



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**Portföy Optimizasyon Yöntemlerinin
Performanslarının Karşılaştırılması**
Mehmet Ali KAYA

YÜKSEK LİSANS TEZİ

İstatistik Anabilim Dalı

Haziran-2023
KONYA
Her Hakkı Saklıdır

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Mehmet Ali KAYA
Tarih:16.06.2023

ÖZET

YÜKSEK LİSANS TEZİ

Portföy Optimizasyon Yöntemlerinin Performanslarının Karşılaştırılması

Mehmet Ali KAYA

**Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
İstatistik Anabilim Dalı**

Prof. Dr. Murat ERİŞOĞLU
2023, 48 Sayfa

Jüri

Prof. Dr. Murat ERİŞOĞLU
Doç. Dr. Aydın KARAKOCA
Dr. Öğr. Üyesi Kadir KARAKAYA

Bu çalışmada, portföy optimizasyonunda meta-sezgisel algoritmalarından Genetik Algoritma, Parçacık Sürü Optimizasyonu, Yapay Arı Kolonisi ve Diferansiyel Gelişim Algoritmalarının kullanımı incelenmiştir. Çalışma kapsamında S&P 500 endeksindeki ilk 25 hisse senedi ve BİST 30 endeksindeki 30 şirketin 03.01.2020 ile 14.12.2022 tarihleri arasındaki günlük getiri verileri kullanılarak ilgili meta sezgisel algoritmalar ile portföy optimize gerçekleştirilmiştir. Çalışma sonucunda portföy optimizasyonunda meta sezgisel algoritmaların yararlı olduğu ancak temel ve teknik analizlerin de dikkate alınması gerektiği, ayrıca portföy çeşitlendirmesi yapılması önerilmiştir. Son olarak, çalışmada kullanılan verilerin sadece belirli bir zaman dilimini kapsadığı ve gelecekteki performansların garanti edilemeyeceği vurgulanmıştır.

Anahtar Kelimeler: Diferansiyel Gelişim Algoritması, Genetik Algoritma, Parçacık Sürü Optimizasyonu, Portföy Optimizasyonu, Yapay Arı Kolonisi

ABSTRACT

MS THESIS

Comparison of Performance of Portfolio Optimization Methods

Mehmet Ali KAYA

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
NECMETTİN ERBAKAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE**

**Prof. Dr. Murat ERİŞOĞLU
2023, 48 Pages**

**Jury
Prof. Dr. Murat ERİŞOĞLU
Assoc. Prof. Dr. Aydın KARAKOCA
Asst. Prof. Dr. Kadir KARAKAYA**

In this study, the use of Genetic Algorithm, Particle Swarm Optimization, Artificial Bee Colony and Differential Growth Algorithms from meta-heuristic algorithms in portfolio optimization is examined. Within the scope of the study, the first 25 stocks in the S&P 500 index and 30 companies in the BIST 30 index were optimized with the relevant meta-heuristic algorithms using daily return data between 03.01.2020 and 14.12.2022. As a result of the study, it is suggested that meta-heuristics are useful in portfolio optimization, but fundamental and technical analysis should also be considered, and portfolio diversification is also recommended. Finally, it is emphasized that the data used in the study covers only a certain period and future performances cannot be guaranteed.

Keywords: Differential Evolution Algorithm, Genetic Algorithm, Particle Swarm Optimization, Portfolio Optimization, Artificial Bee Colony Algorithm

ÖNSÖZ

Bu çalışmanın hayata geçirilmesi sürecinde bilgi ve tecrübelerinden faydalandığım araştırmanın her bir aşamasında görüşleriyle beni destekleyen, samimiyetini her zaman hissettiren ve beni doğru yönde yönlendiren danışman hocam Prof. Dr. Murat ERİŞOĞLU'na, ayrıca çalışmamda desteklerini hiçbir zaman eksik etmeyen, bana olan güvenlerini hiç kaybetmeyen aileme teşekkür ederim.

Mehmet Ali KAYA
KONYA-2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
1. GİRİŞ	1
1.1. Portföy ve Portföy Optimizasyonu.....	3
1.1.1.Portföy Yönetimi	4
1.1.2 Portföy Türleri	4
1.1.3 Risk ve Beklenen Getiri	5
2. KAYNAK ARAŞTIRMASI	9
3. MATERYAL VE YÖNTEM.....	12
3.1.Ortalama Varyans Modeli	12
3.2. Genetik Algoritma (GA)	14
3.2.1.Başlatma.....	15
3.2.2.Değerlendirme	16
3.2.3.Seçim	16
3.2.4.Çaprazlama	17
3.2.5.Mutasyon	19
3.2.5.Tekrarlama	21
3.2.6.Çözüm.....	22
3.3. Parçacık Sürü Optimizasyonu (PSO)	22
3.4.Yapay Arı Kolonisi (ABC)	24
3.5. Diferansiyel Gelişim Algoritması	26
4. UYGULAMA	28
4.1. BİST30 Örneğinde Meta Sezgisel Algoritmalarla Portföy Optimizasyonu.....	28
4.2. S&P500 Örneğinde Meta Sezgisel Algoritmalarla Portföy Optimizasyonu.....	36
5. SONUÇLAR VE ÖNERİLER	43
5.1 Sonuçlar	43
5.2 Öneriler	44
6. KAYNAKLAR	46
ÖZGEÇMİŞ	48

SİMGELER VE KISALTMALAR

Simgeler

R_P	:	Portföyün getirisi
σ_P^2	:	Portföyün varyansı
N	:	Portföydeki varlık sayısı
w_i	:	Portföydeki i . varlığın ağırlığı (oranı)
σ_{ij}	:	Portföydeki i . ve j . varlıkların kovaryansı
μ_i	:	Portföydeki i . varlığın ortalaması
R^*	:	Hedeflenen getiri
λ	:	Riskten kaçınma parametresi
M	:	Popülasyon büyüklüğü
$p_{seçilme,i}$	:	GA 'da i . kromozomun seçilme olasılığı
$p_i^{(t)}$	:	PSO 'da t . tekrardaki sürünün i . parçacığının değeri
$pbest_i^{(t)}$	:	PSO 'da t . tekrarda i . parçacığının çözüme en yakın noktadaki değeri
$gbest^{(t)}$	:	PSO 'da t . tekrarda o ana kadarki en iyi çözüm değerine sahip parçacık
w	:	PSO 'da eylemsizlik sabiti
c_1	:	PSO 'da kişisel öğrenme katsayısı
c_2	:	PSO 'da sosyal öğrenme katsayısı
$X^{(t)}$	:	PSO 'da t . tekrardaki sürü matrisi
$V^{(t)}$	:	PSO 'da t . tekrarda elde edilen hız matrisi
x_{enk}	:	DE algoritmasında o ana kadar elde edilen en iyi çözüm
$x_{çapraz}$	:	DE algoritmasında çaprazlama çözümü
F	:	DE algoritmasında [0,2] aralığında değer alan ölçekleme faktörü
CR	:	DE algoritmasında (0,1) aralığında değer alan çaprazlama oranı
x_i	:	ABC algoritmasında i . besin kaynakları (aday çözüm)
SN	:	ABC algoritmasında popülasyon büyüklüğü

