

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**GELİŞTİRİLMİŞ GRİ KURT ALGORİTMASI TABANLI KARŞILAŞTIRMALI
KISA DÖNEM HİBRİT RÜZGAR GÜCÜ TAHMİN MODELLERİ VE
UYGULAMASI**

YÜKSEK LİSANS TEZİ

TUFAN İNAÇ

TEZ DANIŞMANI
DR. ÖĞR. ÜYESİ EMRAH DOKUR

İKİNCİ TEZ DANIŞMANI
PROF. DR. UĞUR YÜZGEÇ

BİLECİK, 2021

10417377

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**GELİŞTİRİLMİŞ GRİ KURT ALGORİTMASI TABANLI KARŞILAŞTIRMALI
KISA DÖNEM HİBRİT RÜZGAR GÜCÜ TAHMİN MODELLERİ VE
UYGULAMASI**

YÜKSEK LİSANS TEZİ

TUFAN İNAÇ

TEZ DANIŞMANI
DR. ÖĞR. ÜYESİ EMRAH DOKUR

İKİNCİ TEZ DANIŞMANI
PROF. DR. UĞUR YÜZGEÇ

BİLECİK, 2021

10417377

BEYAN

“Geliştirilmiş Gri Kurt Algoritması Tabanlı Karşılaştırmalı Kısa Dönem Hibrit Rüzgar Gücü Tahmin Modelleri ve Uygulaması” adlı yüksek lisans tezinin hazırlık ve yazımı sırasında bilimsel ahlak kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını beyan ederim.

Bu çalışmanın, Bilimsel Araştırmalar Projesi (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte beyan edilmelidir.			
DESTEK ALINMIŞTIR		☐	DESTEK ALINMAMIŞTIR
☒			
Destek alındı ise;			
Destekleyen Kurun:			
Desteğin Türü		Proje Numarası	
1- BAP (Bilimsel Araştırma Projesi)			
2- TÜBİTAK			
Diğer;			

TUFAN İNAÇ

23/08/2021

İmza

ÖN SÖZ

Tez çalışmam da yardımlarını, anlayışlarını ve emeklerini esirgemeyen tez danışmanlarım Dr. Öğr. Üyesi Emrah DOKUR ve Prof. Dr. Uğur YÜZGEÇ'e, beni bu günlere getiren üzerimdeki haklarını hiçbir zaman ödeyemeyeceğim rahmetli babam Ali İNAÇ ve annem Feriha İNAÇ'a, hayatımın her aşamasın da yanımda olan desteğini, sevgisini emeğini hiçbir zaman eksik ettirmeyen daima hissettiren eşim Sare Irmak İNAÇ'a ve yüzündeki gülümsemesiyle tüm yorgunluğumu üzerimden alan sevgili kızım İnci İNAÇ'a teşekkür ederim.

Tufan İNAÇ

23/08/2021



ÖZET

GELİŞTİRİLMİŞ GRİ KURT ALGORİTMASI TABANLI KARŞILAŞTIRMALI KISA DÖNEM HİBRİT RÜZGAR GÜCÜ TAHMİN MODELLERİ VE UYGULAMASI

Dünyanın artan nüfusu ve buna bağlı olarak her geçen gün yükselen enerji ihtiyacı, günümüzde talep edilen enerjinin temiz ve sürdürülebilir olması hedefini sunmuştur. Bu nedenle yenilenebilir enerji sistemlerine yönelim hızla artış göstermektedir. Rüzgar enerji sistemlerinin ilk kurulum maliyetleri yüksek olması nedeniyle istenilen bir bölgeye rüzgar enerjisi sistemi kurulumu yapılmadan önce bölgenin rüzgar hızı ve buna bağlı olarak rüzgar gücü karakteristiklerinin belirlenmesi, planlamaların ve etüd çalışmalarının bu doğrultu da yapılması gerekir. Bu tez çalışması, kısa dönem rüzgar gücü kestirimine yönelik özgün akıllı sezgisel tahmin modelleri ve bunların uygulamalarını içermektedir. Son yıllarda sıklıkla kullanılan akıllı sezgisel yaklaşımlar ve bunların hibrit modelleri, farklı ayrıştırma metodları veya farklı optimizasyon teknikleri ile birlikte daha hassas modellerin ortaya çıkmasını sağlamıştır. Bu tez çalışmasında kullanılan meta-sezgisel optimizasyon algoritmalarından biri olan Gri Kurt Optimizasyon (GWO) algoritması, temel olarak doğadaki gri kurtların avlanma yöntemine ve sosyal hiyerarşisine dayanmaktadır. Çalışmada, arama performansını iyileştirmek için orijinal GWO algoritmasına eklenen bazı etkili ve yeni mekanizmalar içeren Çok Stratejili Rastgele Ağırlıklı Gri Kurt Optimizasyon (MsRwGWO) algoritması sunulmuştur. Bunlar, önerilen MsRwGWO yaklaşımında, $\vec{a}$ parametresini güncellemek için bir geçiş mekanizması, ağırlıklı bir güncelleme mekanizması, bir mutasyon operatörü, bir sınır kontrol mekanizması, açgözlü bir seçim mekanizması ve lider üç kurdun (alfa, beta ve delta kurtları) bir güncelleme mekanizmasını içermektedir. MsRwGWO algoritmasının performansını değerlendirmek için CEC 2014 test takımı olarak bilinen bazı kıyaslama fonksiyonları kullanılmıştır. Öncelikle optimizasyon problemlerinin çözümü sırasında MsRwGWO algoritmasının yakınsama, arama geçmişi, yörünge ve ortalama mesafe gibi davranışları analiz edilmiştir. İkinci olarak, önerilen MsRwGWO ve GWO algoritmalarının karşılaştırmalı istatistiksel sonuçları, 10, 30 ve 50 boyutlu CEC 2014 kıyaslamaları için sunulmuştur. Ayrıca literatürde yer alan bazı popüler meta-sezgisel algoritmalar, 30D CEC 2014 test problemleri için önerilen MsRwGWO algoritması ile karşılaştırılmıştır. Son olarak, MsRwGWO algoritması, gerçek bir dünya problemi olan kısa dönemli rüzgar hızı tahmininde kullanılan bir Çok Katmanlı Algılayıcının (MLP) eğitim sürecine uyarlanmış ve GWO tabanlı MLP ile karşılaştırmalı sonuçlar elde edilmiştir. Kısa dönemli rüzgar hızı tahmini için MLP modelinin kıyaslama problemlerinin ve

eđitim performansının istatistiksel sonuçları, önerilen MsRwGWO algoritmasının GWO algoritmasından daha iyi performansa sahip olduğunu göstermektedir.

Anahtar Kelimeler: Gri Kurt Optimizasyon Algoritması, Rüzgar Gücü Tahmini, Rüzgar Enerjisi, Meta-Sezgisel Yaklaşım, Optimizasyon.



ABSTRACT

GRAY WOLF ALGORITHM BASED SHORT TERM HYBRID WIND POWER FORECASTING MODELS AND APPLICATION

The increasing population of the world and the increasing energy demand accordingly have brought us the target of being clean and sustainable for the energy demanded today. For this reason, the orientation towards renewable energy systems has increased rapidly. Since the initial installation costs of wind energy systems are high, before the installation of a wind energy system in a desired region, the wind speed of the region and the wind power characteristics of the region should be determined, planning and survey studies should be done in this direction. This thesis study includes original intelligent heuristic forecasting models for wind power estimation and their applications. Intelligent heuristic approaches and their hybrid models, which are frequently used in recent years, have led to the emergence of more sensitive models with different decomposition methods or different optimization techniques. Gray Wolf Optimization (GWO), one of the meta-heuristic optimization algorithms used in this thesis, is basically based on the hunting method and social hierarchy of gray wolves in nature. This paper presents the Multi-strategy Random-weighted Gray Wolf Optimizer (MsRwGWO) including some effective and novel mechanisms added to the original GWO algorithm to improve the search performance. These are a transition mechanism for updating the parameter $\vec{a}$, a weighted updating mechanism, a mutation operator, a boundary checking mechanism, a greedy selection mechanism, and an updating mechanism of leader three wolves (alpha, beta, and delta wolves). We utilized some benchmark functions known as CEC 2014 test suite to evaluate the performance of MsRwGWO algorithm in this study. Firstly, during the solution of optimization problems, the MsRwGWO algorithm's behaviors such as convergence, search history, trajectory, and average distance were analyzed. Secondly, the comparison statistical results of MsRwGWO and GWO algorithms were presented for CEC 2014 benchmarks with 10, 30 and 50 dimensions. In addition, some of the popular meta-heuristic algorithms taken from the literature were compared with the proposed MsRwGWO algorithm for 30D CEC 2014 test problems. Finally, MsRwGWO algorithm was adapted to the training process of a MultiLayer Perceptron (MLP) used in wind speed estimation and comparative results with GWO based MLP were obtained. The statistical results of the benchmark problems and training performance of MLP model for short-term wind speed forecasting show that the proposed MsRwGWO algorithm has better performance than GWO algorithm.

Keywords: Wind Power Forecasting, Wind Speed Forecasting, Wind Energy, Gray Wolf Optimizer, Meta-heuristic Optimization Algorithms, Random Weighted, Novel Transition Mechanism.



İÇİNDEKİLER

Sayfa No

ÖN SÖZ.....	i
ÖZET.....	ii
ABSTRACT	iv
İÇİNDEKİLER.....	vi
ŞEKİLLER LİSTESİ.....	ix
TABLolar LİSTESİ.....	x
KISALTMALAR LİSTESİ.....	xi
1. GİRİŞ.....	1
2. ENERJİ SİSTEMLERİ	6
2.1. Yenilenebilir Enerji Sistemleri.....	7
2.2. Rüzgar Enerji Sistemleri	8
3. ENERJİ SİSTEMLERİNDE RÜZGAR GÜCÜ TAHMİN	11
4.RÜZGAR GÜCÜ TAHMİNİNDE META-SEZGİSEL OPTİMİZASYON ALGORİTMALARI	16
4.1. Güve-Alev Optimizasyon (MFO) Algoritması.....	17
4.2. Parçacık Sürü Optimizasyon (PSO) Algoritması.....	18
4.3. Yusufçuk Optimizasyon Algoritması (DA)	18
4.4. Sinüs Kosinüs Algoritması (SCA)	18
4.5. Balina Optimizasyon Algoritması (WOA)	19
4.6. Gri Kurt Optimizasyon (GWO).....	19
5. GELİŞTİRİLEN GRİ KURT OPTİMİZASYON ALGORİTMASI İLE YENİ RÜZGAR GÜCÜ TAHMİN YAKLAŞIMI	25
5.1. Önerilen Çok Stratejili Rastgele Ağırlıklı Gri Kurt Optimizasyon (MsRwGWO) Algoritması.....	26
5.2. Önerilen MsRwGWO Algoritmasının Analizi ve Karşılaştırmalı Performansı ...	31
5.2.1. Önerilen MsRwGWO Algoritmasının Analizi	31
5.2.1.1. Yakınsama Analizi	33
5.2.1.2. Arama Geçmişi Analizi.....	34
5.2.1.3. Yörünge Analizi.....	36
5.2.1.4. Ortalama Mesafe Anazilizi.....	38
5.2.2. CEC 2014 Kıyaslama Fonksiyonları İçin MsRwGWO ve GWO Algoritmalarının Karşılaştırılması	39

5.2.3. MsRwGWO-MLP Hibrit Modeli Kullanılarak Kısa Vadeli Rüzgar Gücü Tahmini	49
6. SONUÇLAR.....	56
KAYNAKÇA	57



ŞEKİLLER LİSTESİ

Sayfa No

Şekil 2.1. 2000-2021 yılları arasında dünya üzerindeki enerji üretiminin kaynaklara göre dağılımı.....	6
Şekil 2.2. 2040 yılına kadar öngörülen dünya üzerindeki elektrik enerjisi üretimin de enerji kaynaklarının payı	7
Şekil 2.3. Dünya kurulu rüzgar kapasitesinin 2001-2020 yılları arasında ki kümülatif değişimi	9
Şekil 2.4. Dünya üzerin de 2020 yılı yeni kurulu güç miktarının ülkelere göre yüzdelik (%) dağılımı.....	9
Şekil 2.5. Türkiye kurulu rüzgar kapasitesinin 2006-2020 yılları arasında ki kümülatif değişimi	10
Şekil 3.1. Rüzgar türbini bileşenleri.....	12
Şekil 3.2. Rüzgar güç eğrisi	14
Şekil 4.1. Gri kurtların liderlik hiyerarşisi	20
Şekil 4.2. Gri kurtların avlanma mekanizması.....	22
Şekil 5.1. Önerilen MsRwGWO algoritmasının kısa dönemli rüzgar gücü tahmininde kullanılmasına ilişkin akış şeması	25
Şekil 5.2. Orjinal ve önerilen geçiş parametreleri	27
Şekil 5.3. Alfa, Beta ve Delta kurtlarının önerilen yeni güncelleme mekanizması	29
Şekil 5.4. Önerilen MsRwGWO algoritmasının analizi için kullanılan fonksiyonlar	33
Şekil 5.5. MsRwGWO algoritması için yakınsama analizleri	34
Şekil 5.6. MsRwGWO ve GWO algoritmalarının arama geçmişi analizleri	35
Şekil 5.7. FN2 fonksiyonu için alfa gri kurdunun konum analizi.....	36
Şekil 5.8. FN6 fonksiyonu için alfa gri kurdunun konum analizi.....	37
Şekil 5.9. FN16 fonksiyonu için alfa gri kurdunun konum analizi.....	37
Şekil 5.10. FN23 fonksiyonu için alfa gri kurdunun konum analizi.....	37
Şekil 5.11. Gri kurtlar arasındaki ortalama mesafe analizi	39
Şekil 5.12. GWO ve MsRwGWO algoritmaları için 10D en iyi kıyaslama sonuçlarının yakınsama eğrileri	41
Şekil 5.13. MsRwGWO algoritmasının 10D Yakınsama eğrileri (En İyi, En Kötü, Ortalama)	42

Şekil 5.14. MsRwGWO algoritması tarafından 50 çalışmada elde edilen en iyi parametreye sahip MLP modeli (a) eğitim ve (b) istatistiksel hatalar içeren test sonuçları	51
Şekil 5.15. MsRwGWO tabanlı MLP modelinin eğitim ve test performansları Hata! Yer işareti tanımlanmamış.	52
Şekil 5.16. GWO ve MsRwGWO algoritması tabanlı MLP modellerinin karşılaştırmalı eğitim ve test sonuçları	53
Şekil 5.17. MLP modelinin eğitiminde MsRwGWO ve GWO algoritmalarının yakınsama eğrileri	53



TABLÖLER LİSTESİ

Sayfa No

Tablo 3.1. Rüzgar tahminlerinin zaman bazın da sınıflandırılması ve uygulama alanları..	11
Tablo 5.1. CEC 2014 karşılaştırma fonksiyonları	32
Tablo 5.2. GWO ve MsRwGWO algoritmaları için 10D CEC 2014 karşılaştırma sonuçları.	43
Tablo 5.3. GWO ve MsRwGWO algoritmaları için 30D CEC 2014 karşılaştırma sonuçları.	44
Tablo 5.4. GWO ve MsRwGWO algoritmaları için 50D CEC 2014 karşılaştırma sonuçları.	45
Tablo 5.5. GWO ve MsRwGWO algoritmaları için CEC 2014 karşılaştırmalarının özet sonuçları	46
Tablo 5.6. 30D CEC2014 problemleri için MsRwGWO ve diğer algoritmaların karşılaştırma	47
Tablo 5.7. 50 tekrar ile GWO-MLP ve MsRwGWO-MLP hibrit modelinin eğitim sonuçları	54
Tablo 5.7. 50 tekrar ile GWO-MLP ve MsRwGWO-MLP hibrit modelinin eğitim sonuçları	55

KISALTMALAR LİSTESİ

MsRwGWO	: Çok Stratejili Rastgele Ağırlıklı Gri Kurt Optimizasyon Algoritması
GWO	: Gri Kurt Optimizasyon Algoritması
MLP	: Modifiye Edilmiş Maksimum Olabilirlik Metodu
MFO	: Güve-Alev Optimizasyon Algoritması
PSO	: Parçacık Sürü Optimizasyon Algoritması
DA	: Yusufçuk Optimizasyon Algoritması
SCA	: Sinüs Kosinüs Optimizasyon Algoritması
WOA	: Balina Optimizasyon Algoritması
CEC 2014	: Kıyaslama Fonksiyonları
TÜREB	: Türkiye Rüzgar Enerjisi Birliği
GWEC	: Global Rüzgar Enerji Konseyi
MAPE	: Ortalama Mutlak Yüzde Hatası
MAE	: Ortalama Mutlak Hata
MSE	: Ortalama Kare Hatası
RMSE	: Kök Ortalama Kare Hatası

1. GİRİŞ

İnsanoğlu dünya üzerinde var olduğu günden bugüne dek zamanın her aşamasında enerjiye ihtiyaç duymuştur. Sadece beslenerek kendi vücudunun enerji ihtiyacını karşılamakla kalmamış, hayatını idame etmek ve sosyal hayatını sürdürebilmek amacı ile de çeşitli enerji kaynaklarını kullanmıştır. Zaman içerisinde de bu kaynakları, geliştirdiği yeni teknolojiler yardımı ile mekanik, ısı ve elektrik gibi farklı enerji kaynaklarına dönüştürerek ihtiyaçlarını karşılamıştır (Aslan ve Yamak, 2006: 65).

Dünya üzerinde kullanılan enerjinin büyük kısmının halen kömür ve petrol gibi fosil yakıtlarla üretilmesi ve artan nüfusa bağlı olarak enerji ihtiyacının da artış göstermesi, çevre açısından değerlendirildiğinde bu süreçlerden kaynaklanan emisyon oranlarının azaltılması gerektiğini gündeme getirmiştir. Yenilenebilir enerji kaynakları ve özelin de temiz enerji kaynağı olarak nitelendirilen rüzgar enerjisi, elektrik enerjisi üretimi açısından düşünüldüğünde uzun vadede dünya üzerindeki emisyon oranlarının azaltılabilmesine imkan sağlamaktadır.

Rüzgar enerjisi ile üretilen elektriğin payının her geçen gün arttığı ülkemizde, mevcut kapasitenin karbon salınımı azaltarak çevreye verdiği olumlu etki diğer enerji kaynakları karşısın da gösterdiği en önemli üstünlüğüdür. Bunun yanında rüzgar enerjisinin en büyük dezavantajı süresiz, kararsız ve asimetrik yapıda olmasıdır. Bu kapsam da rüzgar enerjisi üretim sistemlerin de, rüzgar gücünün tahmini ve modellenmesi kavramları karşımıza çıkmaktadır. Rüzgar enerji sistemlerinin ilk kurulum maliyetleri diğer enerji kaynaklarına göre oldukça yüksek olduğu görülmektedir. Bu nedenle rüzgar enerji sistemleri kurulması planlanan bir bölgede öncelikle rüzgar gücü karakteristiğinin modellenerek belirlenmesi gerekir. Ayrıca modellenmesi yapılan rüzgar enerji sisteminin şebekeye kısa, orta ve uzun vadede aktarabileceği güç miktarı kararsız yapıda bulunan rüzgar gücünün hassas şekilde tahmin edilmesine bağlıdır. Rüzgar gücünün modellenmesi ve tahminine yönelik literatür de bir çok farklı yaklaşım bulunmaktadır.

