhancing integer programming Techniques by metaheuristics. In V. Maniezzo, T. Stützle, and S. Voß, editors, **Matheuristics: Hybridizing Metaheuristics and Mathematical Programming, volume 10 of Annals of Information Systems**.
- Rana, N., Latiff, M.S.A., Abdulhamid, S.M. ve ark., 2020. Whale Optimization Algorithm: A Systematic Review Of Contemporary Applications, Modifications And Developments. **Neural Comput ve Applic** 32: 16245–16277. <https://doi.org/10.1007/s00521-020-04849-z>
- Rao, R., 2016. Jaya: A simple and new optimization algorithm for solving constrained and unconstrained optimization problems. **International Journal of Industrial Engineering Computations**, 7(1): 19-34.
- Reeves, C., 1995. “Modern Heuristic Techniques for Combinatorial Problems”, McGrawHill Book Company, New York
- Rojas E., Benakli N., 2020. Mathematical Literacy and Critical Thinking. In: But J. (eds) Teaching College-Level Disciplinary Literacy. **Palgrave Macmillan, Cham**.
- Sahu, S.K., Kumar, P. ve Singh, A.P., 2018. Modified K-NN algorithm for classification problems with improved accuracy. **Int. j. inf. tecnol.** 10:65–70.
- Sankalap Arora, S. S., 2019. Butterfly Optimization Algorithm: A Novel Approach For Global Optimization. **Soft Computing**, 715–734.
- Salehan, A. ve Deldari, A., 2021.

- Corona virus optimization (CVO): a novel optimization algorithm inspired from the Corona virus pandemic, *The Journal of Supercomputing*, (4):1-32.
- Salimi, H., 2015. Stochastic Fractal Search: A Powerful Metaheuristic Algorithm, *Knowledge-Based Systems*, 75:1–18.
- Sen, P.B., 2020. Logistic Regression in PySpark and sparklyr. <https://dawn15081.medium.com/logistic-regression-in-pyspark-and-sparklyr-9c3864d60b13> Erişim Tarihi: 08.04.2022.
- Schober, P., ve Vetter, T.R., 2021. Logistic Regression in Medical Research, *Anesthesia & Analgesia*, 132 (2): 65-366.
- Shiakolas, P. S., Koladiye, D., Kebrle, J., (2005). On The Optimum Synthesis of Six-Bar Linkages Using Differential Evolution and The Geometric Centroid of Precision Positions Technique, *Mechanism and Machine Theory*, 40: 319- 335.
- Sörensen K., Glover, F., 2013. Metaheuristics. In S.I. Gass and M. Fu, editors, *Encyclopedia of Operations Research and Management Science*, pages 960–970.
- Storn, R., Price, K., 1997. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *J. Global Optim.* 11(14): 341–359.
- Subashini, P., Dhivyaprabha, T.T., Krishnaveni, M., 2017. Synergistic fibroblast optimization. *Proc. Springer Artif. Intell. Evol. Comput. Eng. Syst* 517: 293-302.
- Sur, C., Sharma, S., & Shukla, A., 2013. Egyptian Vulture Optimization Algorithm—A New Nature Inspired Meta-Heuristics For Knapsack Problem. In *The 9th International Conference on Computing and Information Technology*, 227-237.
- Tabari, A., ve Ahmad, A., 2017. A new optimization method: Electro-Search Algorithm. *Computers & Chemical Engineering*, 1-23.
- Taşkın, T. ve Tugrul, B., 2013. "Investigating preschool teacher candidates' mathematics literacy self-sufficiency beliefs on various variables," *5th World Conference on Educational Sciences (WCES)*, (116): 3067-3071.
- Talbi, E.G., 2009. “Metaheuristic: from Design to Implementation”, 2nd Edition, Wiley, 2009
- Too J, Abdullah AR, Mohd Saad N, Mohd Ali N, Tee W., 2018. A New Competitive Binary Grey Wolf Optimizer to Solve the Feature Selection Problem in EMG Signals Classification. *Computers*.7(4):58.
- Williams, K. E., White, S. L. J. ve MacDonald, A., 2016. Early mathematics achievement of Boys and girls: do differences in early self-regulation pathways explain later achievement? *Learn. Individ. Differ.* 51, 199–209. doi: 10.1016/j.lindif.2016.09.006
- Wright, R. E., 1995. Logistic regression. In L. G. Grimm & P. R. Yarnold (Eds.), *Reading and Understanding More Multivariate Statistics*, 17–244.
- Xie, L., Zeng, J., Cui, Z., 2009. General framework of artificial physics optimization algorithm (1321–1326). *Proc Nature & Biologically Inspired Computing World Congress on*, December 9-11, Coimbatore.
- Yang, X. S., 2010. A new metaheuristic bat-inspired algorithm. In *Nature inspired cooperative strategies for optimization (NICSO 2010)*, Springer, Berlin, oHeidelberg. 65- 74.
- Yang, X., 2011. Metaheuristic Optimization, *Scholarpedia*, 6(8): 11472.