Kısaltmalar

PSO	:	Parçacık Sürü Optimizasyonu
GA	:	Genetik Algoritma
ABC	:	Yapay Arı Kolonisi
DE	:	Diferansiyel Gelişim
AAPL	:	Apple
MSFT	:	Microsoft
AMZN	:	Amazon
TSLA	:	Tesla
GOOGL	:	Alphabet Class A
GOOG	:	Alphabet Class C
BRK.B	:	Berkshire Hathaway Class
UNH	:	United Health Group
JNJ	:	Johnson & Johnson
XOM	:	Exxon Mobil
JPM	:	JP Morgan Chase
META	:	Meta
V	:	Visa Class A
PG	:	Procter & Gamble

NVDA	:	Nvidia
HD	:	Home Depot
CVX	:	Chevron Corporation
LLY	:	Eli Lilly
MA	:	Mastercard Inc. Class A
ABBV	:	Abbvie Inc
PFE	:	Pfizer
MRK	:	Merck
PEP	:	Pepsico
BAC	:	Bank of America
KO	:	Coca-Cola Company
AKBNK	:	Akbank T.A.Ş.
AKSEN	:	Aksa Enerji Üretim A.Ş.
ALARK	:	Alarko Holding A.Ş.
ARCLK	:	Arçelik A.Ş.
ASELS	:	Aselsan Elektronik Sanayi ve Ticaret A.Ş.
BIMAS	:	BİM Birleşik Mağazalar A.Ş.
EKGYO	:	Emlak Konut Gayrimenkul Yatırım Ortaklığı A.Ş.
EREGL	:	Ereğli Demir ve Çelik Fabrikaları T.A.Ş.
FROTO	:	Ford Otomotiv Sanayi A.Ş.
GUBRF	:	Gübre Fabrikaları T.A.Ş.
SAHOL	:	Hacı Ömer Sabancı Holding A.Ş.
HEKTS	:	HEKTAŞ Ticaret T.A.Ş.
KRDMD	:	Kardemir Karabük Demir Çelik Sanayi ve Ticaret A.Ş.
KCHOL	:	Koç Holding A.Ş.
KOZAL	:	Koza Altın İşletmeleri A.Ş.
KOZAA	:	Koza Anadolu Metal Madencilik İşletmeleri A.Ş.
ODAS	:	ODAŞ Elektrik Üretim Sanayi Ticaret A.Ş.
PGSUS	:	Pegasus Hava Taşımacılığı A.Ş.
PETKM	:	Petkim Petrokimya Holding A.Ş.
SASA	:	SASA Polyester Sanayi A.Ş.
TAVHL	:	TAV Havalimanları Holding A.Ş.
TKFEN	:	Tekfen Holding A.Ş.
TOASO	:	TOFAŞ Türk Otomobil Fabrikası A.Ş.
TCELL	:	Turkcell İletişim Hizmetleri A.Ş.
TUPRS	:	Tüpraş-Türkiye Petrol Rafinerileri A.Ş.
THYAO	:	Türk Hava Yolları A.O.
GARAN	:	Türkiye Garanti Bankası A.Ş.
ISCTR	:	Türkiye İş Bankası A.Ş.
SISE	:	Türkiye Şişe ve Cam Fabrikaları A.Ş.
YKBNK	:	Yapı ve Kredi Bankası A.Ş.

1. GİRİŞ

Yatırımcılar mali piyasalarda birikimlerini değerlendirmeye başladıkça, portföy seçimi ve yönetimi çalışmaları önem kazanır. Portföy yönetimi, menkul kıymetlerin yatırımcıların tercih ve ihtiyaçlarına göre toplanması olarak tanımlanabilir. Yatırımcının amacı, en düşük riskle en yüksek getirili portföyü veya aynı riskle birden fazla getiri sağlayan bir portföy oluşturmaktır. İnsanlar, varlıklarının toplam getirisini gelecekte mali kısıtlamalar içinde devam etmelerini sağlayacak bir risk düzeyine yükseltmeyi düşünürler. Çok sayıda seçenekle karşı karşıya kalan bireyler, varlıklarına nasıl değer vereceklerine karar vermekte zorlanırlar. Bir portföyü çeşitlendirmenin geleneksel ve modern olmak üzere iki yolu vardır. Geleneksel yaklaşımın amacı, yatırımcıların çıkarlarını maksimize etmektir. Portföy oluşturma'nın temel amacı risk çeşitlendirmesidir. Portföyü oluşturan menkul kıymetlerin gelişimi aynı yönde hareket etmeyeceği için portföyün riski menkul kıymetlere göre daha düşük olacaktır. Geleneksel portföy teorisi, portföydeki menkul kıymet sayısının artırılması esasına dayanmaktadır. Bu yaklaşım, tüm yumurtalarını bir sepete koymamak olarak tanımlanabilir. Bir portföyü çeşitlendirmenin ikinci yolu modern yöntemdir. Modern yöntemlerde portföy çeşitlendirmesi Markowitz (1952) modeline göre yapılmaktadır. Markowitz'e göre, yalnızca çeşitlendirme yoluyla riski azaltmak imkansızdır. Markowitz modeli kullanılarak portföy çeşitlendirilirken korelasyon katsayısı dikkate alınır. Çünkü korelasyon katsayısı ile portföy riski arasında doğrusal bir ilişki vardır.