Literatür de rüzgar gücü tahminine dönük çalışmalar geçmiş dönemde zaman serisi analizleri üzerine olmakla beraber, daha sonraki yıllar da akıllı sezgisel yaklaşımların hızla gelişimi ile birlikte bu metotların sıklıkla kullanılmasını bu alanda sağlamıştır. Verileri öğrenme yeteneklerine sahip olan, daha basit modellerle oluşturulabilen Yapay Sinir Ağları (YSA) da çoklukla kullanılan istatistiksel yaklaşımlardandır. Son olarak akıllı sezgisel

yaklaşımlar ve diğer farklı ayrıştırma yöntemlerini içinde barındıran daha hassas sonuçlar veren hibrit modeller de geliştirilmiştir.

Çevik ve arkadaşları, çalışmaların da, bir sonraki saat de oluşacak rüzgar enerjisi tahmin etmek için, üç aşamadan oluşan yeni bir tahmin modeli önermişlerdir. Önerilen yöntem de ilk aşamada, geçmiş veriler kullanılarak rüzgar hızı, rüzgar yönü ve rüzgar gücü tahmin edilmiştir. Tahmin yöntemleri olarak Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS), Yapay Sinir Ağı (YSA) ve Destek Vektör Makinesi (SVM) seçilirken, ön tahmin yöntemi olarak Ampirik Mod Ayrıştırma (EMD) ve Durağan Dalgacık Ayrıştırma (SWD) yöntemleri kullanılmıştır. Elde edilen sonuçlar literatür çalışmaları ile karşılaştırılmış, önerilen çok aşamalı tahmin modelinin rüzgar enerjisi tahminini verimli bir şekilde yapabildiğini ve gerçek verilere çok yakın değerler ürettiğini göstermiştir (Çevik vd., Çevrimiçi Ön Yayın).

Ak ve arkadaşları, rüzgar enerjisi üretimindeki ilgili belirsizlikleri hesaba katan rüzgarla entegre bir güç sisteminin yeterlilik değerlendirmesini yürütmek için bir modelleme ve simülasyon modeli sunmuşlardır. Çok Katmanlı Algılayıcı Yapay Sinir Ağı (MLP NN), rüzgar gücünün ve yükünün tahmin aralıklarını tahmin etmek için Baskın Olmayan Sıralama Genetik Algoritması-II (NSGA-II) tarafından eğitilmiştir. Rüzgar ve yük tahminlerindeki belirsizliğin sistem yeterliliğinin tahmini üzerindeki etkisini araştırmak için farklı rüzgar gücü ve yük seviyeleri senaryoları araştırmacılar tarafından sunulmuştur (Ak vd., 2018: 220).

Li ve arkadaşları, rüzgar güç sistemleri üzerindeki işletme maliyetlerini azaltabilmek için Gelişmiş Karga Arama Optimizasyon Algoritması - Aşırı Öğrenme Makinesi (ENCSA-ELM) adlı yeni bir hibrit model önermişlerdir. Çalışmada Gelişmiş Karga Optimizasyon Algoritması (ENCSA) ile Aşırı Öğrenme Makinesinin (ELM) parametreleri optimize edilmiştir. Hibrit modelin test sonuçlarına göre ENCSA Algoritmasının yerel geliştirme ve küresel keşif yeteneklerinin geliştirildiğini ayrıca önerilen ENCSA Algoritmasının sonuçlarının literatür de iyi bilinen doğadan ilham alan metasezgisel diğer algoritmalarından daha iyi performans gösterdiğini ortaya koymuştur (Li vd., Çevrimiçi Ön Yayın).

Yıldız ve arkadaşları, rüzgar enerjisi tahmini için iki adımlı yeni bir derin öğrenme yöntemini tanıtmışlardır. Önerilen bu modelde ilk aşamada Variational Mode Decomposition (VMD) tabanlı öznetelik çıkarma işlemi yapılmış sonrasında bu özneteliklerin görüntüye dönüştürülmüştür. İkinci aşamada ise rüzgar gücünü tahmin etmek için geliştirilmiş artık tabanlı derin Evrişimsel Sinir Ağı (CNN) kullanılmıştır. Önerdikleri bu yeni hibrit model de

yaptıkları varyasyon modu ayrıştırmasının ağırlık tahmin performansına önemli ölçüde katkıda bulunduğunu ayrıca daha az karmaşıklık ve daha az hesaplama maliyetine sahip olduğunu bildirmişlerdir (Yildiz vd., Çevrimiçi Ön Yayın).

Aly, rüzgar hızı ve güç tahmini için farklı yapay akıllı sistemleri kullanarak geliştirdiği yüksek doğrulukta hibrit derin öğrenme kümelenmiş modellerini önermiştir. Çalışma da Recurrent Kalman Filtresi (RKF), Fourier Serisi (FS), Wavelet (WNN) ve Yapay Sinir Ağı (YSA)'nın çeşitli kombinasyonları kullanılmıştır. On iki farklı hibrit model yazarlar tarafından ortaya konmuş ve test edilmiştir (Aly, Çevrimiçi Ön Yayın).

Memarzadeh ve Keynia, kısa dönemli rüzgar hızı tahminlerinin doğruluğunu artırmak için, dört modüle dayalı Karga Arama Algoritması (CSA), Dalgacık Dönüşümü (WT) ve Özellik Seçimi (FS) tabanlı, Entropi ve Karşılıklı Bilgi (MI) ve Uzun Kısa Süreli Bellek (LSTM) sinir ağlarına dayalı derin öğrenme zaman serisi tahmini modeli önermişlerdir. Çalışmada LSTM yapısını ve giriş özelliklerinin sayısını optimize etmek için Karga Arama Algoritması (CSA) kullanılmıştır. Önerilen rüzgar hızı tahmin modeli Avrupa da bulunan Galiçya ve Sotavento bölgeleri ile İranın Keman bölgesinden alınan gerçek verilere uygulanmıştır. Sunulan sayısal sonuçlar diğer bazı mevcut rüzgar hızı tahmin yöntemlerine kıyasla önerilen yöntemin verimliliğini göstermektedir (Memarzadeh ve Keynia, Çevrimiçi Ön Yayın).

Zhang ve arkadaşları rüzgar hızı tahmin doğruluğunu artırmak için Varyasyonel Mod Ayrıştırması (VMD), Meyve Sineği Optimizasyon Algoritması (FOA), Otoregresif Entegre Hareketli Ortalama Modeli (ARIMA) ve Derin İnanç Ağına (DBN) dayalı uyarlanabilir bir hibrit model önermişlerdir. İlk olarak rüzgar hızı VMD ve FOA tarafından bazı düzenli ve düzensiz bileşenlere ayrıştırılır. ARIMA modeli düzenli bileşenleri tahmin etmek için oluşturulurken, DBN düzensiz bileşen tahmini için kullanılır. Nihai tahmin sonuçları her bileşenin tahmin sonuçlarının toplanmasıyla elde edilir. Önerilen modelin etkinliği Çin de bulunan iki farklı rüzgar çiftliğinden alınan veriler kullanılarak doğrulanmış ve son yayınlanan bazı hibrit modeller ile karşılaştırılmıştır. Sonuçlara göre uyarlanabilir modelin doğruluğunun diğer modellere göre daha yüksek olduğu bildirilmiştir (Zhang vd., Çevrimiçi Ön Yayın).

Wu ve arkadaşları, etkili bir veri ayrıştırma tekniği, çok amaçlı bir optimizasyon algoritması, bir tahmin algoritması ve bir dizi kapsamlı değerlendirme yöntemini içeren yeni bir hibrit tahmin sistemi önermişlerdir. Çalışma da Tam Topluluk Deneysel Mod Ayrıştırması

(CEEMD) daha iyi bir tahmin performansı elde etmek için, rüzgar hızı dizisini bir dizi içsel mod işlevine bölerek Çok Amaçlı Gri Kurt Optimizasyon Algoritması (MOGWO) tarafından optimize edilen Aşırı Öğrenme Makinesine (ELM) uygular. Geliştirilen tahmin sisteminin performansının doğrulanması için Çin'in Shandong Yarımadasından 10 dakikalık aralıklarla alınan rüzgar hızı verileri kullanılarak kapsamlı değerlendirmeler sunulmuştur. Sonuçlar önerilen hibrit sistemin, karşılaştırılan diğer geleneksel modellere göre üstün olduğunu, aynı anda yüksek doğruluk ve güçlü kararlılık gösterdiğini rapor etmişlerdir (Wu vd., 2020: 158).

Li ve arkadaşları, kısa vadeli rüzgar gücü tahmini için Geliştirilmiş Yusufçuk Algoritması (IDA) ve Destek Vektör Makinesini (SVM) birleştirerek yeni hibrit bir model önermişlerdir. Yeni hibrit model IDA-SVM'de, SVM'nin optimal parametrelerini seçmek için IDA Algoritması kullanılmıştır. Önerilen modelin etkinliği Fransa'da bulunan La Haute Borne rüzgar çiftliğinden elde edilen gerçek veri kümeleri üzerinde doğrulanmıştır. Sonuçlara göre önerilen modelin Geri Yayımlı Sinir Ağı (BPNN) ve Gauss Süreç Regresyonu (GPR) gibi diğer modellere kıyasla daha iyi tahmin performansı göstermiştir (Li vd., Çevrimiçi Ön Yayın).

Chen ve Folly, rüzgar gücü tahmini için geleneksel bir yöntem ile iki yapay zeka yönteminin karşılaştırmasını sunmaktadır. Çalışmada tartışılan geleneksel yöntem en sağlam ve basit zaman serisi yöntemlerinden biri olan Otoregresif Hareketli Ortalama (ARMA) dır. Yapay zeka yöntemleri ise Yapay Sinir Ağları (YSA) ve Uyarlanabilir Nöro-bulanık Çıkarım Sistemi (ANFIS) dir. Önerilen yöntem için çok kısa vadeli ve kısa vadeli tahminler gerçekleştirilmiş, simülasyon sonuçlarına göre ANFIS'nin çok kısa vadeli (10 dakika ileri) durumlar da, ARMA'nın ise kısa vadeli (1 saat ileri) durumlar da rüzgar gücü tahmini için uygun olduğunu bildirmişlerdir (Chen ve Folly, 2018: 417).

Xiao ve arkadaşları, çalışmalarında kısa vadeli yük tahmini, kısa vadeli rüzgar hızı tahmini ve kısa vadeli elektrik fiyatı tahmini için yeni bir hibrit model önermişlerdir. Önerilen bu modelde Dalgacık Sinir Ağı (WNN) üzerinde kullanılan başlangıç ağırlıkları, genişleme ve öteleme parametrelerini optimize etmek için yeni geliştirilmiş Guguk Kuşu Optimizasyon Algoritması (COA) kullanılmıştır. Önerilen hibrit modelin değerlendirilmesi için Birleşik Krallık Gallerde Queensland, Avustralya'da Victoria ve Çin'de Penglai bölgelerindeki dört rüzgar enerjisi istasyonundan alınan gerçek veriler kullanılmıştır. Çalışmanın sonucunda karşılaştırılan modellere kıyasla önerilen hibrit modelin, kısa vadeli yük tahmini, kısa vadeli rüzgar hızı tahmini ve kısa vadeli elektrik fiyatı tahmininde Ortalama Mutlak Yüzde Hatası


(MAPE) deęerinde azalma saęladıęını gstermiřtir. (Xiao vd., 2017: 205).



2. ENERJİ SİSTEMLERİ

Hayatımızın her yönüyle vazgeçilmez bir parçası haline gelen enerji kavramı iş yapabilme yeteneği şeklinde ifade edilmektedir. Enerji sistemi ise enerjinin veya enerjinin dönüşümünden sonra açığa çıkan faydalarının istenen yere, istenen zaman da talep edilen ölçü de bir iletim ve dağıtım sistemi aracılığı ile ulaştırılabilmesi şeklinde tanımlanabilir. Enerji sistemleri, enerji taleplerini karşılayan enerji arz söktörü ile enerjiyi talep ederek tüketen son kullanıcı teknolojilerinden oluşan bir yapıya sahiptir. Bu sistemlerin amacı son kullanıcı olan müşterilere iletilen enerjinin kararlı, kaliteli ve kesintisiz olarak ulaştırılmasıdır.

Elektrik enerji üretimini, enerji kaynaklarının kullanımına göre konvansiyellik ve yenilenebilirlik açısından sınıflandırmak mümkündür. Konvansiyonel enerji kaynakları ilk akla gelen petrol, odun, kömür, doğalgaz vb. fosil yakıtların yanı sıra toryum ve uranyum gibi parçalanabilen yakıtları da kapsamaktadır. Yenilenemeyen enerji kaynakları olarak adlandırılan bu enerji kaynakları her ne kadar hayvan ve bitki artıkları ile dönüşerek fosil yakıtları oluştursalar da çok uzun yıllar gerektiren bu dönüşümleri nedeni ile konvansiyonel enerji kaynakları olarak ifade edilmektedirler (Dokur, 2014:6). Enerdata 2021 Global Enerji Trentleri Raporuna göre hazırlanmış 2000-2021 tarihleri arasında dünya üzerin de elektrik üretiminin enerji kaynaklarına göre dağılımı Şekil 2.1. de gösterilmiştir (Enerdata, 2021: 33).




Şekil 2.1. 2000-2021 yılları arasında dünya üzerindeki enerji üretiminin kaynaklara göre dağılımı
Kaynak: (Enerdata, 2021: 33)

Enerji sistemlerin de kullanılan diğer bir enerji kaynağı ise tez çalışmamızın da ana konusunu içeren yenilenebilir enerji kaynaklarıdır.

2.1. Yenilenebilir Enerji Sistemleri

Dünya üzerinde sanayi devriminden bugüne dek hızla artan enerji tüketimi ağırlıklı olarak üretim teknolojileri gelişmiş fosil tabanlı enerji kaynaklarından sağlanmaktadır. Fosil enerji kaynaklarının dünya üzerinde büyük çevresel sorunlara yol açması, rezervlerin yakın gelecek de azalacak veya tükenecek olması, enerji arzını sağlayan ülkelere bağımlılığın siyasi ve ekonomik sorunlara yol açabilmesi ve oluşan fiyat istikrarsızlıkları gibi nedenlerden dolayı yenilenebilir enerji kaynaklarının kullanımı önem kazanmıştır (Yılmaz, 2012: 33).

Yenilenebilir enerji sistemlerinin sınıflandırılması enerji kaynaklarına göre rüzgar enerjisi, güneş enerjisi, jeotermal enerji, hidrolik enerjisi ve biyoyakıt enerjisi olarak adlandırılmaktadır. Küresel ısınmanın çevreye verdiği etkiler nedeni ile dünyanın her geçen biraz daha ısınması yeni enerji politikalarının ortaya çıkmasına neden olmuştur. Bu politikalar gelecek de yenilenebilir kaynaklara olan yönelmenin hızla artacağına yöneliktir. International Energy Agency (IEA)'nin raporuna 2040 yılı öngörülerine göre hazırlanan dünya elektrik üretimin de enerji kaynaklarının payları Şekil 2.2. de gösterilmiştir (IEA, 2016: 46).



Şekil 2.2. 2040 yılına kadar öngörülen dünya üzerindeki elektrik enerjisi üretimin de enerji kaynaklarının payı
Kaynak: (IEA, 2016: 46)

Şekil 2.2. de kullanımı en çok azalan enerji kaynağı petrol olmak ile birlikte, yenilenebilir enerji kaynaklarının kullanımı yıllara göre artış göstermektedir. Konvansiyonel

enerji kaynakları arasında yer alan kömür, nükleer ve doğalgazın da kullanımının yıllara göre artış göstereceği de ayrıca rapor edilmiştir.


2.2. Rüzgar Enerji Sistemleri

Yenilenebilir enerji kaynakları arasında yer alan ve temiz enerji olarak nitelendirilen rüzgar enerjisi, aslında kaynağını güneşten sağlayan bir enerji türüdür. Günün belli evrelerin de dünyanın bir kısmının güneş tarafından ısıtılması neticesinde büyük hava kütleleri yoğunluğu düşen havanın sebep olduğu düşük basınç bölgelerine doğru hareket ederler. Bu hareket rüzgar adı verilen doğa olayının gerçekleşmesine sebep olmaktadır. Güneş den dünya üzerine gelen %1-2'lik enerji rüzgar enerjisine dönüşürken, dönüşen enerjinin değeri yaklaşık olarak 1.260.000 GW olarak hesaplanmaktadır. Ortaya çıkan bu enerji dünya enerji tüketiminin 20 katından daha fazladır. Teorik olarak dünya enerji ihtiyacının tek kaynak olarak rüzgar enerjisi ile karşılanabileceği akla gelse de kararlılık problemleri ve üretim verimlilikleri bu duruma imkan sağlamamaktadır (Dokur, 2017: 8).


M.Ö. 5000'li yıllara kadar uzanan bir geçmişi olan rüzgar enerjisi, elektrik üretmek maksadı ile ilk olarak 1881 yılın da Danimarka da kullanılmıştır. Yeterli güvenin oluşmaması nedeni ile 1920'lerin sonuna doğru kullanımı azalmıştır. 2. Dünya savaşının silah sanayinin yanı sıra bilimsel gelişmeleri ivmelendirdiği bu dönem de, özellikle aerodinamik teknolojisi hızla gelişmiştir. Bunun akabin de özellikle 2. Dünya savaşının sona ermesinin ardından rüzgar türbinlerinden elektrik enerjisinin elde edilerek kullanımı yine önem kazanmıştır. İlerleyen yıllar da ülkelerin mevcut özkaynaklarının kullanılmasına dönük öneminin artması ve petrol krizleri gibi nedenlerden rüzgar enerjisi üzerine yapılan çalışmalar hızla artmıştır (Akdağ, 2008: 10).

Günümüz enerji üretimi içerisinde yenilenebilir enerji kaynakları ve rüzgar enerjisinin payı her geçen gün hızla artmaktadır. Dünya da kurulu rüzgar kapasitesinin 2001-2020 yılları arasında ki kümülatif değişimi Şekil 2.3. de gösterilmiştir. Her yıl düzenli olarak Global Rüzgar Enerji Konseyinin (GWEC) dünya kamuoyuna sunduğu ve bu yıl 2021 Mart ayında açıkladığı raporuna göre 2020 yılı rüzgar endüstrisi açısından yıllık %59 büyüme oranı ile tarihinin en iyi yılı olduğu görülmektedir. . 2019 yılının sonlarına doğru ortaya çıkan ve 2020 yılın da bütün dünyayı etkisi altına alan Covid-19 salgını sebebi ile hem küresel tedarik zincirinin kesintiye uğraması hem de yeni rüzgar enerjisi projelerindeki inşaat hızlarının yavaşlaması rüzgar endüstrisi açısından zorlu bir yıl geçirilmesine neden olmuştur. Buna rağmen rüzgar endüstrisi 93 GW'lık yeni kurulum ile toplam kümülatif kurulu güç değerini

743 GW seviyesine yükseltmiştir. Rapora göre ülkeler bazında Çin ve ABD yıl içerisinde eklenen yeni kapasitenin %75'inden fazlasını bünyelerine katarak dünyanın en büyük kara rüzgar pazarları olmaya devam etmiştir. 2020 yılın da toplam kümülatif kurulu güç içerisindeki açık deniz rüzgar kapasitesinin payı %4,8 ile 35 GW olarak gerçekleşmiş ve Çin bu kapasitesinin yarısını tek başına bünyesine katmıştır (GWEC, 2021: 6).