- Zhao, G., Wang, H. , Jia, D. ,Wang, Q. , 2019. Feature Selection of Grey Wolf Optimizer Based on Quantum Computing and Uncertain Symmetry Rough Set, *Symmetry*, **11**(12): 1470; <https://doi.org/10.3390/sym11121470>
- Zaffar, M., Hashmani, M. A. ve Savita, K. S. , 2017. Performance analysis of feature selection algorithm for educational data mining. *IEEE Conference on Big Data and Analytics (ICBDA)*. <https://doi.org/10.1109/ICBDAA.2017.8284099>





ÖZ GEÇMİŞ

Ecrin Nüda BAK ilköğretim ve ortaöğretimi Van'da tamamladı. Lise eğitime 2007-2011 yılları arasında Van Milli Piyango Anadolu Lisesi'nde tamamlamıştır. 2013 yılında Van Yüzüncü Yıl Üniversitesinde Matematik Bölümü'ne başladı ve 2017 yılında mezun olmuştur. 2019 yılında aynı üniversitede lisansüstü eğitime başladı ve devam etmektedir.



**VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
LİSANSÜSTÜ TEZ ORJİNALLİK RAPORU**

Tarih: 17/05/2022

Tez Başlığı / Konusu: PISA MATEMATİK OKURYAZARLIĞININ GRİ KURT OPTİMİZASYON ALGORİTMASI İLE PERFORMANS DEĞERLENDİRMESİ

Yukarıda başlığı/konusu belirlenen tez çalışmamın Kapak sayfası, Giriş, Ana bölümler ve Sonuç bölümlerinden oluşan toplam 94 sayfalık kısmına ilişkin, 16/05/2022 tarihinde şahsım/tez danışmanım tarafından Turnitin intihal tespit programından aşağıda belirtilen filtreleme uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %9 (yüzde Dokuz) dur.

Uygulanan filtreler aşağıda verilmiştir:

- Materyal ve yöntem hariç,
- Kaynaklar hariç,
- Tezden çıkan yayınlar hariç,
- 7 kelimeden daha az örtüşme içeren metin kısımları hariç (Limit inatch size to 7 words)

Van Yüzüncü Yıl Üniversitesi Lisansüstü Tez Orijinallik Raporu Alınması ve Kullanılmasına İlişkin Yönergeyi inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim.

Tarih ve İmza

Adı Soyadı: Ecrin Nüda BAK

Öğrenci No: 19910001185

Anabilim Dalı: Yapay Zekâ ve Robotik

Programı:

Statüsü: ☒ Yüksek Lisans

☐ Doktora

DANIŞMAN ONAYI
UYGUNDUR
Sanem ŞEHRİBANOĞLU

ENSTİTÜ ONAY
UYGUNDUR