Bu teoriye göre, portföyün unsurları arasındaki korelasyon önemlidir ve aynı trend ve yüksek korelasyona sahip unsurların seçilmesi, aynı unsur gibi olacağı için portföyün riskini azaltmada herhangi bir etkiye sahip olmayacaktır. Portföydeki öğeler daha az ilişkiliyse, bir öğeyi kaybedip diğerini kazanarak riskinizi azaltabilirsiniz. Bir portföyde birleştirildiğinde iki öğe arasındaki varyanslar eşitse, portföyün varyansı her bir maddenin bireysel varyansından küçüktür. Bu teoride risk, her bir unsurun varyansı ile ilişkili değildir; Elementler arasında anormal bir ilişki biçimi olan ve kovaryans gösteren heterotrofi ile ilişkilidirler.

Bu çalışma, yatırımcıların portföy optimizasyonunda farklı algoritmaları kullanma ve sonuçlarını karşılaştırma konusunda bir anlayış geliştirmelerine yardımcı olmayı amaçlamaktadır. Yatırımcılar, kendi risk toleranslarına ve getiri hedeflerine en

uygun algoritmayı seçerek portföylerini optimize edebilir ve daha iyi yatırım kararları verebilirler.

Ancak, portföy optimizasyonu sürecinde dikkate alınması gereken diğer faktörler de vardır. Örneğin, veri güvenilirliği, piyasa koşulları, likidite gibi faktörler, portföy performansını etkileyebilir. Bu nedenle, algoritmaların sonuçlarının yalnızca bir başlangıç noktası olduğunu ve yatırımcıların sürekli olarak portföylerini izlemeleri, güncellemeleri ve gerektiğinde yeniden optimize etmeleri gerektiğini unutmamak önemlidir.

Sonuç olarak, farklı optimizasyon algoritmalarının kullanılması ve sonuçlarının karşılaştırılması, yatırımcıların portföylerini optimize etmelerine ve yatırım kararlarını desteklemelerine yardımcı olabilir. Ancak, her bir algoritmanın kendi avantajları ve sınırlamaları olduğunu unutmamak ve dikkatli bir şekilde değerlendirme yapmak önemlidir. Yatırımcılar, kendi hedeflerine ve tercihlerine en uygun olan algoritmayı seçerek, başarılı bir portföy optimizasyonu stratejisi geliştirebilirler.

Portföy optimizasyonu, yatırımcılar için önemli bir süreçtir çünkü doğru bir şekilde yapıldığında riskleri minimize edebilir ve getirileri maksimize edebilir. Farklı optimizasyon algoritmalarının kullanılması, bu süreci daha etkili ve verimli hale getirebilir.

Bu çalışmada portföy optimizasyonunda Genetik Algoritma (GA), Parçacık Sürü Optimizasyonu (PSO), Yapay Arı Kolonisi (ABC) ve Diferansiyel Gelişim (DE) algoritmaları kullanılacaktır. GA, genetik algoritma prensiplerini kullanarak potansiyel çözümleri keşfeder ve en iyi sonucu bulmaya çalışır. PSO, parçacık sürüsü benzetimini kullanarak olası çözüm alanını araştırır. ABC, arıların davranışını taklit ederek çözüm alanında gezinir ve en iyi çözümü bulmaya çalışır. DE algoritması, farklı vektörlerin kombinasyonlarını oluşturarak ve değerlendirerek en iyi çözümü arar.

Bu algoritmaların her biri kendi avantajlarına sahiptir. Örneğin, GA ve PSO genellikle global optimuma yaklaşmakta daha başarılıdır, DE daha hızlı yakınsama sağlayabilirken ABC algoritması daha esnek ve keşif odaklıdır. Ancak, her bir algoritmanın belirli parametreleri ve kısıtlamaları vardır ve her durumda en iyi sonucu sağlamayabilir.

Yatırımcılar, portföy optimizasyonunda bu algoritmaları kullanırken dikkate almaları gereken bazı faktörler vardır. Bunlar, yatırımcının risk toleransı, getiri hedefleri, likidite gereksinimleri, zaman kısıtlamaları ve diğer özel gereksinimleridir. Ayrıca, algoritmaların performansını değerlendirmek için geriye dönük testler yapmak ve farklı parametre kombinasyonlarını denemek önemlidir.

Sonuç olarak, portföy optimizasyonunda farklı algoritmaların kullanılması, yatırımcılara daha iyi kararlar vermeleri için değerli bir araç sağlar. Ancak, bu algoritmaların sonuçlarına kesinlikle güvenmek yerine, yatırımcılar kendi analizlerini yapmalı, verileri değerlendirmeli ve risk-getiri tercihlerini dikkate alarak kararlarını vermelidirler. Portföy optimizasyonu sürekli bir süreçtir ve piyasa koşulları ve yatırımcı hedefleri değiştikçe güncellenmesi gerekmektedir.

Bu çalışmada meta sezgisel algoritmaların portföy optimizasyonunda kullanımı incelenecektir. Çalışmada öncelikle portföy ve portföy optimizasyonu ile ilgili temel kavramlar verilecektir. Çalışmanın ikinci bölümünde portföy optimizasyonunda meta sezgisel algoritmalar kullanımına ilişkin literatür verilecektir. Çalışmanın üçüncü bölümünde Markowitz'in ortalama-varyans modeli tanımlanarak portföy optimizasyonunda GA, PSO, ABC ve DE algoritmaları tanımlanacaktır. Çalışmanın uygulama bölümünde Borsa İstanbul'da işlem gören piyasa ve işlem hacmi bakımından en yüksek 30 hisse senedinden oluşan BİST30'da yer alan hisse senetlerinin 03.01.2020 ile 14.12.2022 tarihleri arasındaki günlük getiri değerlerinden oluşan veri seti ile aynı tarih diliminde S&P500'te yer alan 25 hisse senedinin günlük getiri değerlerinden oluşan veri seti kullanılarak GA, PSO, ABC ve DE algoritmaları ile portföy optimizasyonu gerçekleştirilecektir. Çalışmadan elde edilen sonuçlar, sonuç ve öneriler bölümünde değerlendirilecektir.