Şekil 2.3. Dünya kurulu rüzgar kapasitesinin 2001-2020 yılları arasında ki kümülatif değişimi
Kaynak: (GWEC, 2021: 8)



Şekil 2.4. Dünya üzerin de 2020 yılı yeni kurulu güç miktarının ülkelere göre yüzdelik (%) dağılımı
Kaynak: (GWEC, 2021: 50)

Şekil 2.4. de dünya üzerinde 2020 yılı içerisinde de yeni kurulmuş 86,9 GW'lık güç miktarının ülkelere göre yüzdelik dağılımı gösterilmiştir. Grafiğe göre Çin yeni kurulu güç miktarının %56'sını tek başına gerçekleştirmiştir. Çinin ardından ABD %19 pay ile ikinci sırayı almaktadır. Türkiye 2020 yılını da gerçekleştirdiği 9,3 GW'lık yeni kurulu güç miktarı ile ilk ondaki yerini almıştır (GWEC, 2021: 50).

Covid-19 salgını tüm dünyayı olduğu gibi ülkemizi de derinden etkilemiştir. Tüm bu olumsuzluklara rağmen Türkiye Rüzgar Enerji Birliğinin (TÜREB) verilerine göre ülkemiz 2020 yılı içerisinde devreye alınan 1.124 MW'lık yeni kurulum ile toplam kurulu gücünü 9.305 MW'a yükseltmiştir. Türkiye kurulu rüzgar kapasitesinin 2006-2020 yılları arasında ki kümülatif değişimi Şekil 2.5. de gösterilmiştir. 2020 yılı içerisinde özellikle covid-19 salgını tedbirleri kapsamında kısıtlamaların yaşandığı dönemlerde rüzgar enerji santralleri elektrik enerjisi taleplerinin karşılanması da önemli rol oynamıştır. Aynı yıl içerisinde rüzgardan elde edilen elektrik enerjisi toplamı 24.486.469 MWh erişirken bu miktar Türkiye'de üretilen toplam elektrik enerjisinin %8,44'ünü oluşturmuştur. 2020 Nisan ayında ülkemizde üretilen elektrik enerjisinin %10,36'sı rüzgardan karşılanmış ve tüm zamanların rekoru kırıldığı görülmektedir. Halen yapımı süren inşa halindeki rüzgar enerji santralleri ile birlikte yaklaşık olarak 1.872 MW'lık kurulu güç ülkemize kazandırılacaktır. Bunlar gibi yeni yatırımlar ile birlikte Türkiye 2023 ulusal hedefi doğrultusunda da toplam 20 GW kurulu güce ulaşmayı amaçlamaktadır (TÜREB, 2021: 1).



Şekil 2.5. Türkiye kurulu rüzgar kapasitesinin 2006-2020 yılları arasında ki kümülatif değişimi
Kaynak: (TÜREB, 2021: 1)

3. ENERJİ SİSTEMLERİNDE RÜZGAR GÜCÜ TAHMİNİ


Elektrik enerjisi üretimi için kullanılan rüzgar enerji sistemleri, değişken yapıdaki rüzgar hızına ve meteorolojik şartlara bağıllık göstermektedir. Elektrik enerjisi üretiminin planlanması ve tüm ülkeyi kapsayan enterkonnekte sistemin yönetimi açısından rüzgar enerji sistemlerin de üretilecek elektrik enerjisinin anlık, kısa, orta ve uzun vadede tahmin edilebilmesi büyük öneme sahiptir. Bu neden ile hata oranını minimuma indirerek rüzgar hızının ve buna bağlı olarak rüzgar gücünün tahmin edilmesi gerekmektedir.

Rüzgar türbini kontrolü için kullanılan anlık tahminler birkaç dakikalık tahminleri ifade ederken, güç sisteminin yönetimi için kullanılan çok kısa süreli tahminler ise 0-6 saat arası yapılan tahminleri kapsamaktadır. Üretim planlaması ve enerji borsaları için kullanılan kısa süreli tahminler 0-72 saat aralığındadır. Orta ve uzun vadeli olarak ifade edilen ve tahminler 0-7 gün veya daha fazla süreli olarak yapılan, bakım ve onarım amacıyla kullanılan tahminlerdir. Tablo 3.1. de rüzgar tahminlerinin zaman açısından sınıflandırılmaları ve uygulama alanlarını göstermektedir.

Tablo 3.1. Rüzgar tahminlerinin zaman açısından sınıflandırılmaları ve uygulama alanları

Zaman Dilimi	Zaman Aralığı	Uygulama Alanları
Çok Kısa Vadeli	Birkaç saniyeden 30 dakikaya kadar olan süreyi kapsamaktadır.	- Elektrik piyasası faiz oranları - Düzenletici eylemler
Kısa Vadeli	30 dakikadan 6 saate kadar olan süreyi kapsamaktadır.	- Ekonomik yük dağıtım planlaması - Yük arttırma/azaltma kararları
Orta Vadeli	6 saatten 1 güne kadar olan süreyi kapsamaktadır.	- Generatör çevrimiçi çevrimdışı olma kararları - Bir sonraki gün için elektrik piyasasının da operasyonel güvenlik
Uzun Vadeli	1 günden 1 haftaya kadar olan süreyi kapsamaktadır.	- Birim taahhüt kararları - Rezerv gereklilik kararları - Optimal işletme maliyeti için

Şekil 3.1’de bir rüzgar enerjisi dönüştürme sisteminde yer alan bileşenler sunulmaktadır.



Şekil 3.1. Rüzgar türbini bileşenleri
Kaynak: (Onay, 2021: 32)

Genel bir rüzgar türbini birbirini ile ilişkili çeşitli parçalardan oluşmaktadır. Rüzgar ölçer, rüzgar hızını ölçerek kontrol ünitesine ileten bileşenidir. Pervane kanatları, üzerinden esen rüzgarın kaldırmasıyla dönme eyleminin gerçekleştiği parçadır. Genellikle 2 veya 3 pervane kanadına sahiptir. Dönmek de olan pervaneye bağlı diskin acil durumlarda durdurulması fren mekanizması tarafından gerçekleştirilir. Sistem mekanik, elektronik ve hidrolik olarak çalışabilir. Kontrol ünitesi rüzgarın hızındaki değişikliklere göre sistemi durdurur veya harekete geçirir. Rüzgar hızının saat de 8-16 mil arasında olması durumun da sistemi çalıştırır. Rüzgar hızının saatte 55 mil'in üzerine çıkması durumlarında türbinin kanatları zarar görmesi sebebiyle rüzgar hızının 55 mil veya üzeri çıkması durumun da sistem durdurulur.. Düşük hızlı mili yüksek hızlı mile bağlayan yapıya vites kutusu denir. Elektrik üretmek için gerekli olan dönüş hızını 30-60 devir/dakikadan (rpm) 1000/1800 devir/dakikaya (rpm) çıkartmaktadır. Rüzgar türbinleri yüksek irtifada daha fazla elektrik enerjisi ürettikleri için kule bölümünde boru şeklin de çelik, beton veya çelik beton gibi daha dayanıklı malzemeler kullanılmaktadır (Wagner, 2018: 495).

Rüzgâr enerjisi tahmin metotları genel olarak 4 başlık altında incelenebilir.

Fiziksel Uygulamalar; pürüzlülük ve engeller gibi arazideki fiziki faktörlerin kullanılarak sayısal hava tahminlerinin iyileştirilmesi işlemidir. Bu yöntem, atmosferik durum, rüzgâr hızı, yerel topografya ve rüzgâr enerjisi santralinin çıktısı arasındaki fiziksel ilişkiyi tanımlayan bir modeli içermektedir (Kırbaş, 2018: 26).

İstatistiksel Uygulamalar; kolaylıkla modellenebilen ve diğer yöntemlerle karşılaştırıldığında da daha ekonomik olan yöntemdir. İstatistiksel yöntemler, önümüzdeki birkaç saat içinde mevcut durumu tahmin etmek için önceki rüzgâr verilerini kullanmaktadır. Kısa süreler için iyi sonuçlar vermektedir. Yöntemin dezavantajı tahmin zamanı ile birlikte hatanın da artış göstermesidir. İstatistik zaman serisi modelleri, rüzgâr enerjisi çıktısını altı saat önceden tahmin etmek için kullanılmaktadır (Kırbaş, 2018: 26).

Yapay Sinir Ağları Uygulamaları; insan beyni ve sinir sistemindeki davranışları taklit etme düşüncesi üzerine kurulmuş bir veri işleme modelidir. Yapay Sinir Ağları (YSA) insan beyni içerisindeki nöronların benzetilmesi ile oluşturulmuştur. Nöronların bir araya gelmesi ile oluşturulan ağ yapılarının öğrenme olayını gerçekleştirmesi prensibine dayanmaktadır. (Dokur, 2017: 19).

Hibrit Uygulamalar; hem nöro-bulanık hem de YSA modelinin bir araya gelmesiyle yada farklı ayrıştırma tekniklerinin bir arada kullanılmasıyla oluşan kombinasyonlardır. Hibrit yöntemler, bireysel modellere kıyasla daha iyi doğruluk da rüzgâr tahmini sonuçları elde etmektedir (Kırbaş, 2018: 26).

Rüzgar türbinlerin de kullanılan ideal bir rüzgar güç eğrisi grafiği Şekil 3.2. de gösterilmiştir. Bu eğri, rüzgar hızı ile çıkış da alınacak rüzgar gücünün ilişkisini anlatmaktadır.

$$P_w = \frac{1}{2} \cdot \rho \cdot A \cdot v^3 \quad (3.4)$$

Burada P_w değeri rüzgar gücünü (Watt), ρ hava yoğunluğunu (kg/m^3)(15°C ve 1 atm için, $\rho=1.225 \text{ kg/m}^3$), A rüzgarın geçtiği kesit alanını (m^2) ve v rüzgar hızını (m/s) belirtmektedir (Masters, 2013: 312).

Elektrik güç sisteminin en önemli karakteristiklerinden biri de sürekli ve tam güç ile ürettiği kW gücüdür. Üretilen bu güce anma gücü denir. Sistem bir generatöre sahip ise anma gücü generatörün çıkışına göre belirlenmektedir. Eğer bu jeneratör bir yıl boyunca çıkış olarak anma gücünü verir ise, verilen enerji anma gücünün 8760 (saat/yıl) katı olacaktır. Güç sistemleri tam güçte bir yıl boyunca çalışmadığından, maksimum miktarın altında bir çıkış vermektedirler. Kapasite faktörü (KF) 0 ile 1 arasında değişen, alınan enerji ve anma gücü arasındaki ilişkiyi veren ifadedir. Denklem (6)'da gösterilmiştir.

$$Yıllık \text{ Enerji } (kWh / yıl) = P_R (kW) \times 8760 (saat / yıl) \times KF \quad (3.5)$$

Burada P_R anma gücü (kW) ve KF kapasite faktörü değerleridir.

$$KF = \frac{\text{Verilen gerçək enerji}}{P_R \times 8760} \quad (3.6)$$

Başka bir şekilde ifade etmek gerekirse,

$$KF = \frac{\text{Verilen gerçək enerji} / 8760 \text{ sa} / \text{yıl}}{P_R} = \frac{\text{Ortalama güç}}{\text{Anma gücü}} \quad (3.7)$$

4. RÜZGAR GÜCÜ TAHMİNİNDE META-SEZGİSEL OPTİMİZASYON ALGORİTMALARI

Meta-sezgisel optimizasyon algoritmaları basit, esnek ve kolay yapıları nedeni ile son otuz yılda akademik alanda çok popüler hale gelmiştir. Bu yaklaşımların yüksek verimlilikleri, kolay uygulanır yapıda olmaları ve yerel optimumdan kaçınma becerileri günümüz mühendislik bilimlerin de yaygın olarak kullanılmalarını sağlamıştır. Optimizasyon teknikleri bilimsel bilimsel çalışmalar sırasında oluşturulan modellerin gerçek hayat uyumunu sağlamak için en iyi ürünü elde etmeyi hedeflemektedir. Doğadan ilham alan meta-sezgisel algoritmaların tasarlanmasında sıklıkla doğadaki çeşitli canlıların avlanma teknikleri, beslenme yöntemleri ve çiftleşme alışkanlıkları gibi özellikleri kullanılır. Bu algoritmaların en bilinenlerine örnek olarak Genetik Algoritma (GA), Parçacık Sürü Optimizasyonu (PSO) algoritması ve Yapay Arı Kolonisi (ABC) algoritması verilebilir.

Güç sistemlerinin planlanması, güvenilirliği ve yönetimi açısından rüzgar enerji sidönüştürme sistemlerinden elde edilecek olan elektrik enerjisinin kısa dönemli tahmini büyük öneme sahiptir. Rüzgar enerji sistemlerinden elde edilecek olan enerjinin en önemli parametrelerinden biri rüzgar gücüdür. Rüzgar gücü verisinin kesikli, asimetrik, kaotik ve durağan olmayan yapısı sebebiyle rüzgar hızı tahminin, meta-sezgisel algoritmalar ve bu algoritmaların hibrit yaklaşımları geliştirilerek sıklıkla kullanılmıştır. Giriş bölümünde ele alınan çalışmalara ek olarak literatürdeki bu alandaki bazı çalışmalar aşağıda verilmiştir.

Dokur ve arkadaşları, Adaptive Neuro Fuzzy Inference System (ANFIS) kullanılarak mevsimsel rüzgar hızı tahmin modelleri geliştirilmişlerdir. ANFIS parametrelerinin eğitimi için meta-sezgisel Parçacık Sürü Optimizasyonu (PSO) algoritması kullanılmıştır. Türkiye, Bandırma için önerilen hibrit yaklaşımın sonbalar, ilkbahar, yaz ve kış için performans metrikleri (MSE) çıkarılmış ve tahmin sonuçlarına göre bahar döneminde diğer mevsimlere göre daha iyi sonuçlar verdiği belirtilmiştir (Dokur vd., 2019: 318).

Niu ve arkadaşları, rüzgar hızı tahminin de optimum özellik seçimi ve yapay bir sinir ağı kullanılan modifiye Yarasa Optimizasyon algoritması kullanarak tahmin performansını iyileştirmişlerdir (Niu vd., 2018: 228).

Liu ve arkadaşları, Düzenli Ekstrem Öğrenme Makinesi (RELM) parametrelerini Gri Kurt Optimizasyon (GWO) algoritması ile optimize ederek çok adımlı rüzgar hızı tahmini için hibrit bir model önermiştir (Liu vd., 2018: 282).

Xiao ve arkadaşları, rüzgar hızı tahminin de ağırlık katsayılarını optimize etmek için Kaotik Parçacık Sürü Optimizasyonu (CPSO) algoritmasını kullanarak dört ayrı rüzgar çitliğinden alınan rüzgar serilerini doğrulamıştır (Xiao vd., 2015: 286).

Wang ve arkadaşları, Çok Amaçlı Balina Optimizasyonu (MOWOA) algoritması kullanarak rüzgar hızı tahminin de yeni bir hibrit sistem önermişlerdir (Wang vd., 2017: 358).

Osorio ve arkadaşları, Evrimsel Parçacık Sürü Optimizasyonu (EPSO) algoritması tabanlı Bulanık Çıkarım Sistemi (ANFIS) hibrit yaklaşımı ile kısa vadeli rüzgar hızı tahminin de düşük hesaplama yükünün yanı sıra daha az belirsizlik elde etmişlerdir (Osorio vd., 2015: 305).

Fei ve He, dalgacık ayrıştırmasının hibrit modelini ve Yapay Arı Kolonisi (ABC) algoritmasına dayalı yeni bir hibrit model önermişlerdir (Fei ve He, 2015: 630).

Rahmani ve arkadaşları, kısa vadeli rüzgar enerjisi tahmini için Karınca Kolonisi Optimizasyonu (ACO) algoritması ile Parçacık Sürü Optimizasyonu (PSO) algoritmasının hidridizasyonundan yeni bir hibrit yaklaşım önermişlerdir (Rahmani vd., 2013: 169).

Bu bölüm de temel meta-sezgisel algoritma örneklerinden olan ve tez çalışmamız da önerdiğimiz yeni hibrit yaklaşımın karşılaştırılmasın da kullandığımız Güve-Alev Optimizasyon (MFO) algoritması (Mirjalili, 2015: 230), Parçacık Sürü Optimizasyon (PSO) algoritması (Kennedy ve Eberhart, 1995: 40), Yusufçuk Optimizasyon algoritması (DA) (Mirjalili, 2016: 1054), Sinüs Kosinüs Algoritması (SCA) (Mirjalili, 2016: 121) ve Balina Optimizasyon Algoritması (WOA) (Mirjalili ve Lewis, 2016: 52) kısaca tanıtılmıştır. Ardından tez çalışmamız da kullandığımız Gri Kurt Optimizasyon (GWO) algoritması ayrıntılı olarak incelenmiştir.

4.1. Güve-Alev Optimizasyon (MFO) Algoritması

Güve-Alev Optimizasyon (MFO) algoritması, 2015 yılın da Mirjalili tarafından önerilen, doğadan ilham alan yeni bir meta-sezgisel optimizasyon algoritmasıdır. MFO algoritmasının edicinin ana ilham kaynağı, doğadaki güvelerin enine yönlendirme adı verilen gezinme yöntemleridir. Güveler geceleri aya göre sabit bir açıyı koruyarak uçmaktadırlar. Bu durum uzun mesafeler boyunca düz bir çizgide seyahat etmek için çok etkili bir yöntemdir. Bununla birlikte, yapay ışıkların etrafın da bu özelliklerini kullanamayarak ölümcül sarmal bir yolda sıkışıp kalırlar (Mirjalili, 2015: 230)

4.2. Parçacık Sürü Optimizasyon (PSO) Algoritması

Parçacık Sürü Optimizasyon (PSO) algoritması, Kennedy ve Eberhart tarafından önerilen yeni meta-sezgisel yaklaşımlardan bir tanesidir. PSO algoritması, kuşların ve böceklerin doğal akın ve sürü davranışına dayanmaktadır. Bu algorithmada arama uzayın da bir grup kuş rastgele besin kaynağı bulmak için arama yapmaktadır. PSO algoritmasının da parçacık olarak adlandırılan kuşlar mekanizma. Parçacıkların/kuşların tümü, uygunluk fonksiyonu kullanılarak hesaplanan maliyet değerlerine ve uçuşu yönlendiren hızlara sahiptir. Parçacık, her tekrarlama da kişisel en iyi ve genel en iyi değerleri ile güncellenir. Kişisel en iyi değeri elde edilen en iyi çözümü ifade etmektedir. Her parçacık için uzak küresel en iyi, popülasyondaki herhangi bir parçacık tarafından şimdiye kadar elde edilen en iyi çözümü temsil etmektedir. Optimizasyonu kullanmadan önce PSO algoritmasının da ayarlanması gereken bazı parametreler vardır. Bunlar parçacık sayısı ve öğrenme faktörleridir (c_1 ve c_2). (Kennedy ve Eberhart, 1995: 40) (Dokur vd., 2017: 8).