1.1.Portföy ve Portföy Optimizasyonu

"Portföy" terimi, aynı kişi veya işletme tarafından tutulan bir grup yatırımı ifade eder. Menkul kıymetler koleksiyonu, bir portföyü tanımlamanın bir yoludur. Belirli şirketlere yapılan yatırımlar olan hisse senetleri, faiz kazanmaya yönelik borç yatırımları olan tahviller ve esasen uzmanlar tarafından veya endekslere uygun olarak yatırılan yatırımcı paralarının kolektifleri olan yatırım fonları, ortak yatırımlardan bazılarıdır.

Portföy optimizasyonu, yatırımcının getiriye maksimize ederken riski minimize etme arzusundan kaynaklanan bir optimizasyon problemidir. Yüksek getiri elde etmek isteyen yatırımcılar büyük riskler alırlar. Riskten kaçınan bir yatırımcı düşük getiri elde edecektir (Yaman, 2014).

1.1.1.Portföy Yönetimi

Yatırım karması ve stratejisi hakkında karar vermek, yatırımları hedeflerle eşleştirmek, varlıkları hem insanlar hem de kurumlar için tahsis etmek ve risk ve performansı yönetmek hem bir sanat hem de bir bilim olan portföy yönetiminin parçalarıdır. Portföy yönetimi, belirli bir kişi için en az miktarda risk ve en yüksek potansiyel getiri ile ideal yatırım stratejisini seçme uygulamasıdır. Ek olarak, belirli bir zaman çerçevesinde mümkün olan en fazla parayı kazanmasını sağlamak için bir kişinin tahvil, hisse senedi, nakit, yatırım fonu vb. varlıklarını yönetmeyi ifade eder. Bir portföy yöneticisinin bilgili yönetimi altında bir kişi tarafından yönetilen paraya portföy yönetimi denir. Risk getirisi takası yapabilmek için çeşitli yatırım olanaklarındaki güçlü, zayıf yönler, fırsatlar ve tehlikeler incelenerek yapılır. Portföy yönetimi, borç ve öz sermaye, yerel ve yabancı, büyüme ve güvenlik kararlarındaki güçlü yönler, zayıf yönler, fırsatlar ve tehlikeler ve belirli bir risk iştahında getiriye optimize etme arayışında bulunan diğer bazı ödünleşimlerle ilgilidir. Basitçe söylemek gerekirse, bir portföy farklı hisse senetlerinin bir koleksiyonudur. Portföy yönetiminin özü, piyasa dinamiklerini anlamaktır.

Varlıklar bir portföyde birleştirilir. Yatırımcının gelirine, harcama kapasitesine ve zaman çerçevesine bağlı olarak, hisse senetleri, yatırım fonları, tahviller, nakit vb. gibi çeşitli yatırım araçlarını ifade eder.

1.1.2 Portföy Türleri

Portföy türleri Portföyü oluşturan varlık türleri yatırımcının iradesine bağlıdır. Yatırımcılar, bir portföy oluştururken risk alma veya riskten kaçınma istekleri, zaman ufku ve varlıkların elden çıkarılma hızı gibi faktörleri göz önünde bulundurmalıdır. Portföy tipi, yatırımcıların risk iştahlarına göre oluşturmak istedikleri optimum karışımın oluşturulmasında çok önemlidir. Sahip olunan varlıklara göre dört farklı portföy türü vardır. Farklı menkul kıymetlerden oluşan portföyler şunlardır:

- Tahvillerden oluşan portföyler

- Hisse senetlerinden oluşan portföyler
- Hisse senedi ve tahvillerden oluşan portföyler
- Diğer yatırım araçlarından oluşan portföyler

1.1.3 Risk ve Beklenen Getiri

Yatırım kararları tamamen risk ve ödül arasındaki ilişkiye dayanmaktadır. Yatırımcılar riskten kaçınırlar, bu nedenle aynı öngörülen getiriye sahip iki yatırım arasında seçim yapmaları durumunda, daha yüksek kesinlik derecesine sahip olanı seçeceklerdir. Yatırımcılar bu nedenle riskli yatırımlar için daha büyük bir öngörülen getiriye ihtiyaç duyarlar. Daha büyük bir tahmin edilen getirinin her zaman daha yüksek bir gerçek getiriye dönüşmediğini unutmayın. Tehlikeli varlıkların getirileri tanım gereği tahmin edilemez olduğundan, bir yatırım beklenen getiriyi sağlamayabilir. Gerçek getirinin beklenen getiriden farklı olma olasılığı daha yüksek veya daha düşük olabilir. Getiri dağılımı genişledikçe ortalama yıllık getiri artar.

1.1.3.1 Risk ve Getiri Ölçümü

Risk, potansiyel ödüllerin bilinmeyen doğasıdır. Tahmin edilen getiri ile gerçekleşen getiri arasındaki fark, riski ölçmek için kullanılabilir. Beklenen getiri, gelecekteki bir zaman dilimi için öngörülen getiridir.

Volatilite: Beklenen getiri oranına göre fiyat değişim aralığı, oynaklık olarak bilinir. Bir hisse senedi, daha fazla fiyat hareketi olduğunda daha oynaktır. Oynaklık belirsizlik sağladığı için riski artırır. Geçmiş oynaklık verileri bize bir hisse senedinin riski hakkında bilgi verir.

Standart Sapma: Varyans veya standart sapma yatırımlarda riski ölçmek için en çok kullanılan ölçüttür. Standart sapma, getirilerin ortalama getiri değerine göre muhtemelen ne kadar değişken olacağını gösterir

1.1.3.2 Sharpe Oranı

Sharpe oranı, 1966 yılında William Sharpe (Sharpe, 1966) tarafından geliştirildi ve o zamandan beri finasta en yaygın kullanılan risk/getiri ölçütlerinden biri haline geldi. Sharpe oranının temelini oluşturan beklenen getiriler ve oynaklıklar, istatistiksel olarak değerlendirilmesi gereken bilinmeyen sayılardır ve tahmin hatasına duyarlıdır.

Sharpe oranı, daha riskli bir varlığı tutarken yaşadığınız ek oynaklık karşılığında elde ettiğiniz daha fazla getiri miktarını gösterir.

Ölçülen getiriler düzenli olarak dağılıyorsa, herhangi bir frekansa sahip olabilirler. Tüm varlık getirileri normal bir dağılım izlemediğinden, oranın doğal bir kusuru vardır.

Daha uzun kuyruklu basıklık, daha büyük zirveler veya çarpıklık, bu durumlarda standart sapma daha az yararlı olduğundan, oran için sorun oluşturabilir. Getirilerin eşit olarak dağılmadığı durumlarda bu tekniğin kullanılması bazen riskli olabilir.