4.3. Yusufçuk Optimizasyon Algoritması (DA)

Yusufçuk Algoritması (DA), yeni bir sürü zekası optimizasyon tekniği olarak 2016 yılın da Mirjalili tarafından önerilmiştir. DA algoritmasının ana ilham kaynağı, yusufçukların doğadaki statik ve dinamik oğul verme davranışlarıdır. Optimizasyonun iki temel aşaması, olan keşif ve sömürü, yusufçukların gezinme, yiyecek arama ve dinamik veya istatistiksel olarak sürü halindeyken düşmanlardan kaçınmadaki sosyal etkileşimini modelleyerek tasarlanmıştır (Mirjalili, 2016: 1058).

4.4. Sinüs Kosinüs Algoritması (SCA)


Mirjalili tarafından 2016 yılın da önerilen Sinüs Kosinüs Algoritması (SCA), daha iyi çözümler bulma umuduyla arama uzayında iki çözüm arasındaki boşluğu keşfetmek ve kullanmak için sinüs ve kosinüs fonksiyonlarını kullanmaktadır. Önerilen bu algoritma, ilham, matematiksel formülasyon ve gerçek dünya uygulaması açısından tamamen farklılık göstermektedir. MFO algoritması doğadaki güvelerin navigasyonunu taklit ederken, SCA algoritması optimizasyon problemlerini çözmek için sinüs/kosinüs matematiksel fonksiyonlarına dayanmaktadır (Mirjalili, 2016: 121).

4.5. Balina Optimizasyon Algoritması (WOA)

Kambur balinaların sosyal davranışını taklit eden Balina Optimizasyon Algoritması (WOA) 2016 yılın da Mirjalili ve Lewis tarafından önerilen, doğadan ilham alan yeni bir meta-sezgisel optimizasyon algoritmasıdır. Algoritma, kabarcık ağı avlama stratejisinden esinlenmiştir (Mirjalili ve Lewis, 2016: 52).

4.6. Gri Kurt Optimizasyon (GWO) Algoritması

Son zamanlar da popüler olarak kullanılan meta-sezgisel optimizasyon algoritmaların dan biri de Gri Kurt Optimizasyon (GWO) algoritmasıdır. 2014 yılında Mirjalili tarafından önerilen algoritma, doğada bozkurt (Canis lupus) ailesine ait gri kurtların liderlik hiyerarşisi ve avlanma biçimlerini taklit eden meta-sezgisel bir yaklaşımdır. Gri kurtlar doğal yaşam içerisinde besin zincirinin en üstün de yer alan yırtıcı türlerdir. 5 ila 12 arasında gri kurdun oluşturduğu sürüler halinde hareket ederler. Sürüler çok sert ve baskın bir hiyerarşik yapı ile yönetilir. Sürü içerisinde de gri kurtlar alfa, beta, omega ve delta şeklinde adlandırılan ve hakimiyetin yukarıdan aşağıya doğru indiği bir yapıya sahiptir. Lider gri kurt, sürünün en baskın üyesi alfa kurdur. Alfa kurdu her zaman sürünün en güçlü üyesi değildir. Yönetme becerisi açısından sürünün en iyisidir. Alfa kurdu sürü içerisinde de genellikle avlanma, uyuma yeri, uyanma zamanı vb. konularla ilgili kararlar vermekten sorumludur. Sıralamada ikinci sırada yer alan beta kurdu, karar verme ve diğer faaliyetlerin de alfa kurduna yardımcı olur. Beta kurdu hiyerarşik olarak alfa kurduna bağlıyken, altındaki diğer kurtları da (omega ve delta) yönetir. En alt kategori de olan omega kurdu, diğer baskın kurtların tümüne boyun eğer. Sürü içerisinde de gri kurtlar alfa, beta ve omega kurtlarından biri değilse delta olarak adlandırılır. Delta kurtları hiyerarşik olarak alfa ve beta kurtlarına bağlıyken omega kurtlarına hükmederler. Şekil 4.1. de gri kurtların liderlik hiyerarşisi gösterilmiştir (Mirjalili vd., 2014: 54).



Şekil 4.1. Gri kurtların liderlik hiyerarşisi

Kaynak: (Doğan ve Yüzgeç, 2018: 71)

Gri kurtların bir başka sosyal davranış şekli de grup avı stratejisidir. Bu stratejide gri kurtlar öncelikle avın yerini tanır ve alfa kurdun önderliğinde avın etrafını sararlar. Gri kurtların avlanma stratejisinin matematiksel modelinde alfa, beta ve delta kurtlarının, avın yeri hakkında daha iyi bilgiye sahip oldukları varsayılmaktadır. Bu nedenle, kurtların GWO algoritmasındaki konumlarını güncellemek için en iyi ilk üç çözüm (alfa, beta ve delta kurtları için) kullanılır. GWO algoritmasında omega kurtu kullanılmamıştır. Gri kurtların avlanma mekanizması, aşağıda verilen denklemler kullanılarak modellenmiştir (Mirjalili vd., 2014: 54).

$$\vec{D}_\alpha = |\vec{C}_\alpha \cdot \vec{X}_\alpha - \vec{X}_i| \quad (4.1)$$

$$\vec{D}_\beta = |\vec{C}_\beta \cdot \vec{X}_\beta - \vec{X}_i| \quad (4.2)$$

$$\vec{D}_\delta = |\vec{C}_\delta \cdot \vec{X}_\delta - \vec{X}_i| \quad (4.3)$$

$$\vec{U}_\alpha = \vec{X}_\alpha - \vec{A}_\alpha \vec{D}_\alpha \quad (4.4)$$

$$\vec{U}_\beta = \vec{X}_\beta - \vec{A}_\beta \vec{D}_\beta \quad (4.5)$$

$$\vec{U}_\delta = \vec{X}_\delta - \vec{A}_\delta \vec{D}_\delta \quad (4.6)$$


$$\vec{X}_i = (\vec{U}_\alpha + \vec{U}_\beta + \vec{U}_\delta)/3 \quad (4.7)$$

Bura da $\vec{D}_\alpha, \vec{D}_\beta, \vec{D}_\delta$, alfa, beta ve delta gri kurtları ile av arasındaki mesafe vektörünü göstermektedir. $\vec{X}_\alpha, \vec{X}_\beta, \vec{X}_\delta$, alfa, beta ve delta gri kurtları için avın konum vektörünü temsil etmektedir. $\vec{X}_i$ iterasyondaki konum vektörünü, $\vec{U}_\alpha, \vec{U}_\beta, \vec{U}_\delta$ alfa, beta ve delta gri kurtları için deneme vektörünü göstermektedir. $\vec{C}_\alpha, \vec{C}_\beta, \vec{C}_\delta, \vec{A}_\alpha, \vec{A}_\beta, \vec{A}_\delta$ ise alfa, beta ve delta gri kurtları için katsayı vektörlerini ifade etmektedir. Bu katsayı vektörleri aşağı da verilen denklemlere göre bulunmaktadır.

$$\vec{A}_i = 2\vec{a}\vec{r}_{i1} - \vec{a}, i = \alpha, \beta, \delta \quad (4.8)$$

$$\vec{C}_i = 2\vec{r}_{i2}, i = \alpha, \beta, \delta \quad (4.9)$$

Burada $\vec{a}$ 2 den 0'a doğrusal olarak azaltılmış bir vektörü ifade eder. $\vec{r}_{i1}$ ve $\vec{r}_{i2}$ [0 1] aralığının da seçilen rasgele vektörü temsil etmektedir. Şekil 4.2 de gri kurtların avlanma stratejisi gösterilmiştir. Bu şekilde de görüldüğü gibi gruptaki her bir gri kurt alfa, beta ve delta gri kurtları arasındaki mesafeye göre konumunu günceller ve avına yaklaşır. Sonunda av gri kurtlar tarafından yakalanır ve kurt grubu ava saldırarak avı bitirir. GWO algoritmasının kaba kodu aşağıda verilmiştir (Mirjalili vd., 2014: 54) (Doğan ve Yüzgeç, 2018: 72).



Şekil 4.2. Gri kurtların avlanma mekanizması

Kaynak: (Doğan ve Yüzgeç, 2018: 72)

Algoritma 1: GWO algoritmasının kaba kodu (Mirjalili vd., 2014: 54).

```
Gri Kurtların konumlarını başlat
Gri Kurtların fitness değerlerini hesapla
En iyi alfa gri kurdunu kaydet
En iyi alfa beta kurdunu kaydet
En iyi delta gri kurdunu kaydet

while (iterasyon < maksimum iterasyon)
    for her gri kurt için
        Alfa, Beta ve Delta için katsayı vektörlerini üret
        Uzaklık vektörlerini hesapla ( $\vec{D}_\alpha, \vec{D}_\beta, \vec{D}_\delta$ )
        Deneme vektörlerini hesapla ( $\vec{U}_\alpha, \vec{U}_\beta, \vec{U}_\delta$ )
        Denklem (7)'i kullanarak gri kurdun konumunu güncelle
    end for
    Güncellenmiş gri kurtlar için uygunluk değerlerini hesapla
    for her gri kurt için
        if (gri kurt < alfa)
            alfa kurdunu güncelle
        else if (gri kurt < beta)
            beta kurdunu güncelle
        else if (gri kurt < delta)
            delta kurdunu güncelle
        end if
    end for
    iterasyonu artır
end while
alfaya geri dön
```

Literatürde sürü zekasına dayalı sezgisel Gri Kurt Optimizasyon (GWO) algoritması ve hibrit yaklaşımlarının, rüzgar hızı tahmini, rüzgar gücü tahmini, yük tahmini ve ekonomik yük dağıtım problemlerine yönelik çözüm yöntemleri önerilmiştir.

Doğan ve Yüzgeç, çalışmaların da robot yol planlama problemini ele almış, herhangi bir engele dokunmadan başlangıç noktasından hedef noktaya en uygun yolu bulabilmek için GWO algoritmasını önermişlerdir. GWO algoritması Diferansiyel Evrim (DE), Parçacık Sürü

Optimizasyonu (PSO) algoritması, Yapay Arı Kolonisi (ABC) algoritması ve Ateş Böceği Optimizasyon Algoritması (FOA) gibi iyi bilinen meta-sezgisel algoritmalar ile karşılaştırılmıştır. Karşılaştırma sonuçlarına göre önerilen GWO algoritmasının çok rekabetçi sonuçlar sağlayabildiği bildirilmiştir (Doğan ve Yüzgeç, 2018-72).

Altan ve arkadaşları, Uzun Kısa Süreli Bellek (LSTM) ağı ve GWO algoritması ile ayrıştırma yöntemlerine dayalı güvenilir ve doğru yeni bir rüzgar hızı tahmin yöntemi geliştirmişlerdir (Altan vd., 2021: 630).

Fu ve arkadaşları, çok adımlı ileriye dönük kısa vadeli rüzgar hızı tahmini için hibrit Harris Şahin Optimizasyonu (HHO) algoritması ile GWO algoritmalarının mutasyon ve hiyerarşi tabanlı hidridizasyon stratejisini önermişlerdir (Fu vd., Çevrimiçi Ön Yayın).

Wang ve arkadaşları, kısa vadeli rüzgar hızı tahmini için Çok Amaçlı Gri Kurt optimizasyonu (MOGWO) ile optimize edilmiş bir hibrit Elman Sinir Ağı (ENN) yöntemi geliştirilmiştir (Wang vd., 2019: 1190).

Wu ve arkadaşları, rüzgar hızı tahminin de Çok Amaçlı Gri Kurt Optimizasyonu (MOGWO) ile optimize edilmiş Aşırı Öğrenme Makinesi (ELM) kullanarak çok amaçlı optimizasyona sahip hibrit bir sistem önermişlerdir (Wu vd., 2020: 163).

Barman ve Choudhury, Hindistanın Assam şehrinde anormal güç sistemi durumların da kullanılmak üzere benzerlik tabanlı GWO algoritması ile hibritlenmiş Destek Vektör Makinesi (SVM) hibrit güç sistemi yük tahmin yöntemi geliştirmiştir (Barman ve Choudhury, Çevrimiçi Ön Yayın).

Singh ve Dhillon, ekonomik yük dağıtım probleminin çözümü için İyileştirilmiş Gri Kurt Optimizasyon (AGWO) algoritması olarak adlandırılan hibrit algoritmayı geliştirmiş ve orta büyüklükteki elektrik jeneratör sistemleri için kıyaslama problemlerin de doğrulamıştır (Singh ve Dhillon, 2019: 417).

Pradhan ve arkadaşları, GWO algoritmasının etkinliğini gerçekleştirmek için valf noktası etkisi, rampa hızı ve yasak bölge gibi doğrusal olmayan ekonomik yük dağıtım sorunlarına uygulamışlardır (Pradhan vd., 2016: 325).


Jayabarathi ve arkadaşları, güç sistemlerinin ekonomik dağıtım problemlerinin çözümün de geliştirdikleri Hibrit Gri Kurt Optimizasyon (HGWO) algoritmasını önermişlerdir (Jayabarathi vd., 2016: 632).

Pradhan ve arkadaşları, önerdikleri hibrit Muhalif Tabanlı Gri Kurt Optimizasyon (OGWO) algoritmasını ekonomik yük dağıtım problemlerinin çözümünde kullanmış ve etkinliğini incelemek için GWO algoritması ile karşılaştırmışlardır (Pradhan vd., 2018: 2023).



5. GELİŞTİRİLEN GRİ KURT OPTİMİZASYON ALGORİTMASI İLE YENİ RÜZGAR GÜCÜ TAHMİN YAKLAŞIMI

Bu bölümde gri kurt optimizasyon algoritması üzerinden geliştirilerek önerilen Çok Stratejili Rastgele Ağırlıklı Gri Kurt Optimizasyon (MsRwGWO) algoritmasının geliştirilme sürecine ve performans analizlerine ayrıntılı şekilde yer verilmiştir. Ayrıca önerilen MsRwGWO algoritmasının rüzgar gücü tahmininde uygulamasına ilişkin tez çalışmasının akış şeması Şekil 5.1 de sunulmuştur.



Şekil 5.1. Önerilen MsRwGWO algoritmasının kısa dönemli rüzgar gücü tahmininde kullanılmasına ilişkin akış şeması

Tez çalışmasında Türkiye'deki Balıkesir ilinde bulunan rüzgar çiftliklerinden 2016 yılının Şubat-Haziran döneminde, 15 dakika aralıklarla alınmış gerçek zamanlı rüzgar hızı veri kümeleri kullanılmıştır. Her seri 6849 örnek içermekle birlikte eğitim serileri ve test serileri olmak üzere iki gruba ayrılmıştır. Her veri serisinin ilk 4794 örneği eğitim için, geri kalanı ise test için kullanılmıştır. Ölçülen rüzgar hızının yüksekliği 50 m ve örnekleme aralığı 15 dakikadır. Model performansını artırmak için giriş veri seti [0 1] aralığının da normalize edilmiştir. Tek adımlı kısa vadeli rüzgar gücü tahmini için, MsRwGWO' algoritmasına dayalı MLP modelindeki rüzgar gücü veri setinin üç ardışık girdisi ($V(k), V(k-1), V(k-2)$) kullanılmıştır.

5.1. Önerilen Çok Stratejili Rastgele Ağırlıklı Gri Kurt Optimizasyon (MsRwGWO) Algoritması


Tez çalışmamız da, orjinal GWO algoritmasının arama performansını geliştirebilmek için bazı yeni yaklaşımlar önermekteyiz. Bu bölüm de önerilen bu yeni yaklaşımlar ayrıntılı şekilde açıklanmıştır. GWO algoritmasına toplam olarak altı farklı yeni mekanizma eklenmiştir. bunlar sırasıyla aşağıdaki gibidir.

1. Denklem de kullanılan $\vec{a}$ parametresini güncellemek için bir geçiş mekanizması uyarlanmış (8),
2. Gri kurtların konumlarını güncellemek için yeni bir ağırlıklı güncelleme mekanizması sunulmuş,
3. GWO algoritmasına yeni bir mutasyon operatörü eklenmiş,
4. Arama uzayının sınırlarını kontrol etmek için yeni bir mekanizma kullanılmış,
5. Algoritmaya bir seçim mekanizması eklenmiş,
6. Alfa, beta ve delta kurtlarının güncelleme mekanizması yenilenmiştir.

GWO algoritmasının parametrelerinden bir tanesi de optimizasyon işlemi sırasında 2'den 0'a lineer olarak düşürülen $\vec{a}$ parametresidir. Bu parametre keşif aşamasından işletme aşamasına geçişte önemli bir rol oynamaktadır. Bu geçiş mekanizması tez çalışmamız da yerel optimal çözümlerden kaçınmak amacı ile 2020 yılın da Gupta ve arkadaşları tarafından sunulan Sinüs Kosinüs Optimizasyon Algoritması (SCA) için önerilen doğrusal olmayan bir fonksiyona göre yeniden tanımlanmıştır. $\vec{a}$ parametresi için önerilen doğrusal olmayan geçiş fonksiyonu aşağıda verilmiştir (Gupta vd., Çevrimiçi Ön Yayın).

$$\vec{a} = 2 \times \sin \left(\left(1 - \frac{iter}{Max_iter} \right) \times \frac{\pi}{2} \right) \quad (5.1)$$

Şekil 5.2. de GWO algoritmasındaki orijinal doğrusal geçiş parametresinin değişikliklerini ve önerilen doğrusal olmayan geçiş parametresini birlikte göstermektedir. $\vec{a}$ parametresinin daha yüksek değerleri keşif aşamasını ($\vec{a} > 1$) kolaylaştırırken, $\vec{a}$ parametresinin daha düşük değerleri arama uzayının yerel kullanım aşamasını ($\vec{a} < 1$) kolaylaştırmaktadır. Grafik 5.2. de görülebileceği gibi, önerilen geçiş prosedürü arama aşamasının süresinin, işletme aşamasının süresinden daha uzun olmasını sağlamaktadır.



Şekil 5.2. Orjinal ve önerilen geçiş parametreleri

GWO algoritmasının da bulunan $\vec{a}$ parametresinin değiştirilmesin de doğrusal olmayan geçiş fonksiyonunun kullanılmasının sonrasın da, gri kurtların konumlarının güncellenmesine yönelik mekanizmanın oluşturulmasına odaklanılmıştır. Orjinal GWO algoritmasının da gri kurtların konumları, alfa, beta ve delta gri kurtlarının konumlarına göre hesaplanan deneme vektörlerinin $\vec{U}_\alpha, \vec{U}_\beta, \vec{U}_\delta$ ortalaması alınarak güncellenmektedir. Önerilen güncellenmiş mekanizmada, kurtların gruptaki yeni konumları alfa, beta ve delta kurtlarının uygunluk puanlarına göre belirlenmiştir. Yeni oluşturulan bu mekanizmanın denklemleri aşağıda verilmiştir.

$$S = \sum_{i=\alpha,\beta,\delta} \frac{1}{f(\vec{X}_i)} \quad (5.2)$$

$$w_\alpha = \frac{f(\vec{X}_\alpha)^{-1}}{S}, w_\beta = \frac{f(\vec{X}_\beta)^{-1}}{S}, w_\delta = \frac{f(\vec{X}_\delta)^{-1}}{S} \quad (5.3)$$

$$\vec{X}_i = w_\alpha \vec{U}_\alpha + w_\beta \vec{U}_\beta + w_\delta \vec{U}_\delta \quad (5.3)$$

Burada S, alfa, beta ve delta kurtlarının toplam puanlarını göstermektedir. $f(.)$ uygunluk fonksiyonunu temsil ederken, $w_\alpha, w_\beta, w_\delta$ ağırlık değerlerini göstermektedir. Bu yeni güncellenmiş mekanizma, algoritmanın keşif ve kullanım yeteneklerini geliştirmeye yardımcı olur. Önerilen bu yenilikler bazı problemler üzerinde iyi sonuç gösterse de, bazı durumlar da algoritmanın yine yerel optimal noktada takıldığı gözlemlenmiştir. Bu nedenle, önerilen

güncelleme mekanizması ve doğrusal olmayan geçiş parametresi ile kurtlar için daha iyi konumların bulunamadığı durumlar için algoritmaya bir mutasyon operatörü eklenmiştir.