Öğeyle ilişkili artan risk için size adil bir şekilde ödeme yapılıp yapılmadığını belirlemek için, risksiz getiri oranı kullanılır. En kısa vade tarihli hazine tahvili genellikle en düşük risksiz getiri oranına sahiptir. Bu tür bir menkul kıymetin en düşük volatiliteye sahip olmasına rağmen, diğerleri, uzunluğunun karşılaştırılabilir bir yatırımına karşılık gelmesi gerektiğini iddia ediyor. Risksiz oran veya risksiz bir ortamda elde edeceğiniz oran, karşılaştırma ölçütünüz olarak hizmet eder. Hazine tahvillerinin temerrüde düşme olasılığı düşük olduğundan, Sharpe oranı bunları bu bağlamda sıklıkla kullanır.

Portföy getirisi: Bu, portföyünüzün kazandığı veya belirli bir süre boyunca ilk yatırımınızın bir oranı olarak kazanacağını tahmin ettiğiniz miktardır.

Oynaklığın bir ölçüsü olan standart sapma, getirilerin zaman içinde ne kadar değiştiğini gösterir. Pozitif bir sayı olarak ifade edildiğinde standart sapma hem aşağı hem de yukarı kaymaları hesaba katar (Sharpe, 1994).

1.1.3.3. Risk Türleri

Sistemik Olmayan Risk: Genellikle belirli risk olarak bilinen sistemik olmayan risk, belirli bir güvenlikle bağlantılı bir risk metriğidir; çeşitlendirilebilir risk olarak da bilinir. Yatırım yaptığınız firma veya yatırım yaptığınız sektörle ilgili belirsizlik şeklindedir. Bu risk, çeşitli sektörlerden çeşitli şirketler portföyüne yatırım yaparak azaltılabilir.

Sistemik Risk: Sistemik risk, sistemik olmayan riskin çeşitlendirilmesinden sonra geriye kalan şeydir. Piyasa riski veya çeşitlendirilemeyen risk, bunun diğer isimleridir. Tüm borsa veya tahvil fonlarında sistemik risk mevcuttur. Bilinen

sistematiik risklere sahip varlıklar, etkin bir piyasada daha düşük fiyatlandırılır ve sonuç olarak yatırımcılar daha büyük getiriler bekleyebilirler. Bu öngörülen bağlantının kapsamına yalnızca sistematiik tehlikeler girer. Yatırımcılar, sistematiik olmayan risk almanın telafisi olmadığı için portföylerinin beklenen getirisini düşürmeden kapsamlı çeşitlilik arayabilir. Çeşitlendirmeden sonra portföy riskini azaltmanın bir sonraki aşaması varlık tahsisidir.

Piyasa Riski: Piyasa oynaklığı nedeniyle tüm yatırımcıların karşı karşıya olduğu bir risktir ve bu risk azaltılamaz. Bu, çoğu insanın yatırımdan bahsederken "risk" kelimesini gelişigüzel kullandıklarında kastettikleri türden bir risktir. Beta riski veya çeşitlendirilemeyen risk olarak da bilinen bu risk, diğerleri arasında makro piyasa faiz oranları, enflasyon, savaş ve durgunluk dahil olmak üzere küresel makroekonomik ve sosyopolitik olaylarla bağlantılıdır. Çeşitlendirme, piyasa riskini asla azaltamaz.

Politik Risk: Mevzuattaki veya siyasi sistemdeki değişiklikler nedeniyle bir yatırımın tehlikeye girmesi tehlikesidir. Vergi mevzuatındaki olası değişiklikler veya bir ülkenin yönetim sistemindeki değişikliklerin her ikisi de politik risk kaynaklarıdır.

Yönetim Riski: Aktif olarak yönetilen fonlar, yatırımcıları, fon veya portföy yöneticilerinin yönetim kararları veya tarzı nedeniyle kriterlerin altında performans gösterme riskine maruz bırakır. Yatırımcılar pasif olarak yönetilen endeks fonlarına yatırım yaparak bu riskten kaçınabilirler.

Faiz Riski: Faiz oranı dalgalanmalarının bir sonucu olarak varlık fiyatlarındaki değişikliklerle ilişkili risktir. Tahviller ve tahvil fonları bu tür risklere karşı savunmasızdır. Mevcut tahvil fiyatları faiz oranları yükseldikçe düşer ve bunun tersi de geçerlidir. Daha uzun vadelere sahip tahviller daha fazla faiz oranı riskine sahiptir ve bunun tersi de geçerlidir.

Enflasyon Riski: Nakit, tahviller ve hisse senetleri, yatırımcının yatırımının enflasyonu düşük gerçekleştirme riskine açıktır. Enflasyon korumalı Hazine bonolarını satın alarak bu risk azaltılabilir.

Mali Risk: Bu risk, bir firmanın sermaye yapısı nedeniyle ortaya çıkar. Bir kuruluşun hisse ve tahvillerine yönelik mali risk, kurumsal borçla daha da şiddetlenir.

Kur Riski: Yabancı hisse senedi ve tahvil yatırımcıları da döviz kurlarındaki dalgalanmaların yarattığı riske tabidir. Yatırımcının mal ve hizmetlerinin çoğunu satın almak için kullandığı para birimi dışındaki para birimlerinde yapılan yatırımlar, döviz kuru riskine açıktır.

2. KAYNAK ARAŞTIRMASI

Küçükkocaoğlu (2002), İstanbul Menkul Kıymetler Borsası'nda (İMKB) Ulusal-30 Endeksi'ne yapılacak olan olası bir yatırım için Modern Portföy Teorimi yaklaşımına göre alternatiflerin seçimi ve Markowitz ortalama-varyans modeline göre en iyi portföyün oluşturulmasına yönelik ampirik bir çalışma gerçekleştirmiştir.

Demirtaş ve Güngör (2004), İMKB-30 hisse senetleri için standart sapmanın en düşük ve Sharpe oranının en yüksek olduğu iki bağımsız portföy seçeneği önermiştir. Çalışma sonucunda en az riskli portföyün oluşturulması için 19 adet hisse senedine ihtiyaç olduğu tespit edilmiştir.