Orijinal GWO algoritmasının da, güncelleme sonrasında da kurtların konumlarının arama uzayı sınırlarını aşıp aşmadığı kontrol edilmektedir. Gri kurdun yeni konumu üst veya alt sınırları aşar ise sınır koşullarının aşılmaması için gri kurdun konumu sınır değerine eşitlenmektedir. Bu durum keşif aşamasında oldukça yaygındır. Bu nedenle bir çok kurt bazı problemler de arama uzayının sınırlarına takılabilmektedir. Bu durumdan kaçınmak amacıyla yeni bir sınır kontrol mekanizması önerilmiştir. Bu mekanizma da sınır kısıtlaması ihlal edilir ise, gri kurdun yeni konumu, önceki konumu ve arama alanı sınır değerinin tam ortası olacak şekilde ayarlanmıştır. Önerilen bu yeni sınır kontrol prosedürü aşağıdaki gösterilmiştir.


$$if(\vec{X}_i(t) > \vec{U}_b) \Rightarrow \vec{X}_i(t) = \frac{\vec{X}_i(t-1) + \vec{U}_b}{2} \quad (5.4)$$

$$if(\vec{X}_i(t) < \vec{L}_b) \Rightarrow \vec{X}_i(t) = \frac{\vec{X}_i(t-1) + \vec{L}_b}{2} \quad (5.5)$$

$\vec{L}_b$ ve $\vec{U}_b$ alt ve üst sınır değerlerini temsil ederken, t mevcut tekrarlamayı temsil etmektedir. Orijinal GWO algoritmasının da seçim mekanizması bulunmamaktadır. Daha sonraki iterasyonlar da popülasyon da daha uygun olan gri kurtların kullanımı için GWO algoritmasına basit bir seçim mekanizması uygulanmıştır. Bu seçim mekanizması aşağıda verilmiştir.

$$\begin{aligned} if(f(\vec{X}_i(t-1)) < f(\vec{X}_i(t))) \Rightarrow \vec{X}_i(t) &= \vec{X}_i(t-1) \wedge f(\vec{X}_i(t)) \\ &= f(\vec{X}_i(t-1)) \end{aligned} \quad (5.6)$$

Burada $\vec{X}_i(t-1)$ gri kurdun eski konumunu belirtirken, $\vec{X}_i(t)$ gri kurdun güncellenmiş konumunu temsil etmektedir. Tez çalışmasında GWO algoritması ile ilgili en son gelişme alfa, beta ve delta kurtlarının güncelleme mekanizması üzerinedir. Orijinal GWO algoritmasının da konumu güncellenen her bir gri kurdun uygunluk değeri alfa, beta ve delta kurtlarının uygunluk değerleriyle tek tek karşılaştırılarak alfa, beta ve delta kurtlarının konumlarının güncellenmesi gerçekleştirilir. Burada alfa, beta veya delta kurtlarının konumlarını güncelledikten sonra bu kurtların eski konum değerlerinin kullanılmadığı gözlemlenmiştir. Alfa, beta ve delta kurtlarının konumlarının yeni güncellenme mekanizması Şekil 5.3. de gösterilmiştir.



Şekil 5.3. Alfa, Beta ve Delta kurtlarının önerilen yeni güncelleme mekanizması

Kaynak: (Mirjalili vd., 2014: 54)

Şekil 5.3. de omega kurdu konumu güncellenen gri kurdu temsil etmektedir. Orjinal GWO algoritmasından farklı olarak alfa kurdun güncellenmesin de, eğer omega kurdunun uygunluk değeri alfa kurdundan daha iyiye, yeni alfa kurdu omega kurt olmaktadır. Ayrıca eski alfa kurdu, yeni beta kurdu olarak güncellenirken, eski beta kurdu da yeni delta kurdu olarak güncellenmektedir. Aynı şekilde beta kurdunun güncellenmesi sonrasında da, eski beta kurdu yeni delta kurdu olarak değiştirilir. Önerilen MsRwGWO algoritmasının kaba kodu Algoritma 2 de verilmiştir.

Algoritma 2: MsRwGWO algoritmasının kaba kodu

Gri Kurtların konumlarını başlat

Gri Kurtların fitness değerlerini hesapla

En iyi alfa gri kurdunu kaydet

En iyi alfa beta kurdunu kaydet

En iyi delta gri kurdunu kaydet

while (*iterasyon < maksimum iterasyon*)

a parametresini Denklem (10) 'u kullanarak hesapla

for her gri kurt için

Alfa, Beta ve Delta için katsayı vektörlerini üret

Uzaklık vektörlerini hesapla ($\vec{D}_\alpha, \vec{D}_\beta, \vec{D}_\delta$)

Deneme vektörlerini hesapla ($\vec{U}_\alpha, \vec{U}_\beta, \vec{U}_\delta$)

Alfa, Beta, Delta için ağırlık vektörlerini hesapla Denklem (11-12) kullanarak hesapla

Denklem 13'deki toplam ağırlıkları kullanarak gri kurdun pozisyonunu güncelle

Mutasyon operatörünü gri kurda uygula

Denklem (14-15) 'i kullanarak güncellenmiş gri kurt için sınır kontrolü

end for

Güncellenmiş gri kurtlar için uygunluk değerlerini hesapla

for her gri kurt için

if (gri kurt < alfa)

delta $\leftarrow$ beta

beta $\leftarrow$ alfa

alfa kurdunu güncelle

```

    else if (gri kurt < beta)
         $\delta \leftarrow \beta$ 
        beta kurdunu güncelle
    else if (gri kurt < delta)
        delta kurdunu güncelle
    end if
end for
iterasyonu artır
end while
alfaya geri dön

```

5.2. Önerilen MsRwGWO Algoritmasının Analizi ve Karşılaştırmalı Performansı

İlk olarak önerilen MsRwGWO algoritmasının performans analizini yapabilmek için, yakınsama, arama geçmişi, yörünge ve ortalama mesafe olmak üzere farklı metrikler incelenmiştir. Literatür de IEEE Congress on Evolutionary Computation (CEC 2014) olarak bilinen ve sıklıkla kullanılan bazı kıyaslama fonksiyonları kullanılmıştır. MsRwGWO algoritmasının analizi sonrası IEEE Congress on Evolutionary Computation (CEC 2014) test paketine dayanan otuz kıyaslama problemi ele ele alınmıştır (Liang vd., 2013: 490).

Farklı problem boyutları için bu kıyaslama problemleri orijinal GWO algoritması ve MsRwGWO algoritması ile çözülmüş ve sonuçlar istatistiksel olarak karşılaştırılmıştır. Ayrıca önerilen MsRwGWO algoritmasının 30D CEC 2014 test problem sonuçları ile güncel meta-sezgisel algoritmaların sonuçları karşılaştırılarak, geliştirilen yeni algoritmanın üstünlüğü gösterilmiştir. Bu bölümün son alt bölümünde ise, GWO ve MsRwGWO algoritmaları, bir Çok Katmanlı Algılayıcı (MLP) yapısına entegre edilerek kısa vadeli rüzgar hızı tahmini için test edilmiştir.

5.2.1. Önerilen MsRwGWO Algoritmasının Analizi


Tez çalışmamız da, orjinal GWO algoritmasının keşif ve yararlanma yeteneklerinin geliştirilmesi amacı ile MsRwGWO algoritması yeni bir yaklaşım olarak ortaya çıkmıştır. MsRwGWO algoritmasının yakınsama davranışını gösterebilmek birbirinden farklı dört metrik analizi üzerin de düşünülmüştür. Bunlar birinci olarak yakınsama analizi, ikinci olarak arama geçmişi analizi, üçüncü olarak yörünge analizi ve son olarak da ortalama mesafe analizidir. Bu analizleri gerçekleştirmek için CEC 2014 kıyaslama problemleri arasından dört

farklı kıyaslama işlevi seçilmiştir. CEC 2014 test paketi, tek modlu, basit çok modlu, hibrit ve kompozisyon türün de olmak üzere dört farklı problem yapısı içermektedir. Tablo 5.1. de, bu kıyaslama işlevleri ve isimleri özetlenmektedir (Liang vd., 2014: 627).

Analiz için kullanılan fonksiyonlar Tablo 5.1. de verilmiştir. Bunlar tek modlu fonksiyonlardan döndürülmüş bükülmüş puro (FN2) fonksiyonu, kaydırılmış ve döndürülmüş Weierstrass (FN6) fonksiyonu, basit çok modlu fonksiyonlardan kaydırılmış, döndürülmüş ve genişletilmiş Scaffer (FN16) fonksiyonu ve (FN23) kompozisyon fonksiyonlarıdır. Şekil 5.4. de önerilen MsRwGWO algoritmasının analizlerin de kullanılan kıyaslama fonksiyonları gösterilmektedir. Her alt şekil yapılan bu işlevlerin 2B'si için 3B haritaları ve kontur çizgilerini içermektedir. Önemli bir not olarak söylemek gerekirse GWO ve MsRwGWO algoritmalarındaki tüm analizler için gri kurtların başlangıç konumları eşit olarak alınmıştır.

Tablo 5.1. CEC 2014 karşılaştırma fonksiyonları

No	Fonksiyon Adı	Çözüm	No	Fonksiyon Adı	Çözüm
FN1	Döndürülmüş Yüksek Koşullu Eliptik	100	FN16	Kaydırılmış, Döndürülmüş ve Genişletilmiş Scaffer F6	1600
FN2	Döndürülmüş Bent Puro	200	FN17	Hibrit Fonksiyon 1 (N = 3)	1700
FN3	Döndürülmüş Disk	300	FN18	Hibrit Fonksiyon 2 (N = 3)	1800
FN4	Kaydırılmış ve Döndürülmüş Rosenbrock	400	FN19	Hibrit Fonksiyon 3 (N = 4)	1900
FN5	Kaydırılmış ve Döndürülmüş Ackley	500	FN20	Hibrit Fonksiyon 4 (N = 4)	2000
FN6	Kaydırılmış ve Döndürülmüş Weierstrass	600	FN21	Hibrit Fonksiyon 5 (N = 5)	2100
FN7	Kaydırılmış ve Döndürülmüş Griewank	700	FN22	Hibrit Fonksiyon 6 (N = 5)	2200
FN8	Kaydırılmış Rastrigin	800	FN23	Kompozisyon Fonksiyonu 1 (N = 5)	2300
FN9	Kaydırılmış ve Döndürülmüş Rastrigin	900	FN24	Kompozisyon Fonksiyonu 2 (N = 3)	2400
FN10	Kaydırılmış Schwefel	1000	FN25	Kompozisyon Fonksiyonu 3 (N = 3)	2500
FN11	Kaydırılmış ve Döndürülmüş Schwefel	1100	FN26	Kompozisyon Fonksiyonu 4 (N = 5)	2600
FN12	Kaydırılmış ve Döndürülmüş Katsuura	1200	FN27	Kompozisyon Fonksiyonu 5 (N = 5)	2700
FN13	Kaydırılmış ve Döndürülmüş HappyCat	1300	FN28	Kompozisyon Fonksiyonu 6 (N = 5)	2800
FN14	Kaydırılmış ve Döndürülmüş GHBat	1400	FN29	Kompozisyon Fonksiyonu 7 (N = 3)	2900
FN15	Genişletilmiş F4 artı F7	1500	FN30	Kompozisyon Fonksiyonu 8 (N = 3)	3000




Şekil 5.4. Önerilen MsRwGWO algoritmasının analizi için kullanılan fonksiyonlar

5.2.1.1. Yakınsama Analizi

Bir metasezgisel algoritmanın performansı, bir optimizasyon probleminin çözümün de meydana gelen yakınsama davranışına bağlıdır. Yakınsama davranışı bize algoritmanın hızı hakkında bilgi vermektedir. Bu kapsam da dört farklı kıyaslama probleminin çözümü için önerilen MsRwGWO algoritması ve orjinal GWO algoritmasının yakınsama eğrileri elde edilmiştir. Bu analizde problem boyutu 2 olarak alınmıştır. Şekil 5.5. de her iki algoritmanın yakınsama davranışlarının karşılaştırma sonuçları gösterilmiştir. Bu eğriler, optimizasyon boyunca MsRwGWO ve GWO algoritmaları tarafından bulunan en iyi gri kurtların hata değerlerini göstermektedir. Burada en iyi bulunan çözüm ile problemin gerçek çözümü arasındaki fark alınarak bu hata değerleri hesaplanır. Şekil 5.4. de orijinal GWO ve MsRwGWO algoritmalarının yakınsama eğrileri logaritmik ölçek de verilmiştir. Yakınsama eğrilerindeki eğilimlere bakıldığında problemin çözümün de MsRwGWO algoritmasının GWO algoritmasına göre daha hızlı yakınsadığı görülmektedir. Analiz sonuçları, önerilen


MsRwGWO algoritmasının global optimuma daha yakın bir çözüm bulma yeteneğini göstermektedir.



Şekil 5.5. MsRwGWO algoritması için yakınsama analizleri

5.2.1.2. Arama Geçmişi Analizi

Bu analiz de, optimizasyon probleminin çözümü sırasında arama ajanlarının (gri kurtların) arama uzayındaki hareketlerini veren arama geçmişi incelenmiştir. Şekil 5.6. da, GWO ve MsRwGWO algoritmaları ile elde edilen gri kurtların arama geçmişi sonuçları, CEC 2014 test takımından seçilen kıyaslama fonksiyonları için gösterilmiştir. Her iki algoritmanın da bu analizleri, tüm fonksiyonlar için ilk gri kurdun başlangıç pozisyonları (başlangıç popülasyonu) aynı kalmak şartı ile alınarak yapılmıştır. Güncellenen gri kurtların konumları, tekrarlanan her 100 adımın da kıyaslama işlevlerinin kontur yüzeylerin de gösterilmiştir. Arama geçmişi analizinde gri kurt sayısı 20 olarak kullanılmıştır.




Şekil 5.6. MsRwGWO ve GWO algoritmalarının arama geçmişi analizleri


Analizin sonuçları, MsRwGWO algoritması tarafından güncellenen gri kurtların, global optimum etrafındaki dağılımının, keşif ve sömürü aşamaların da arama uzayın da GWO algoritması tarafından güncellenen gri kurtların dağılımından daha yüksek olduğunu göstermektedir. Dolayısıyla MsRwGWO algoritmasının keşif ve işletme aşamaların da arama uzayının en umut verici alanlarını araştırdığını söylemek mümkündür. GWO algoritması tarafından bulunan gri kurtların konumlarının, FN6 test problemi dışın da özellikle benchmark problemlerinin yüzeylerin de arama uzayının sınır değerlerine takıldığı görülmektedir. Bunun nedeni, keşif aşamasında sınır değerlerini aşan gri kurtların sınır değerleri üzerin de konumlandırılmasıdır. Önerilen sınır kontrol mekanizması sayesinde bu sorunlar önerilen MsRwGWO algoritması sonuçlarında görünmemektedir.

5.2.1.3. Yörünge Analizi


Bu analiz de, optimizasyon probleminin çözümü sırasın da problemin arama uzayın da her iterasyon da en iyi gri kurdun (alfa kurd) konumunun nasıl değiştiği incelenmiştir. Seçilen kıyaslama fonksiyonları için yörünge analizinin sonuçları Şekil 5.7.-5.10. de gösterilmektedir. Her şekil de iki grafik bulunmaktadır. Bunlardan birincisi, optimizasyon işlemi sırasın da alfa gri kurdun (elit adayı) arama alanının kontur yüzeyinde bulunan pozisyonundaki değişiklikleri vermektedir. Grafiklerin ikincisi ise alfa gri kurdunun konumunu iki boyut için ayrı ayrı göstermektedir.




Şekil 5.7. FN2 fonksiyonu için alfa gri kurdunun konum analizi (◇: GWO. □ : MsRwGWO)



Şekil 5.8. FN6 fonksiyonu için alfa gri kurdunun konum analizi (◇: GWO. □ : MsRwGWO)



Şekil 5.9. FN16 fonksiyonu için alfa gri kurdunun konum analizi (◇: GWO. □ : MsRwGWO)




Şekil 5.10. FN23 fonksiyonu için alfa gri kurdunun konum analizi (◇: GWO. □ : MsRwGWO)

Analiz sonuçlarını içeren Şekil 5.7.-5.10. de şekillerin sağındaki grafikler de kırmızı işaretler, optimizasyon sonunda her iki algoritma tarafından elde edilen en iyi alfa gri kurtlarının konumlarını göstermektedir. FN2, FN6 ve FN16 kıyaslama problemlerinin yörünge analizi sonuçlarına bakıldığında, optimizasyon süreci sonunda GWO ve MsRwGWO algoritmaları ile elde edilen alfa kurtlarının konumlarının, global optimuma çok yakın ve yaklaşık olarak aynı olduğu görülmüştür. FN2 kıyaslama probleminin analizinde alfa kurtlarının konum değişiklikleri her iki algoritma için farklı eğilimler gösterse de optimizasyon sonunda alfa kurtlarının konumlarının birbirine çok yakın olduğu sonucu elde edilmiştir.

GWO ve MsRwGWO algoritmaları arasındaki yörünge analizinin tek farklı sonucu FN23 kıyaslama probleminde görülmektedir. Bu fonksiyon da optimizasyon sürecinin sonunda iki farklı elit çözüm ile karşılaşılmıştır. GWO algoritması, küresel optimuma yakın bir alfa kurdu (en iyi aday) bulamadığından, bu kıyaslama problemi için yerel minimum da takılı kalmaktadır. Önerilen MsRwGWO algoritması, FN23 kıyaslamasının global optimumuna daha yakın bir elit arama ajanı olarak bir alfa kurdu sunmuştur. Kısacası MsRwGWO algoritmasının bu analizine göre, alfa kurdunun konumu keşif aşamasında daha hızlı güncellenir ve sömürü aşamasında global optimuma yaklaşır sonucu çıkarılmıştır.

5.2.1.4. Ortalama Mesafe Analizi

Ortalama mesafe analizi, optimizasyon işlemi sırasında ilk gri kurdun gruptaki diğer gri kurtlara olan konumunun ortalama mesafesini vermektedir. Bu durum MsRwGWO algoritmasının keşfedici veya sömürücü davranışlarını göstermektedir. Şekil 5.11. de seçilen kıyaslamalar için önerilen MsRwGWO algoritması ve GWO algoritmasının ortalama mesafe analizi sonuçlarını göstermektedir. MsRwGWO algoritmasının analiz sonucundan da anlaşılacağı gibi, gri kurtların ortalama mesafe eğilimleri, GWO algoritmasına eklenen seçim mekanizması ve alfa kurdunun yeni güncelleme mekanizması sayesinde GWO algoritmasına göre daha az salınım ve dalgalanmaya sahiptir. Alfa, beta ve delta kurtları FN23 ve FN2 kıyaslama problemlerinin analiz sonuçlarına bakıldığında, algoritmanın keşif aşamasında MsRwGWO algoritmasının ortalama mesafe eğrisinde artış gösteren kısımlar da problemin yerel optimum noktalarından başarılı bir şekilde kaçındığı anlaşılmaktadır. Bunun nedeni, GWO algoritmasına eklenen mutasyon operatörü ve yeni gri kurt güncelleme mekanizmasıdır.




Şekil 5.11. Gri kurtlar arasındaki ortalama mesafe analizi


5.2.2. CEC 2014 Kıyaslama Fonksiyonları İçin MsRwGWO ve GWO Algoritmalarının Karşılaştırılması

Önerilen MsRwGWO algoritmasının performansını değerlendirmek için, literatür de algoritmaların kıyaslanması da sıklıkla kullanılan CEC 2014 test takımı olarak bilinen bazı sayısal optimizasyon problemleri kullanılmıştır. CEC 2014 test paketi, minimizasyon sorunları olan otuz kıyaslama işlevini içinde barındırmaktadır. Bu kıyaslama işlevleri dört gruba ayrılır. Bunlar tek modlu (FN1-FN3), basit çok modlu (FN4-FN16), hibrit (FN17-FN22) ve kompozisyon (FN23-FN30) işlevleridir. Belirli problem boyutlarına (10D, 30D ve 50D) sahip tüm optimizasyon kıyaslama testi problemleri, orjinal GWO algoritması ve önerilen MsRwGWO algoritması kullanılarak 51 bağımsız çalışma için çözülmüştür. Benchmark testlerinde popülasyon boyutunu boyut sayısının 10 katı ve maksimum iterasyon sayısı 1000 olarak kullanılmıştır. Optimizasyon problemlerinin çözümünde maksimum iterasyon sayısına ulaşmak için sonlandırma kriterini kullanılması tercih edilmiştir. GWO ve MsRwGWO algoritmalarının kodları Intel(R) Core(TM) i7-6500U CPU@2.50 GHz ve 8 GB RAM'li PC üzerinde çalıştırılmıştır. CEC 2014 test problemlerinin çözümünde, her bir

çalıştırma da her fonksiyon için 14 hata değeri kaydedilmiştir. Şekil 5.12. da her iki algoritma için 10D ile bazı kıyaslamaların en iyi yakınsama eğrileri sunulmuştur. Farklı özelliklere sahip kıyaslama testlerinden sadece ikisinde (F7 ve F29), GWO algoritması optimizasyon sonunda daha iyi bir sonuç bulabilmiştir. Bu eğrilerden, önerilen MsRwGWO algoritmasının açıkça daha iyi bir yakınsamaya sahip olduğu görülebilir. Grafik 5.13. da 51 çalışmanın sonunda MsRwGWO algoritması ile elde edilen en iyi, en kötü ve ortalama yakınsama eğrileri gösterilmektedir. Bu sonuçlar, MsRwGWO algoritmasının en iyi ve en kötü yakınsama eğrilerinin ortalamaya yakın olduğunu yani standart sapmasının düşük olduğunu göstermektedir. Bu durum önerilen algoritmanın problemleri kararlı bir şekilde çözebileceğini ortaya koymaktadır. Karşılaştırma sonuçların da ortalama, en kötü, en iyi, medyan ve standart sapma olmak üzere beş metrik değerlendirilmiştir. Tablo 5.2.-5.4. de GWO ve MsRwGWO algoritmalarının, CEC2014 kıyaslama problemleri için istatistiksel sonuçları sırasıyla 10D, 30D ve 50D olarak verilmiştir. Bu tablolar da metrikler arasın da en iyi sonuçlar kalın harflerle vurgulanmıştır.



Şekil 5.12. GWO ve MsRwGWO algoritmaları için 10D en iyi kıyaslama sonuçlarının yakınsama eğrileri



Şekil 5.13. MsRwGWO algoritmasının 10D Yakınsama eğrileri (En İyi, En Kötü, Ortalama)

Tablo 5.2. GWO ve MsRwGWO algoritmaları için 10D CEC 2014 karşılaştırma sonuçları

No	GWO					MsRwGWO				
	En iyi	En kötü	Medyan	Ortalama	Std	En iyi	En kötü	Medyan	Ortalama	Std
1	8.32E+05	1.70E+07	4.29E+06	4.94E+06	3.39E+06	4.38E+05	6.99E+06	1.27E+06	1.74E+06	1.28E+06
2	2.03E+07	1.29E+08	7.06E+08	7.35E+08	2.19E+08	1.52E+07	1.27E+08	7.74E+07	7.23E+07	2.26E+07
3	5.51E+02	9.27E+03	1.84E+03	3.06E+03	2.43E+03	3.58E+02	1.57E+03	8.18E+02	8.40E+02	2.55E+02
4	1.07E+01	4.02E+01	3.63E+01	3.37E+01	7.86E+00	9.57E+00	3.82E+01	3.70E+01	3.26E+01	9.46E+00
5	1.03E+01	2.05E+01	2.04E+01	1.97E+01	2.19E+00	2.02E+01	2.05E+01	2.04E+01	2.04E+01	7.99E-02
6	2.29E+00	6.23E+00	3.40E+00	3.55E+00	8.31E-01	2.21E+00	5.52E+00	3.19E+00	3.38E+00	7.39E-01
7	1.45E+00	5.54E+00	3.04E+00	3.25E+00	9.26E-01	1.90E+00	4.42E+00	2.84E+00	2.86E+00	4.93E-01
8	1.29E+01	3.26E+01	1.82E+01	1.92E+01	4.21E+00	1.52E+01	3.41E+01	2.28E+01	2.25E+01	3.79E+00
9	1.42E+01	4.03E+01	2.28E+01	2.30E+01	4.57E+00	1.78E+01	3.54E+01	2.50E+01	2.48E+01	3.98E+00
10	1.66E+02	8.21E+02	3.72E+02	4.04E+02	1.43E+02	1.12E+02	1.01E+03	4.22E+02	4.53E+02	2.00E+02
11	2.39E+02	1.25E+03	7.10E+02	7.18E+02	2.50E+02	4.01E+02	1.50E+03	7.59E+02	7.93E+02	2.42E+02
12	5.59E-01	1.53E+00	1.13E+00	1.08E+00	2.34E-01	5.97E-01	1.63E+00	1.21E+00	1.17E+00	2.13E-01
13	1.88E-01	4.70E-01	3.27E-01	3.16E-01	6.78E-02	1.95E-01	4.23E-01	2.88E-01	2.89E-01	5.03E-02
14	1.44E-01	8.51E-01	2.64E-01	3.27E-01	1.92E-01	1.16E-01	3.26E-01	2.23E-01	2.22E-01	4.92E-02
15	2.10E+00	5.65E+00	3.36E+00	3.43E+00	6.82E-01	1.98E+00	4.39E+00	3.44E+00	3.35E+00	5.76E-01
16	1.93E+00	3.41E+00	2.55E+00	2.62E+00	3.05E-01	1.93E+00	3.23E+00	2.60E+00	2.60E+00	2.73E-01
17	1.45E+03	2.69E+04	5.48E+03	7.20E+03	4.78E+03	1.33E+03	1.09E+04	4.28E+03	5.18E+03	2.48E+03
18	1.56E+02	2.55E+04	6.46E+03	8.59E+03	6.94E+03	6.76E+02	2.52E+04	5.90E+03	7.16E+03	5.63E+03
19	2.12E+00	5.59E+00	3.11E+00	3.34E+00	7.68E-01	1.99E+00	5.12E+00	2.96E+00	3.07E+00	5.90E-01
20	3.90E+01	1.12E+04	2.06E+03	3.11E+03	3.55E+03	7.31E+01	4.04E+02	1.61E+02	1.71E+02	7.41E+01
21	1.03E+03	1.22E+04	5.29E+03	5.93E+03	3.80E+03	7.60E+02	1.29E+04	2.61E+03	4.01E+03	3.16E+03
22	2.51E+01	1.71E+02	4.52E+01	6.20E+01	4.56E+01	2.80E+01	1.74E+02	4.53E+01	6.30E+01	4.68E+01
23	3.30E+02	3.37E+02	3.31E+02	3.32E+02	1.94E+00	3.30E+02	3.32E+02	3.31E+02	3.31E+02	4.67E-01
24	1.22E+02	2.04E+02	1.31E+02	1.36E+02	1.77E+01	1.20E+02	2.03E+02	1.32E+02	1.33E+02	1.15E+01
25	1.50E+02	2.03E+02	2.01E+02	2.00E+02	7.32E+00	1.31E+02	2.02E+02	2.00E+02	1.82E+02	2.63E+01
26	1.00E+02	1.00E+02	1.00E+02	1.00E+02	5.03E-02	1.00E+02	1.00E+02	1.00E+02	1.00E+02	5.53E-02
27	2.82E+00	4.31E+02	3.92E+02	3.35E+02	1.44E+02	4.11E+00	4.11E+02	3.91E+02	3.11E+02	1.62E+02
28	3.87E+02	6.02E+02	4.64E+02	4.56E+02	5.66E+01	3.84E+02	5.22E+02	4.54E+02	4.52E+02	5.07E+01
29	3.41E+02	2.13E+06	8.40E+02	2.30E+05	6.36E+05	3.85E+02	2.41E+06	9.30E+02	1.25E+05	5.05E+05
30	5.07E+02	2.80E+03	1.01E+03	1.19E+03	5.38E+02	6.30E+02	2.80E+03	1.23E+03	1.31E+03	5.50E+02

Tablo 5.3. GWO ve MsRwGWO algoritmaları için 30D CEC 2014 karşılaştırma sonuçları

No	GWO					MsRwGWO				
	En iyi	En kötü	Medyan	Ortalama	Std	En iyi	En kötü	Medyan	Ortalama	Std
1	2.61E+07	1.16E+08	5.68E+07	5.65E+07	2.12E+07	2.95E+07	9.09E+07	5.26E+07	5.53E+07	1.27E+07
2	2.09E+09	4.55E+09	3.02E+09	3.13E+09	5.55E+08	2.27E+09	4.13E+09	2.94E+09	2.97E+09	3.63E+08
3	9.26E+03	3.99E+04	2.20E+04	2.14E+04	5.94E+03	6.29E+03	1.29E+04	9.21E+03	9.30E+03	1.67E+03
4	1.83E+02	4.88E+02	2.59E+02	2.65E+02	4.95E+01	2.05E+02	3.13E+02	2.54E+02	2.56E+02	2.27E+01
5	2.08E+01	2.10E+01	2.10E+01	2.09E+01	5.43E-02	2.08E+01	2.11E+01	2.10E+01	2.10E+01	5.39E-02
6	1.80E+01	2.73E+01	2.17E+01	2.21E+01	1.81E+00	1.78E+01	2.44E+01	2.03E+01	2.03E+01	1.29E+00
7	2.11E+01	6.64E+01	2.96E+01	3.01E+01	6.58E+00	1.84E+01	3.34E+01	2.59E+01	2.57E+01	3.19E+00
8	1.08E+02	2.00E+02	1.34E+02	1.36E+02	1.52E+01	1.36E+02	2.17E+02	1.68E+02	1.68E+02	1.50E+01
9	1.41E+02	2.19E+02	1.95E+02	1.92E+02	1.57E+01	1.63E+02	2.24E+02	1.98E+02	1.97E+02	1.17E+01
10	2.51E+03	4.64E+03	3.51E+03	3.51E+03	5.10E+02	3.47E+03	6.08E+03	4.85E+03	4.74E+03	5.79E+02
11	4.14E+03	6.89E+03	5.91E+03	5.79E+03	6.90E+02	5.54E+03	7.20E+03	6.60E+03	6.48E+03	3.76E+02
12	1.65E+00	2.89E+00	2.50E+00	2.40E+00	3.04E-01	1.78E+00	2.87E+00	2.45E+00	2.46E+00	2.35E-01
13	5.43E-01	8.96E-01	6.96E-01	6.99E-01	6.90E-02	5.44E-01	8.38E-01	6.40E-01	6.53E-01	6.57E-02
14	1.83E+00	1.55E+01	6.47E+00	6.67E+00	2.93E+00	1.71E+00	8.88E+00	4.26E+00	4.52E+00	1.98E+00
15	2.94E+01	1.40E+02	3.93E+01	4.18E+01	1.53E+01	2.92E+01	6.35E+01	3.55E+01	3.68E+01	5.51E+00
16	1.09E+01	1.25E+01	1.18E+01	1.17E+01	3.17E-01	1.12E+01	1.25E+01	1.19E+01	1.19E+01	3.06E-01
17	4.50E+05	5.88E+06	1.16E+06	1.40E+06	9.51E+05	3.68E+05	3.85E+06	1.31E+06	1.46E+06	6.89E+05
18	8.36E+06	7.09E+07	2.23E+07	2.57E+07	1.54E+07	4.70E+06	5.68E+07	2.18E+07	2.44E+07	1.19E+07
19	2.24E+01	7.67E+01	2.87E+01	3.09E+01	8.73E+00	2.21E+01	3.57E+01	2.76E+01	2.79E+01	3.21E+00
20	1.60E+03	1.83E+04	9.71E+03	9.83E+03	4.39E+03	8.23E+02	3.50E+03	1.66E+03	1.76E+03	6.16E+02
21	1.33E+05	1.66E+06	3.69E+05	5.12E+05	3.89E+05	1.16E+05	1.12E+06	3.22E+05	4.00E+05	2.31E+05
22	2.49E+02	7.78E+02	3.68E+02	4.11E+02	1.34E+02	2.17E+02	7.23E+02	4.72E+02	4.52E+02	1.31E+02
23	3.24E+02	3.57E+02	3.30E+02	3.31E+02	4.90E+00	3.22E+02	3.31E+02	3.26E+02	3.26E+02	2.03E+00
24	2.00E+02	2.00E+02	2.00E+02	2.00E+02	0.00E+00	2.00E+02	2.00E+02	2.00E+02	2.00E+02	0.00E+00
25	2.06E+02	2.17E+02	2.12E+02	2.11E+02	2.56E+00	2.00E+02	2.14E+02	2.10E+02	2.10E+02	2.41E+00
26	1.01E+02	1.01E+02	1.01E+02	1.01E+02	8.20E-02	1.01E+02	2.01E+02	1.01E+02	1.10E+02	3.00E+01
27	4.21E+02	9.81E+02	8.54E+02	7.78E+02	1.89E+02	4.23E+02	9.37E+02	7.97E+02	7.23E+02	1.85E+02
28	1.04E+03	2.27E+03	1.17E+03	1.25E+03	2.38E+02	1.13E+03	1.56E+03	1.22E+03	1.24E+03	7.46E+01
29	2.00E+05	1.31E+06	4.87E+05	5.56E+05	2.82E+05	3.10E+05	2.00E+06	7.70E+05	9.39E+05	4.99E+05
30	1.37E+04	1.48E+05	4.14E+04	4.35E+04	2.22E+04	1.67E+04	8.62E+04	3.85E+04	4.37E+04	1.71E+04

Tablo 5.4. GWO ve MsRwGWO algoritmaları için 50D CEC 2014 karşılaştırma sonuçları

No	GWO					MsRwGWO				
	En iyi	En kötü	Medyan	Ortalama	Std	En iyi	En kötü	Medyan	Ortalama	Std
1	6.90E+07	2.33E+08	1.23E+08	1.29E+08	2.96E+07	8.36E+07	2.27E+08	1.30E+08	1.36E+08	3.02E+07
2	7.83E+09	1.57E+10	1.07E+10	1.10E+10	1.86E+09	6.64E+09	1.22E+10	9.63E+09	9.66E+09	1.03E+09
3	2.01E+04	7.61E+04	4.17E+04	4.16E+04	1.07E+04	1.80E+04	3.18E+04	2.40E+04	2.42E+04	3.23E+03
4	5.51E+02	1.77E+03	8.25E+02	8.59E+02	2.06E+02	5.57E+02	1.13E+03	7.44E+02	7.65E+02	1.14E+02
5	2.11E+01	2.12E+01	2.11E+01	2.11E+01	3.29E-02	2.10E+01	2.12E+01	2.11E+01	2.11E+01	4.65E-02
6	3.75E+01	4.97E+01	4.35E+01	4.37E+01	2.57E+00	3.54E+01	4.71E+01	4.14E+01	4.16E+01	2.53E+00
7	6.60E+01	1.32E+02	8.71E+01	8.93E+01	1.32E+01	6.34E+01	1.07E+02	7.94E+01	8.11E+01	9.00E+00
8	2.60E+02	3.89E+02	3.24E+02	3.26E+02	2.39E+01	3.30E+02	4.17E+02	3.75E+02	3.75E+02	2.17E+01
9	3.69E+02	4.39E+02	4.04E+02	4.04E+02	1.91E+01	3.50E+02	4.50E+02	4.03E+02	4.03E+02	1.96E+01
10	6.97E+03	1.03E+04	8.71E+03	8.79E+03	7.07E+02	8.24E+03	1.27E+04	1.10E+04	1.10E+04	9.74E+02
11	1.05E+04	1.32E+04	1.21E+04	1.20E+04	6.76E+02	1.18E+04	1.35E+04	1.28E+04	1.28E+04	4.26E+02
12	2.19E+00	3.86E+00	3.28E+00	3.26E+00	3.12E-01	2.61E+00	3.82E+00	3.34E+00	3.28E+00	2.85E-01
13	7.52E-01	1.37E+00	9.79E-01	9.82E-01	1.11E-01	7.39E-01	1.17E+00	9.20E-01	9.14E-01	7.79E-02
14	1.80E+01	3.91E+01	2.41E+01	2.44E+01	4.19E+00	1.65E+01	2.64E+01	2.08E+01	2.11E+01	2.12E+00
15	1.17E+02	3.08E+03	5.07E+02	6.89E+02	5.86E+02	1.45E+02	6.09E+02	2.87E+02	3.06E+02	1.03E+02
16	2.03E+01	2.20E+01	2.12E+01	2.12E+01	4.12E-01	2.06E+01	2.20E+01	2.14E+01	2.14E+01	3.21E-01
17	2.34E+06	1.30E+07	6.83E+06	7.03E+06	2.79E+06	3.51E+06	1.28E+07	7.50E+06	7.43E+06	2.30E+06
18	1.24E+08	3.80E+08	2.19E+08	2.16E+08	4.56E+07	9.43E+07	3.61E+08	2.24E+08	2.24E+08	5.65E+07
19	7.02E+01	1.14E+02	9.72E+01	9.54E+01	1.07E+01	6.68E+01	1.12E+02	9.05E+01	9.05E+01	1.42E+01
20	2.20E+03	2.40E+04	1.07E+04	1.14E+04	4.81E+03	1.97E+03	6.93E+03	3.44E+03	3.52E+03	9.01E+02
21	1.00E+06	5.95E+06	2.46E+06	2.59E+06	1.11E+06	9.27E+05	6.66E+06	2.11E+06	2.46E+06	1.15E+06
22	6.20E+02	2.08E+03	1.32E+03	1.33E+03	3.02E+02	9.92E+02	1.86E+03	1.48E+03	1.48E+03	2.06E+02
23	4.05E+02	4.92E+02	4.38E+02	4.44E+02	1.90E+01	3.94E+02	4.55E+02	4.25E+02	4.24E+02	1.22E+01
24	2.00E+02	2.00E+02	2.00E+02	2.00E+02	0.00E+00	2.00E+02	2.00E+02	2.00E+02	2.00E+02	5.05E-02
25	2.19E+02	2.43E+02	2.29E+02	2.29E+02	4.94E+00	2.19E+02	2.39E+02	2.31E+02	2.30E+02	4.03E+00
26	1.01E+02	3.91E+02	2.00E+02	1.56E+02	6.05E+01	1.01E+02	2.10E+02	2.03E+02	1.76E+02	4.67E+01
27	1.32E+03	1.64E+03	1.45E+03	1.45E+03	6.00E+01	1.24E+03	1.54E+03	1.40E+03	1.40E+03	6.80E+01
28	1.90E+03	4.27E+03	2.27E+03	2.49E+03	6.04E+02	2.16E+03	4.58E+03	2.44E+03	2.57E+03	4.01E+02
29	4.00E+06	2.93E+07	7.90E+06	8.93E+06	4.12E+06	6.30E+06	2.72E+07	1.41E+07	1.44E+07	4.89E+06
30	8.69E+04	3.71E+05	2.04E+05	2.07E+05	6.85E+04	1.45E+05	5.80E+05	2.56E+05	2.74E+05	8.29E+04