Boztosun ve ark. (2005), Markowitz'in karesel programlama yöntemini kullanarak Ocak 2003- Temmuz 2004 tarihleri arasında İMKB 100 Endeksinde yer alan hisse senetleri için haftalık, 15 günlük, aylık ve üç aylık getiri verilerine dayalı portföy optimizasyonu gerçekleştirmiştir. Çalışmadan elde edilen sonuçlar, İMKB 100 endeksi ile aynı getiri seviyesinin altında, riskli portföylerin düşük ağırlıkta olduğunu ve bireysel yatırımcıların farklı risk alma eğilimlerine göre alternatifler oluşturduğunu göstermiştir.

Keskintürk (2007) çalışmasında Markowitz'in ortalama-varyans modelini kullanmış ve en iyi getiriye elde etmek için portföy seçiminde genetik algoritmaları kullanmıştır.

Aranha ve Iba (2009), portföy optimizasyonu için ağaç tabanlı GA önermişlerdir. Çalışmada portföy optimizasyonu için önerilen ağaç tabanlı GA'nın, klasik GA'dan daha iyi performans gösterdiği belirtilmiştir.

Lukeris ve ark. (2009), portföy optimizasyonunda meta sezgisel algoritmalarından GA, DEA ve PSO algoritmalarının en iyi çözümü vermesi için optimum parametre değerlerinin belirlenmesine yönelik ampirik bir çalışma gerçekleştirmişlerdir. Çalışma sonucunda DEA'nın en iyi ve en istikrarlı sonuçlara sahip olduğu gösterilmiştir.

Cura (2009), PSO tekniklerini portföy optimizasyon problemine uygulamıştır. Çalışmadan elde edilen sonuçlar PSO algoritmasının, GA ile karşılaştırıldığında portföy yatırımlarını optimize etmede daha etkili olduğunu göstermiştir.

Özdemir (2011), 15 Mayıs 2008- 26 Haziran 2009 tarihleri arasındaki İMKB-100 hisse senetlerinin günlük kapanış fiyatlarını temel alarak GA ve karesel programlama ile portföy optimizasyonu gerçekleştirmiştir. Çalışmada öncelikle GA ile portföyü oluşturacak hisse senetleri belirlenmiş ve ikinci aşamada belirlenen hisse senetlerinin ağılıkları karesel programlama ile belirlenmiştir.

Zhu ve ark. (2011), PSO yaklaşımı kullanarak portföy optimizasyon problemine meta-ampirik bir yaklaşım modeli önermişlerdir. Önerilen model, kısıtlanmış ve kısıtlanmamış risklerin farklı kombinasyonları üzerinde test edilmiş ve genetik algoritma ile karşılaştırılmıştır.

Gölmakani ve Fazel (2011), portföy optimizasyonunda Markowitz ortalama-varyans modeli için PSO ve GA yöntemlerini uygulamışlar ve çalışma sonucunda portföy optimizasyonunda PSO algoritmasının GA'dan daha iyi performans gösterdiğini belirtmişlerdir.

Sadeghi ve Zandia (2011), portföy optimizasyonu için oyun teorisine dayalı yeni bir model önermişlerdir. Önerilen modelin müşteri-mühendislik etkileşim modeline dayalı olarak portföy oluşturduğunun ifade edildiği çalışmada ampirik bir uygulama ile önerilen modelin etkinliği gösterilmiştir.

Guo ve ark. (2011), GA ve PSO arasında hibrit bir yaklaşım geliştirdi. Geliştirilen yöntem ham petrol fiyatını içeren bir veri setine uygulanmıştır.

Corazza ve ark. (2013), fon yönetimi uygulamasında kullanılan birçok sınırlama ile doğrusal olmayan karma tam sayılı bir portföy seçim modeli kullanmıştır.

Abay (2013), İMKB 30 Endeksindeki hisse senetleri için 2005 yılındaki 12 aylık getiri verilerini kullanarak karesel programlama ile Markowitz portföy seçim modeli ile portföy seçimi gerçekleştirmiştir.

Liagkouras ve Metaxiotis (2014), GA için yeni bir mutasyon operatörü geliştirmiş ve performansını çeşitli veri kümeleri üzerinde test etmiştir.

Ackora-Prah ve ark. (2014), geometrik ortalama geri dönüş modelini kullanarak Avrupa satım opsiyonunu fiyatlandıran bir GA geliştirmişlerdir.

Çelenli ve ark. (2015), İMKB 30 Endeksinde yer alan hisse senetlerinin günlük getiri oranlarına dayalı olarak ortalama varyans modeli altında portföy optimizasyonu için PSO algoritmasını kullanmışlardır. Çalışmada PSO algoritması ile elde edilen sonuçlar matematiksel programlamadan elde edilen sonuçlar ile karşılaştırılmıştır.

Kartal (2015), finansal portföy optimizasyonunda ABC algoritmasının kullanımını incelemiştir. Çalışmada literatürde yer alan 5 örnek ve BİST 30 Endeks verileri üzerinde ABC algoritmasının sonuçları GA, PSO, tavlama benzetimi ve tabu arama algoritmalarının sonuçları ile karşılaştırılmıştır. Çalışma sonuçları ABC algoritmasının portföy optimizasyonunda etkili çözümler oluşturduğunu göstermiştir.

Mercangöz (2018), BİST’de işlem gören ulaştırma sektöründe hizmet veren işletmelerin hisse senetleri için, PSO algoritması kullanılarak optimum portföyü araştırmıştır. Çalışmada BEYAZ, CLEBİ, DOCO, GSDDE, PGSUS, RYSAS ve THYAO hisse senetlerinin son üç yılki günlük fiyat hareketlerinden logaritmik dönüşümle elde edilen getiri değerleri kullanılmıştır. Çalışma sonucunda PSO algoritmasının portföy optimizasyonunda etkili bir yöntem olduğu belirtilmiştir.

Akyer ve ark. (2018), portföy optimizasyonu probleminin çözümü için PSO algoritmasını uyarlayarak Borsa İstanbul endeksine uygulamışlardır. Çalışma sonuçları kısıtsız etkin sınıra yaklaşabilmek için düşük risk seviyelerinde daha fazla hisseye yatırım yapılması gerekirken, risk seviyesi arttıkça elde tutulması gereken hisse senedi sayısının azaldığını göstermiştir.