CEC 2014 kıyaslama fonksiyonlarının çoğunluğun da tüm problem boyutların da önerilen MsRwGWO algoritması, tüm istatistiksel metrikler açısından orijinal GWO algoritmasından daha iyi performans göstermiştir. Tüm bu istatistiksel sonuçları daha iyi gösterebilmek için Tablo 5.5. de tüm problem boyutları için bir özet verilmiştir. Bu özet sonuç tablosundan da görüleceği üzere MsRwGWO algoritması, en iyi hata metriğine göre 30 ve 50 problem boyutunda GWO algoritmasından %53,33 daha iyi sonuçlar elde etmiştir. Burada dikkat edilecek önemli bir göstergede MsRwGWO algoritmasının tüm boyutlar için başarı oranı (10D için %70, 30D için %76,67 ve 50D için %70), en kötü hata metriğin de GWO algoritmasından çok daha yüksek oluşudur. Ortalama hata metriği özet sonuçları bize problem boyutu artarken önerilen MsRwGWO algoritmasının GWO algoritması ile aynı performansa sahip olduğunu göstermektedir (her iki algoritma da 50D için %50 başarılıdır). 10D ve 30D için önerilen MsRwGWO algoritması, GWO algoritmasından sırasıyla %70 ve %60 daha iyi sonuçlar sağlamıştır. Son olarak tüm metriklerin toplamına bakıldığında MsRwGWO algoritmasının 10D için %64.67, 30D için %70 ve 50D için %58 başarı oranına sahip olduğu anlaşılmaktadır.

Tablo 5.5. GWO ve MsRwGWO algoritmaları için CEC 2014 karşılaştırmalarının özet sonuçları

	GWO			MsRwGWO		
	<i>10D</i>	<i>30D</i>	<i>50D</i>	<i>10D</i>	<i>30D</i>	<i>50D</i>
En iyi	50.00%	46.67%	46.67%	50.00%	53.33%	53.33%
En kötü	30.00%	23.33%	30.00%	70.00%	76.67%	70.00%
Medyan	43.33%	30.00%	46.67%	56.67%	70.00%	53.33%
Ortalama	30.00%	40.00%	50.00%	70.00%	60.00%	50.00%
Std	23.33%	10.00%	36.67%	76.67%	90.00%	63.33%
Total	35.33%	30.00%	42.00%	64.67%	70.00%	58.00%

GWO ve MsRwGWO algoritmaları arasındaki karşılaştırmaya ek olarak, önerilen MsRwGWO algoritması popüler ve son teknoloji meta-sezgisel algoritmalar ile de karşılaştırılmıştır. Bu karşılaştırma çalışmasının da Güve-Alev Optimizasyon (MFO) algoritması (Mirjalili, 2015: 230), Parçacık Sürü Optimizasyon (PSO) algoritması (Kennedy ve Eberhart, 1995: 1943), Yusufçuk Optimizasyon algoritması (DA) (Mirjalili, 2016: 1054), Sinüs Kosinüs Algoritması (SCA) (Mirjalili, 2016: 121) ve Balina Optimizasyon Algoritması (WOA) (Mirjalili ve Lewis, 2016: 52) kullanılmıştır. Seçilen algoritmaların parametreleri

kendi orjinal makalelerin de kullanılan parametrelere göre ayarlanmıştır. Tablo 5.6. da, 30D CEC 2014 kıyaslama fonksiyonları için karşılaştırma sonuçları özetlenmiştir.

Tablo 5.6. 30D CEC2014 problemleri için MsRwGWO ve diğer algoritmaların karşılaştırma

No		MFO	PSO	DA	SCA	WOA	MsRwGWO
1	<i>Ortalama</i>	7.59E+07	8.19E+07	4.49E+08	2.24E+08	3.24E+07	5.53E+07
	<i>Std</i>	9.77E+07	8.27E+09	3.88E+08	7.18E+07	1.42E+07	1.27E+07
	<i>Sıralama</i>	3	4	6	5	1	2
2	<i>Ortalama</i>	1.36E+10	2.81E+04	3.67E+10	1.60E+10	5.05E+06	2.97E+09
	<i>Std</i>	8.42E+09	5.30E+02	1.55E+10	3.12E+09	4.79E+06	3.63E+08
	<i>Sıralama</i>	4	1	6	5	2	3
3	<i>Ortalama</i>	8.99E+04	2.09E+01	1.81E+05	3.79E+04	2.97E+04	9.30E+03
	<i>Std</i>	4.98E+04	2.77E+01	9.61E+04	7.28E+03	2.10E+04	1.67E+03
	<i>Sıralama</i>	5	1	6	4	3	2
4	<i>Ortalama</i>	1.14E+03	9.01E+03	4.86E+03	1.02E+03	1.76E+02	2.56E+02
	<i>Std</i>	1.13E+03	1.85E+02	3.72E+03	2.04E+02	4.70E+01	2.27E+01
	<i>Sıralama</i>	4	6	5	3	1	2
5	<i>Ortalama</i>	2.04E+01	2.19E+02	2.08E+01	2.09E+01	2.04E+01	2.10E+01
	<i>Std</i>	1.75E-01	6.01E+03	1.17E-01	5.00E-02	1.80E-01	5.39E-02
	<i>Sıralama</i>	1	5	2	3	1	4
6	<i>Ortalama</i>	2.40E+01	6.78E+03	3.72E+01	3.44E+01	3.48E+01	2.03E+01
	<i>Std</i>	3.33E+00	2.46E+00	3.71E+00	2.61E+00	3.61E+00	1.29E+00
	<i>Sıralama</i>	2	6	5	3	4	1
7	<i>Ortalama</i>	1.17E+02	1.61E+00	3.54E+02	1.33E+02	1.03E+00	2.57E+01
	<i>Std</i>	6.91E+01	2.67E+01	1.59E+02	2.91E+01	5.00E-02	3.19E+00
	<i>Sıralama</i>	4	2	6	5	1	3
8	<i>Ortalama</i>	1.43E+02	1.10E+03	2.89E+02	2.36E+02	1.76E+02	1.68E+02
	<i>Std</i>	3.81E+01	1.24E+01	4.77E+02	2.08E+01	3.73E+01	1.50E+01
	<i>Sıralama</i>	1	6	5	4	3	2
9	<i>Ortalama</i>	2.23E+02	2.30E+06	3.01E+02	2.67E+02	2.13E+02	1.97E+02
	<i>Std</i>	6.06E+01	8.06E+07	6.73E+01	2.04E+01	5.22E+01	1.17E+01
	<i>Sıralama</i>	3	6	5	4	2	1
10	<i>Ortalama</i>	3.47E+03	4.43E+01	6.57E+03	5.88E+03	3.77E+03	4.74E+03
	<i>Std</i>	8.85E+02	7.82E+03	6.79E+02	4.51E+02	5.30E+02	5.79E+02
	<i>Sıralama</i>	2	1	6	5	3	4
11	<i>Ortalama</i>	4.15E+03	6.50E+05	6.92E+03	7.04E+03	4.50E+03	6.48E+03
	<i>Std</i>	6.90E+02	6.35E+02	7.41E+02	2.77E+02	7.58E+02	3.76E+02
	<i>Sıralama</i>	1	6	4	5	2	3
12	<i>Ortalama</i>	4.30E-01	3.73E+02	2.21E+00	2.45E+00	1.67E+00	2.46E+00
	<i>Std</i>	2.60E-01	2.76E+02	5.26E-01	2.30E-01	3.60E-01	2.35E-01
	<i>Sıralama</i>	1	6	3	4	2	5
13	<i>Ortalama</i>	2.21E+00	2.14E+02	5.14E+00	2.89E+00	5.00E-01	6.53E-01
	<i>Std</i>	1.34E+00	1.58E+02	1.65E+00	3.30E-01	1.20E-01	6.57E-02
	<i>Sıralama</i>	3	6	5	4	1	2
14	<i>Ortalama</i>	3.54E+01	9.05E+02	1.31E+02	4.11E+01	2.80E-01	4.52E+00
	<i>Std</i>	2.47E+01	1.92E+03	5.52E+01	5.51E+00	4.00E-02	1.98E+00
	<i>Sıralama</i>	3	6	5	4	1	2
15	<i>Ortalama</i>	2.23E+05	1.04E+07	2.85E+05	2.82E+03	7.00E+01	3.68E+01
	<i>Std</i>	5.77E+05	6.54E+04	4.25E+05	3.62E+03	2.52E+01	5.51E+00
	<i>Sıralama</i>	4	6	5	3	2	1
16	<i>Ortalama</i>	1.27E+01	2.49E+07	1.32E+01	1.28E+01	1.26E+01	1.19E+01
	<i>Std</i>	5.30E-01	2.21E+09	3.23E-01	3.10E-01	5.80E-01	3.06E-01
	<i>Sıralama</i>	3	6	5	4	2	1
	<i>Ortalama</i>	3.39E+06	1.26E+04	1.61E+07	6.61E+06	4.33E+06	1.46E+06

17	<i>Std</i>	4.07E+06	3.30E+02	1.36E+07	2.94E+06	2.22E+06	6.89E+05
	<i>Siralama</i>	3	1	6	5	4	2
	<i>Ortalama</i>	5.19E+06	4.80E-02	6.11E+08	1.85E+08	1.55E+04	2.44E+07
18	<i>Std</i>	3.61E+07	1.43E+00	8.31E+08	8.68E+07	4.80E+04	1.19E+07
	<i>Siralama</i>	3	1	6	5	2	4
	<i>Ortalama</i>	7.36E+01	2.91E+01	2.68E+02	9.08E+01	4.48E+01	2.79E+01
19	<i>Std</i>	5.32E+01	1.48E+01	1.08E+02	2.42E+01	3.14E+01	3.21E+00
	<i>Siralama</i>	4	2	6	5	3	1
	<i>Ortalama</i>	5.67E+04	1.34E+01	2.78E+05	1.31E+04	2.04E+04	1.76E+03
20	<i>Std</i>	4.34E+04	4.16E+02	5.77E+05	4.83E+03	1.06E+04	6.16E+02
	<i>Siralama</i>	5	1	6	3	4	2
	<i>Ortalama</i>	7.83E+05	3.88E+02	8.23E+06	1.48E+06	9.48E+05	4.00E+05
21	<i>Std</i>	1.18E+06	2.70E-01	8.77E+06	8.55E+05	9.91E+05	2.31E+05
	<i>Siralama</i>	3	1	6	5	4	2
	<i>Ortalama</i>	8.67E+04	7.40E-01	1.12E+03	7.54E+02	7.49E+02	4.52E+02
22	<i>Std</i>	2.29E+04	1.19E+01	4.04E+02	1.25E+02	1.99E+02	1.31E+02
	<i>Siralama</i>	6	1	5	4	3	2
	<i>Ortalama</i>	3.71E+02	2.94E+03	5.76E+02	3.70E+02	3.31E+02	3.26E+02
23	<i>Std</i>	3.98E+01	3.10E-01	1.98E+02	1.37E+01	6.24E+00	2.03E+00
	<i>Siralama</i>	4	6	5	3	2	1
	<i>Ortalama</i>	2.76E+02	1.05E+06	2.81E+02	2.01E+02	2.06E+02	2.00E+02
24	<i>Std</i>	2.73E+01	4.44E+07	4.14E+01	9.10E-01	5.95E+00	0.00E+00
	<i>Siralama</i>	4	6	5	2	3	1
	<i>Ortalama</i>	2.14E+02	1.64E+01	2.40E+02	2.27E+02	2.25E+02	2.10E+02
25	<i>Std</i>	7.65E+00	1.52E+04	2.28E+01	6.18E+00	1.66E+01	2.41E+00
	<i>Siralama</i>	3	1	6	5	4	2
	<i>Ortalama</i>	1.03E+02	2.83E+05	1.04E+02	1.02E+02	1.00E+02	1.10E+02
26	<i>Std</i>	1.50E+00	1.99E+02	1.69E+00	5.60E-01	1.00E-01	3.00E+01
	<i>Siralama</i>	3	6	4	2	1	5
	<i>Ortalama</i>	9.21E+02	2.28E+01	1.09E+03	7.22E+02	9.05E+02	7.23E+02
27	<i>Std</i>	2.23E+02	2.15E+00	3.58E+02	2.91E+02	4.15E+02	1.85E+02
	<i>Siralama</i>	5	1	6	2	4	3
	<i>Ortalama</i>	1.12E+03	2.59E+00	2.24E+03	2.00E+03	2.15E+03	1.24E+03
28	<i>Std</i>	1.57E+02	5.98E+01	5.47E+02	3.17E+02	4.80E+02	7.46E+01
	<i>Siralama</i>	2	1	6	4	5	3
	<i>Ortalama</i>	3.06E+06	2.71E+02	2.15E+07	1.34E+07	4.38E+06	9.39E+05
29	<i>Std</i>	3.62E+06	5.04E+02	1.09E+07	7.63E+06	4.68E+06	4.99E+05
	<i>Siralama</i>	3	1	6	5	4	2
	<i>Ortalama</i>	5.89E+04	1.18E+07	4.79E+05	2.48E+05	8.20E+04	4.37E+04
30	<i>Std</i>	5.40E+04	8.87E+04	3.77E+05	8.39E+04	6.61E+04	1.71E+04
	<i>Siralama</i>	2	6	5	4	3	1
<i>Genel ortalama</i>		3.13	3.63	5.23	3.97	2.57	2.30
<i>Genel sıralama</i>		3	4	6	5	2	1

Tablo 5.6. da tüm algoritmalar için ortalama ve standart sapma metrikleri sunulmakta ve benchmark fonksiyonlarının ortalama hata değerlerine göre sıralanmaktadır. Tablonun sonun da verilen ortalama ve genel sıralamalardan, önerilen MsRwGWO algoritmasının diğer meta-sezgisel algoritmalarından daha iyi performans gösterdiği açık olarak görülmüştür. Sonuç olarak, bu çalışma da kullanılan CEC 2014 kıyaslama fonksiyonları ile karşılaştırmalı sonuçlar, geçiş mekanizması, yeni ağırlıklı güncelleme mekanizması, yeni kontrol sınır mekanizması, alfa, beta ve delta kurtlarının yenilenen güncelleme mekanizması gibi farklı

mekanizmaların eklendiğini göstermektedir. MSRwGWO algoritması, keşif ve kullanım aşamasın da algoritmanın performansını artırmaktadır.

5.2.3. MsRwGWO-MLP Hibrit Modeli Kullanılarak Kısa Vadeli Rüzgar Gücü Tahmini

Bu bölümde, önerilen MsRwGWO algoritması, gerçek dünya uygulaması olarak rüzgar gücü tahmini yürütmek için Çok Katmanlı Algılayıcı (MLP) modeline uyarlanmıştır. Güç sistemlerinin planlanması ve yönetimi açısından rüzgar enerjisinden elde edilecek elektrik enerjisinin belirlenmesi büyük önem taşımaktadır. Bu nedenle üretilen elektrik enerjisinin anlık, kısa, orta ve uzun vade de tahmin edilmesi gerekmektedir. Rüzgar hızının kaotik ve belirsiz yapısı nedeniyle, günümüzde araştırmacılar tarafından kısa vadeli tahmin araştırmalarının performansını artırmak için farklı modeller önerilmiştir. Günümüz de meta-sezgisel yaklaşımlara sahip hibrit modeller bu araştırma alanın da oldukça popüler hale gelmiştir.

MsRwGWO algoritması, eğitim aşamasın da MLP modelinin parametrelerini optimize etmek için kullanılmıştır. MsRwGWO-MLP hibrit modelin de, tüm gri kurtlar $[-10, 10]$ aralığında rastgele oluşturulmuş gerçek değerlerin tek boyutlu vektörleri olarak kodlanmıştır. Bu kodlama vektörü iki kısımdan oluşur. Birincisi katmanlar arasındaki bağlantı ağırlıkları ve gizli ve çıktı katmanlarının bias değerleridir. MLP modelinin ağırlık ve bias değerlerinin optimizasyonun da problem boyutu bu vektörün uzunluğudur ve aşağıdaki gibi hesaplanabilir


$$D = N_I \times N_H + N_H \times N_O + N_H + N_O \quad (5.7)$$

N_I girdi sayısını, N_H gizli katmandaki nöron sayısını ve N_O çıktı sayısını temsil etmektedir. Şekil 5.3. de MLP model parametrelerinin MsRwGWO algoritması tarafından nasıl optimize edildiğini göstermektedir.

MLP modelinin parametrelerinin optimize edilmesin de eğitim veri setindeki örnekler için RMSE fonksiyonu olarak amaç fonksiyonu kullanılmıştır. MLP model parametrelerinin optimizasyonun da kullanılan MsRwGWO algoritması 50 kez bağımsız olarak çalıştırılmış ve MsRwGWO-MLP modelinin eğitim ve test aşamaları için performans sonuçları istatistiksel olarak hesaplanmıştır. Kısa dönemli rüzgar hızı tahmini için MsRwGWO algoritması ile optimize edilmiş en iyi parametrelere sahip MLP modelinin 50 tekrarlı çalıştırma da eğitim ve

test sonuçları ve hata performans analizleri Şekil 14 (a) ve 14.(b) de gösterilmektedir. Bu grafiklerden de anlaşılacağı üzere MsRwGWO algoritması ile optimize edilmiş en iyi parametreye sahip MLP modelinin test ve eğitim aşamalarında 1 saatlik rüzgar hızı tahminin de başarılı performans verdiği görülmektedir. Ayrıca MsRwGWO tabanlı MLP model performansı, Şekil 17'de eğitim ve test aşamaları için dağılım grafikleri olarak gösterilmektedir.