Acar (2021), farklı getiri ölçümlerindeki yatırım optimizasyonu problemi için GA kullanmıştır. BİST 30 Endeksinden elde edilen getiri değerlerinin kullanıldığı çalışmada portföy optimizasyonu problemlerinde GA kullanımının zaman açısından dezavantajlı olduğu belirtilmiştir.

3. MATERYAL VE YÖNTEM

3.1.Ortalama Varyans Modeli

Markowitz (1956) tarafından geliştirilen ortalama-varyans modeli, finansal portföy optimizasyonu için kullanılan bir matematiksel çerçevedir. Markowitz'in ortalama-varyans modeli, hedeflenen bir beklenen getiri seviyesinde portföyün riskini en aza indiren bir portföy oluşturmayı hedefler.

Markowitz'in ortalama-varyans modeli, portföyün getirisini ortalama ve riskini varyans ile temsil eder. Model, portföydeki bireysel varlıkların ağırlıklarını, bunların ortalama getirilerini ve getiriler arasındaki kovaryansı dikkate alır. Markowitz'in ortalama-varyans modelinde portföyün getirisini ifade eden ortalama ve portföyün riskini temsil eden varyans sırasıyla,

$$R_p = \sum_{i=1}^N w_i \mu_i \quad (1)$$

$$\sigma_p^2 = \sum_{i=1}^N \sum_{j=1}^N w_i w_j \sigma_{ij} \quad (2)$$

eşitlikleri ile tanımlanır. Eşitlikte yer alan N gösterimi portföydeki varlık sayısını, w_i gösterimi portföydeki i . varlığın portföydeki ağırlığını (oranını), μ_i gösterimi portföydeki i . varlığın ortalamasını, σ_{ij} gösterimi ise portföydeki i . ve j . varlıkların kovaryansını göstermektedir. Portföydeki i . ve j . varlıklar arasındaki korelasyon (ilişki) katsayısı ρ_{ij} olmak üzere i . ve j . varlıkların kovaryansı,

$$\sigma_{ij} = \rho_{ij} \sigma_i \sigma_j \quad (3)$$

eşitliği ile ifade edilir. Eşitlikte yer alan σ_i ve σ_j gösterimleri portföydeki i . ve j . varlıkların standart sapmalarını göstermektedir.

Markowitz'in modern portföy optimizasyonu ortalama ve varyans arasındaki dengeye dayanmaktadır ve ikinci dereceden bir programlama modelidir. Markowitz'in standart ortalama-varyans modeli;

$$\min_w \sum_{i=1}^N \sum_{j=1}^N w_i w_j \sigma_{ij} \quad (4)$$

$$\sum_{i=1}^N w_i \mu_i = R^* \quad (5)$$

$$\sum_{i=1}^N w_i = 1 \quad (6)$$

$$w_i \geq 0, \quad i = 1, 2, \dots, N \quad (7)$$

olarak tanımlanır. Eşitlik (4), portföy riskini en küçüklenmesini ifade eden amaç fonksiyonudur. Model, belirli kısıtlar altında en iyi portföyü oluşturmayı hedefler. Bu kısıtlar Eşitlik (5)'deki belirli bir hedeflenen getiri düzeyi (R^*), Eşitlik (6)'daki varlık ağırlıklarının toplamının 1 olması ve Eşitlik (7)'deki varlık ağırlıklarının sıfırdan büyük veya eşit olması kısıtlarıdır. Modelin amacı, portföydeki riski minimize etmek ve belirli bir getiri düzeyini sağlamaktır. Bu sayede, yatırımcıya risk ve getiri tercihlerine uygun bir portföy seçeneği sunulur.

Farklı getiri R^* değerlerine göre amaç fonksiyonuna riskten kaçınma parametresi λ ($\lambda \in [0,1]$) eklenmesi ile

$$\min_w \lambda \sum_{i=1}^N \sum_{j=1}^N w_i w_j \sigma_{ij} - (1 - \lambda) \sum_{i=1}^N w_i \mu_i \quad (8)$$

$$\sum_{i=1}^N w_i = 1 \quad (9)$$

$$w_i \geq 0, \quad i = 1, 2, \dots, N \quad (10)$$

şeklinde tanımlanabilir. Riskten kaçınma parametresi $\lambda = 0$ olduğunda, riske bakılmaksızın beklenen getiri en büyüklenmekte, $\lambda = 1$ olduğunda beklenen getiriye bakılmaksızın risk en küçüklenmektedir. Riskten kaçınma parametresinin farklı değerlerine göre etkin sınır oluşturulabilmektedir.

Markowitz'in ortalama-varyans modeli, yatırımcılara portföy yönetimi ve varlık dağılımı konusunda rehberlik etmek için kullanılabilir. Ancak, modelin pratik


uygulamasında veri doğruluğu, varsayımların geçerliliği ve diğer faktörler dikkate alınmalıdır.

3.2. Genetik Algoritma (GA)

GA doğada gözlemlenen evrimsel sürece benzer şekilde çalışan arama ve eniyileme yöntemidir. GA'nın temelleri Holland (1975) tarafından atılmıştır. Genetik algoritma, doğal seçim sürecinden ilham alan bir optimizasyon algoritmasıdır. Optimizasyon ve arama problemlerine yaklaşık çözümler bulmak için kullanılır. GA, çok boyutlu uzayda belirli bir amaç fonksiyonunu en iyilemek için iterasyonlar yapar ve her iterasyonda en iyi çözümü veren çözüm vektörünün hayatta kalması esasına dayanır. GA'da probleme tek bir çözüm üretmek yerine farklı olası çözümlerden oluşan bir çözüm kümesi üretilir. Böylelikle arama uzayında aynı anda birden fazla olası çözüm değerlendirilmekte ve global çözüme ulaşma olasılığı yükselmektedir.

GA'da çok boyutlu uzayda farklı olası çözüm noktalarından oluşan küme popülasyon olarak isimlendirilmektedir. Popülasyonu oluşturan olası başka bir ifade ile aday çözüm noktaları vektör, kromozom veya birey olarak, çözüm noktasının her bir elemanı gen olarak tanımlanır. GA'da başlangıç popülasyonu oluşturulduktan sonra her bir birey için amaç (uygunluk) fonksiyonunun değeri hesaplanır ve amaç fonksiyonunu en iyileme kriterine göre her bireyin hayatta kalma olasılıkları hesaplanır. GA'da popülasyon doğal seçim, çaprazlama ve mutasyon ile yenilenir.