Şekil 5.14. de gösterildiği gibi, tahmin modeli, rüzgar hızının aniden değiştiği aşım noktalarında zayıf bir performans sergilemektedir. Ancak, önerilen MsRwGWO-MLP modelinin geleneksel GWO-MLP modeline karşı genel performansını göstermek için hata performansı ölçümlerine ihtiyaç duyulmaktadır. Uygulamada, geliştirilen modellerin tahmin yeteneği, gözlemlenen ve tahmin edilen rüzgar hızı zaman serileri arasındaki çoklu istatistiksel indeks değerleri ile değerlendirilebilir.



Şekil 5.14. MsRwGWO algoritması tarafından 50 çalışmada elde edilen en iyi parametreye sahip MLP modeli (a) eğitim ve (b) istatistiksel hatalar içeren test sonuçları

Bu tez çalışmasında model performansını değerlendirebilmek için ortalama mutlak yüzde hatası (MAPE), ortalama mutlak hata (MAE), ortalama kare hatası (MSE) ve ortalama kare hatası (RMSE) kullanılmıştır. Genel olarak, bu performans metrikleri ne kadar küçük olursa model o kadar iyi performans göstermektedir. Dokur ve arkadaşları, bu üç performans ölçü indeksinin hesaplamalarını çalışmalarında göstermişlerdir (Dokur, 2020: 82), (Dokur vd., 2015: 421).


$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (5.8)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (5.9)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (5.10)$$


$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (5.11)$$

y_i ve $\hat{y}_i$ rüzgar hızının gözlemlenen değerini ve tahmin değerini temsil ettiğinde, N performans değerlendirmesi ve karşılaştırması için kullanılan toplam veri sayısıdır.




Şekil 5.15. MsRwGWO tabanlı MLP modelinin eğitim ve test performansları

Karşılaştırma için, geleneksel GWO-MLP modelinin ve MsRwGWO-MLP modelinin tahmin eğitimi ve test sonuçları sırasıyla Şekil 5.16 da gösterilmektedir. Model performansını daha net gösterebilmek için MLP modelinin eğitimi sırasında her iki algoritmanın yakınsama eğrileri Şekil 5.17. de gösterilmiştir. Bura da 50 çalıştırma sonucundan sonra elde edilen en iyi parametre değerine sahip MLP modellerinin RMSE değerleri, iterasyonlara bağlı olarak sunulmaktadır. Yineleme sonun da gösterilen yakınlaştırma penceresinden, önerilen MsRwGWO algoritmasının orjinal GWO algoritmasından daha iyi yakınsadığı söylenebilir.



Şekil 5.16. GWO ve MsRwGWO algoritması tabanlı MLP modellerinin karşılaştırmalı eğitim ve test sonuçları



Şekil 5.17. MLP modelinin eğitiminde MsRwGWO ve GWO algoritmalarının yakınsama eğrileri

Her iki MLP modeli de sonuçlar da rakamsal olarak rekabetçi bir sonuç gösterse de, önerilen MsRwGWO algoritmasının performansını daha iyi değerlendirmek adına her iki algoritma için 50 bağımsız çalıştırma ile MLP modellerinin eğitim ve test sonuçlarını özetleyen Tablo 5.7. ve Tablo 5.8. sunulmuştur. Bu tablolar, rüzgar hızı tahmini için MsRwGWO tabanlı MLP modeli ve GWO tabanlı MLP modeli tarafından bulunan MSE, RMSE, MAE ve MAPE metriklerinin istatistiksel sonuçlarını içermektedir. Bu metriklerin en iyi değerleri kalın harflerle vurgulanmıştır. Tablo 5.7. deki eğitim sonuçlarından da anlaşılacağı gibi, MsRwGWO-MLP modeli tüm hata metrikleri için GWO-MLP modelinden daha iyi sonuçlar vermektedir. Ayrıca MsRwGWO-MLP modeli, standart sapma dışındaki tüm istatistiksel metrikler açısından en iyisidir.

Tablo 5.8. de verilen test sonuçlarından MsRwGWO tabanlı MLP modeli için ortalama performans metriklerinin yani MSE, RMSE, MAE ve MAPE'nin 3.95E-03, 6.28E-02, 4.53E-02 ve 20.8 olduğu görülmektedir. % sırasına göre en iyi, ortalama ve medyan istatistiksel ölçütlere göre, MsRwGWO algoritmasına dayalı MLP modeli, rüzgar hızı veri setinin test kısmı için diğer MLP modelinden daha iyi sonuçlara sahiptir. Tablodan, önerilen modelin bu analiz sonuçlarında sunulan GWO-MLP'ye kıyasla daha düşük hata değerlerine ulaştığı doğrulanabilir.

Tablo 5.7. 50 tekrar ile GWO-MLP ve MsRwGWO-MLP hibrit modelinin eğitim sonuçları

	Metrik	En iyi	En kötü	Medyan	Ortalama	Std
GWO	MSE	4.05E-03	4.25E-03	4.12E-03	4.12E-03	3.97E-05
	RMSE	6.37E-02	6.52E-02	6.42E-02	6.41E-02	3.08E-04
	MAE	4.60E-02	4.80E-02	4.67E-02	4.66E-02	3.78E-04
	MAPE	2.00E+01	2.03E+01	2.01E+01	2.01E+01	7.40E-02
MsRwGWO	MSE	4.03E-03	4.21E-03	4.10E-03	4.10E-03	4.35E-05
	RMSE	6.35E-02	6.49E-02	6.41E-02	6.40E-02	3.39E-04
	MAE	4.60E-02	4.72E-02	4.65E-02	4.65E-02	3.66E-04
	MAPE	1.99E+01	2.02E+01	2.00E+01	2.01E+01	7.63E-02

Tablo 5.8. 50 tekrar ile GWO-MLP ve MsRwGWO-MLP hibrit modelinin test sonuçları

	Metrik	En iyi	En kötü	Medyan	Ortalama	Std
GWO	MSE	3.75E-03	4.25E-03	4.03E-03	3.99E-03	1.31E-04
	RMSE	6.12E-02	6.52E-02	6.35E-02	6.31E-02	1.04E-03
	MAE	4.42E-02	4.76E-02	4.59E-02	4.56E-02	8.43E-04
	MAPE	2.06E+01	2.14E+01	2.09E+01	2.09E+01	1.44E-01
MsRwGWO	MSE	3.73E-03	4.26E-03	3.97E-03	3.95E-03	1.50E-04
	RMSE	6.11E-02	6.53E-02	6.30E-02	6.28E-02	1.19E-03
	MAE	4.41E-02	4.71E-02	4.55E-02	4.53E-02	9.12E-04
	MAPE	2.06E+01	2.12E+01	2.08E+01	2.08E+01	1.47E-01

6. SONUÇLAR

Bu tez çalışmasında, GWO algoritmasının çok stratejili rastgele ağırlıklı yeni bir yaklaşımı olarak sunulan MsRwGWO algoritması adlı yeni bir GWO varyantı önerilmiştir. MsRWGWO algoritmasının performansı, üç faktöre dayalı olarak kapsamlı bir şekilde analiz edilmiştir. Birinci olarak yakınsama, arama geçmiş, yörünge ve ortalama mesafe analizleri, ikinci olarak 10, 30 ve 50 boyutlu CEC 2014 kıyaslamaları ve son olarak 30D CEC 2014 test problemleri için MFO, PSO, DA, SCA ve WOA gibi bazı popüler meta-sezgisel algoritmalar ile kıyaslamaları verilmiştir. Bu analizler dünya üzerinde gerçek bir problem olarak ele alınan ve literature de sıklıkla kullanılan rüzgar hızı üzerinden rüzgar gücü tahmini konusu üzerinde çalışılmıştır. Yakınsama analizi sonucunda problemin çözümünde MsRwGWO algoritmasının GWO algoritmasına göre daha hızlı yakınsadığı görülmüştür. Önerilen MsRwGWO algoritmasının global optimuma daha yakın bir çözüm bulma yeteneği görülmektedir. Arama geçmiş analizi sonuçları, MsRwGWO algoritması tarafından güncellenen global optimum etrafındaki gri kurtların dağılımının, gri kurtların dağılımından daha yüksek olduğunu göstermektedir. Keşif ve kullanım aşamaların da arama uzayın da GWO algoritması tarafından güncellenmektedir. GWO algoritması tarafından bulunan gri kurtlar, arama geçmiş analizleri sürecin de FN6 test problemi dışın da özellikle benchmark problemlerinin yüzeylerin de arama uzayının sınır değerlerine takılıp kalmaktadır. MsRwGWO algoritmasının yörünge analizi sonuçlarına göre, alfa kurdunun konumu keşif aşamasın da daha hızlı güncellenmekte ve sömürü aşamasın da global optimuma yaklaşmaktadır. Önerilen MsRwGWO algoritması, keşif aşamasın da MsRwGWO algoritmasının ortalama mesafe eğrisin de artış gösteren kısımlar da problemin yerel optimum noktalarından başarılı bir şekilde kaçınmaktadır. CEC2014 kıyaslamalı problemleri üzerindeki testler, MsRwGWO algoritmasının umut verici bir algoritma olduğunu göstermektedir. Aynı zamanda MsRwGWO algoritmasının MFO, PSO, DA, SCA ve WOA'dan daha iyi bir performans gösterdiği gözlemlenmiştir. Ayrıca hibrit yaklaşım MsRwGWO-MLP modeli, rüzgar hızı tahmini için GWO-MLP modelinden daha iyi sonuçlar vermektedir. Analiz sonuçlarına göre önerilen MsRwGWO-MLP hibrit modelinin, daha yüksek tahmin doğruluğuna ve daha güçlü kararlılığa sahip gelecek vaat eden bir rüzgar enerjisi tahmin yöntemi olduğu görülmüştür. Bununla birlik de ileriye dönük rüzgar gücü girdi değerleri ile ilişkili özelliklerin de önerilen yaklaşıma dahil edilmesi ve ayırıştırma yöntemleri ile yeni hibrit modellerin geliştirilmesi planlanmaktadır.

KAYNAKÇA

- Akdağ, S.A.** (2008). Rüzgar Enerjisi Potansiyeli ve Ekonomik Analizinde Weibull Dağılımının Kullanımı. (Yayınlanmış Yüksek Lisans Tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Altan, A., Karasu, S., & Zio, E.** (2021). A new hybrid model for wind speed forecasting combining long short-term memory neural network, decomposition methods and grey wolf optimizer. *Applied Soft Computing*, 100, 106996.
- Aly, H. H.** (2020). A proposed intelligent short-term load forecasting hybrid models of ANN, WNN and KF based on clustering techniques for smart grid. *Electric Power Systems Research*, 182, 106191.
- Aslam, S.** (2018). An optimal home energy management scheme considering grid connected microgrids with day-ahead weather forecasting using artificial neural network. (Yayınlanmış Yüksek Lisans Tezi). COMSATS University Islamabad, Pakistan.
- Aslan, N., & Yamak, T.** (2006). Türkiye'nin Enerji Sorununun Alternatif Enerji Kaynakları Açısından Değerlendirilmesi. *Marmara Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 21(1), 53-76.
- Barman, M., & Choudhury, N. B. D.** (2020). A similarity based hybrid GWO-SVM method of power system load forecasting for regional special event days in anomalous load situations in Assam, India. *Sustainable Cities and Society*, 61, 102311.
- Budak, Ü., Korkmaz, D., & Yıldız, C.** (2021). WSFNet: An efficient wind speed forecasting model using channel attention-based densely connected convolutional neural network.
- Chen, Q., & Folly, K. A.** (2018). Wind power forecasting. *IFAC-PapersOnLine*, 51(28), 414-419.
- Çevik, H. H., Çunkaş, M., & Polat, K.** (2019). A new multistage short-term wind power forecast model using decomposition and artificial intelligence methods. *Physica A: Statistical Mechanics and its Applications*, 534, 122177.
- Doğan, L., & Yüzgeç, U.** (2018, May). Robot Path Planning using Gray Wolf Optimizer. In *Proceedings-International Conference on Advanced Technologies, Computer Engineering and Science (ICATCES'18)*.

Dokur, E. (2017). Enerji Sistemlerinde Rüzgar Hızı Modellemesi İçin Geliştirilen Finsler Geometrisi Tabanlı Yeni Bir Yaklaşım Analizi ve Uygulaması. (Yayınlanmış Doktora Tezi). Bilecik Şeyh Edebali Üniversitesi, Fen Bilimler Enstitüsü, Bilecik.

Dokur, E., Yüzgeç, U., & Kurban, M. Comparative Analysis of Seasonal Wind Speed Forecasting Using ANFIS-PSO Hybrid Approach. *structure*, 7, 10.

Dokur, E., Yüzgeç, U., & Kurban, M. (2017). M. Comparative Analysis of Seasonal Wind Speed Forecasting Using ANFIS-PSO Hybrid Approach. *structure*, 7, 10.

Enerdata (2021). Global Energy Trends. [Erişim 10.08.2021, <https://www.enerdata.net/publications/reports-presentations/world-energy-trends.html>]

Fei, S. W., & He, Y. (2015). Wind speed prediction using the hybrid model of wavelet decomposition and artificial bee colony algorithm-based relevance vector machine. *International Journal of Electrical Power & Energy Systems*, 73, 625-631.

Fu, W., Wang, K., Tan, J., & Zhang, K. (2020). A composite framework coupling multiple feature selection, compound prediction models and novel hybrid swarm optimizer-based synchronization optimization strategy for multi-step ahead short-term wind speed forecasting. *Energy Conversion and Management*, 205, 112461.

Gupta, S., Deep, K., Mirjalili, S., & Kim, J. H. (2020). A modified sine cosine algorithm with novel transition parameter and mutation operator for global optimization. *Expert Systems with Applications*, 154, 113395.

GWEC (2021). Global Wind Report 2016. [Erişim 11.08.2021, <https://gwec.net/global-wind-report-2021/>]

IEA (2016). World Energy Outlook 2016. [Erişim 11.08.2021, <https://www.iea.org/reports/water-energy-nexus>]

Jayabarathi, T., Raghunathan, T., Adarsh, B. R., & Suganthan, P. N. (2016). Economic dispatch using hybrid grey wolf optimizer. *Energy*, 111, 630-641.

Kennedy J, Eberhart RC. (1995). A new optimizer using particles swarm theory. In: Proceedings of sixth international symposium on micro machine and human science, IEEE Service Center, Piscataway, 39–43.

Liang, J. J., Qu, B. Y., & Suganthan, P. N. (2013). Problem definitions and evaluation criteria for the CEC 2014 special session and competition on single objective real-parameter

numerical optimization. *Computational Intelligence Laboratory, Zhengzhou University, Zhengzhou China and Technical Report, Nanyang Technological University, Singapore*, 635, 490.

Liang, J. J., Qu, B. Y., Suganthan, P. N., & Chen, Q. (2014). Problem definitions and evaluation criteria for the CEC 2015 competition on learning-based real-parameter single objective optimization. *Technical Report201411A, Computational Intelligence Laboratory, Zhengzhou University, Zhengzhou China and Technical Report, Nanyang Technological University, Singapore*, 29, 625-640.

Li, L. L., Liu, Z. F., Tseng, M. L., Jantarakolica, K., & Lim, M. K. (2021). Using enhanced crow search algorithm optimization-extreme learning machine model to forecast short-term wind power. *Expert Systems with Applications*, 184, 115579.

Li, L. L., Zhao, X., Tseng, M. L., & Tan, R. R. (2020). Short-term wind power forecasting based on support vector machine with improved dragonfly algorithm. *Journal of Cleaner Production*, 242, 118447.

Liu, H., Wu, H., & Li, Y. (2018). Smart wind speed forecasting using EWT decomposition, GWO evolutionary optimization, RELM learning and IEWT reconstruction. *Energy Conversion and Management*, 161, 266-283.

Memarzadeh, G., & Keynia, F. (2020). A new short-term wind speed forecasting method based on fine-tuned LSTM neural network and optimal input sets. *Energy Conversion and Management*, 213, 112824.

Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in engineering software*, 69, 46-61.

Mirjalili, S. (2015). Güve alevi optimizasyon algoritması: Doğadan ilham alan yeni bir buluşsal paradigma. *Bilgi tabanlı sistemler*, 89, 228-249.

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., & Lewis, A.** (2016). The whale optimization algorithm. *Advances in engineering software*, 95, 51-67.
- Niu, T., Wang, J., Zhang, K., & Du, P.** (2018). Multi-step-ahead wind speed forecasting based on optimal feature selection and a modified bat algorithm with the cognition strategy. *Renewable Energy*, 118, 213-229.
- Onay, A. E.** (2021). Rüzgar Enerji Sistemlerinde Weibull Dağılımı İçin Yeni Nesil Parametre Metotlarının Karşılaştırılmalı Analizi ve Uygulaması. (Yayınlanmış Yüksek Lisans Tezi). Bilecik Şeyh Edebali Üniversitesi, Fen Bilimler Enstitüsü, Bilecik.
- Osório, G. J., Matias, J. C. O., & Catalão, J. P. S.** (2015). Short-term wind power forecasting using adaptive neuro-fuzzy inference system combined with evolutionary particle swarm optimization, wavelet transform and mutual information. *Renewable Energy*, 75, 301-307.
- Paul, A. K., & Shill, P. C.** (2018). New automatic fuzzy relational clustering algorithms using multi-objective NSGA-II. *Information Sciences*, 448, 112-133.
- Pradhan, M., Roy, P. K., & Pal, T.** (2016). Grey wolf optimization applied to economic load dispatch problems. *International Journal of Electrical Power & Energy Systems*, 83, 325-334.
- Pradhan, M., Roy, P. K., & Pal, T.** (2018). Oppositional based grey wolf optimization algorithm for economic dispatch problem of power system. *Ain Shams Engineering Journal*, 9(4), 2015-2025.
- Singh, D., & Dhillon, J. S.** (2019). Ameliorated grey wolf optimization for economic load dispatch problem. *Energy*, 169, 398-419.
- Yılmaz, M.** (2012). Türkiye'nin enerji potansiyeli ve yenilenebilir enerji kaynaklarının elektrik enerjisi üretimi açısından önemi. *Ankara Üniversitesi Çevre Bilimleri Dergisi*, 4(2), 33-54.
- Zhang, J., Wei, Y., & Tan, Z.** (2020). An adaptive hybrid model for short term wind speed forecasting. *Energy*, 190, 115615.
- Xiao, L., Shao, W., Yu, M., Ma, J., & Jin, C.** (2017). Research and application of a hybrid wavelet neural network model with the improved cuckoo search algorithm for electrical power system forecasting. *Applied energy*, 198, 203-222.

Xiao, L., Wang, J., Dong, Y., & Wu, J. (2015). Combined forecasting models for wind energy forecasting: A case study in China. *Renewable and Sustainable Energy Reviews*, 44, 271-288.

Wagner, H. J. (2018). Introduction to wind energy systems. In *EPJ Web of Conferences* (Vol. 189, p. 00005). EDP Sciences.

Wang, J., Du, P., Niu, T., & Yang, W. (2017). A novel hybrid system based on a new proposed algorithm—Multi-Objective Whale Optimization Algorithm for wind speed forecasting. *Applied energy*, 208, 344-360.

Wang, J., Wang, S., & Yang, W. (2019). A novel non-linear combination system for short-term wind speed forecast. *Renewable Energy*, 143, 1172-1192.

Wu, C., Wang, J., Chen, X., Du, P., & Yang, W. (2020). A novel hybrid system based on multi-objective optimization for wind speed forecasting. *Renewable Energy*, 146, 149-165.