Doğal seçim, popülasyondaki bireylerin amaç fonksiyonu değerlerine bağlı olarak yeni bireyleri oluşturmak için ebeveyn seçme işlemidir. Çaprazlama işlemi, seçim işleminden sonra uygulanır ve ebeveyn bireylere ait genlerin yer değiştirmesine böylelikle yeni özellikte bireylerin (çocukların) oluşmasını ifade eder. Mutasyon işlemi ise yeni oluşan bireyi oluşturan genlerin mutasyon olasılığına bağlı olarak değiştirilmesi işlemidir. GA'nın genel akış şeması Şekil 3.1'de verilmiştir.



Şekil 3. 1. GA'nın genel akış şeması (Erişoğlu ve Erişoğlu, 2022-a)

3.2.1. Başlatma

Başlatma adımı, genetik algoritmadaki ilk adımdır ve kromozomlar olarak da bilinen aday çözümlerin başlangıç popülasyonunu oluşturmak için kullanılır. Başlatma adımı, algoritmanın geri kalanı için temel oluşturduğu ve nihai çözümün kalitesi üzerinde doğrudan etkisi olduğu için kritiktir. Çözümler rastgele üretilmelidir, ancak yine de geçerli ve çeşitli olmalıdır.

Başlangıç popülasyonunu başlatmanın birkaç yolu vardır:

Rastgele Başlatma: Bu yöntemde, her bir kromozom rastgele oluşturulur.

Sezgisel Başlatma: Bu yöntem, bir başlangıç popülasyonu oluşturmak için alana özgü bilginin kullanılmasını içerir. Örneğin, sorun bir üretim tesisinin yerleşimini optimize etmekse, iyi olduğu bilinen bir yerleşim planı kullanılarak başlangıç popülasyonu oluşturulabilir.

Hibrit Başlatma: Bu yöntem, popülasyonun bir bölümünü rastgele ve geri kalanını sezgisel yöntemler kullanarak oluşturulur.

Başlatma adımı popülasyonun boyutu da dikkate alınması gereken önemli bir faktördür. Daha büyük bir popülasyon çözümlerin çeşitliliğini artırır, ancak aynı zamanda

hesaplama maliyetini de arttırır. Küçük bir popülasyon ise iyi çözümler üretmek için yeterli çeşitliliğe sahip olmayabilir.

Portföy optimizasyonunda GA'da başlangıç popülasyonundaki kromozomları (aday çözümleri) oluşturan genler portföydeki varlıkların ağırlıklarıdır. Dolayısıyla başlangıç popülasyonunun her geni pozitif ve bir kromozomdaki genlerin toplamı 1 olmalıdır. Başlangıç popülasyonunun rassal olarak üretilmesinde popülasyon büyüklüğü (kromozom sayısı) M , portföydeki varlık sayısı N olmak üzere $M \times N$ boyutlu matrisi sürekli düzgün dağılımdan 0 ve 1 parametreleri ile oluştur. Her bir kromozomdaki genlerin toplamının 1 olması için sürekli düzgün dağılımdan 0 ve 1 parametreleri ile üretilen her bir kromozomdaki genler ilgili kromozomdaki genler toplamına oranlanır.

3.2.2.Değerlendirme

Değerlendirme adımı, genetik algoritmanın ikinci adımıdır ve popülasyondaki her bir kromozomun uygunluğunu değerlendirmek için kullanılır. Uygunluk işlevi, belirli bir kromozomun eldeki sorunu ne kadar iyi çözdüğünün bir ölçüsüdür.

Değerlendirme adımı, popülasyondaki çözümleri karşılaştırmanın ve hangi çözümlerin sorunu çözmek için daha uygun olduğunu belirlemenin bir yolunu sağladığı için önemlidir. En yüksek uygunluk değerlerine sahip çözümler tipik olarak çoğaltma için seçilirken, daha düşük uygunluk değerlerine sahip çözümler atılabilir veya seçilme şansı daha düşük olabilir.

Değerlendirme adımının çözmeye çalıştığınız probleme dayalı olması, uygunluk fonksiyonunun belirli probleme göre tasarlanması ve algoritmayı yazan kişi tarafından iyi anlaşılması gerektiğine dikkat etmek önemlidir.

Portföy optimizasyonunda GA'da popülasyonundaki kromozomların uygunluğu Eşitlik (8) ile verilen amaç fonksiyonu ile gerçekleştirilir.

3.2.3.Seçim

Seçim adımı, genetik algoritmanın üçüncü adımıdır ve popülasyonundaki kromozomların uygunluğuna göre en iyi kromozomları seçmek için kullanılır. Seçim operatörü tipik olarak, en uygun kromozomların üreme için seçilme olasılığının daha yüksek olduğu doğal seçim ilkelerine dayanır. Seçim adımını uygulamak için birkaç yöntem vardır, en yaygın olanlardan bazıları şunlardır:

Rulet Çarkı Seçimi: Bu yöntem, uygunluğuna bağlı olarak her bir kromozoma bir seçim olasılığı atar. Olasılık, kromozomun uygunluğu ile orantılıdır. Kromozomlar daha sonra olasılıklarına göre rastgele seçilir.

Turnuva Seçimi: Bu yöntem, popülasyondan turnuva adı verilen küçük bir kromozom grubunu rastgele seçer. Turnuvadan en iyi kromozom daha sonra üreme için seçilir.

Elit Seçim: Bu yöntem, uygunluklarına bakılmaksızın mevcut popülasyondaki en iyi kromozomların bir sonraki nesle dahil edilmesini sağlar. Şimdiye kadar bulunan en iyi çözümü kaybetmemek için yararlıdır.

Stokastik Evrensel Örnekleme (SUS): Bu yöntem, rulet çarkı seçimine benzer, ancak daha düzgün bir seçimi garanti eder, bu da tüm kromozomların eşit seçilme şansına sahip olduğu anlamına gelir.

GA'da, yeni popülasyon oluşturmak için mevcut popülasyondan çaprazlama ve mutasyon işlemine tabi tutulacak kromozomların seçilmesi gerekir. Seçilim aşamasında amaç fonksiyonunu en iyileyen kromozomların seçilme olasılığının fazla olması gerekmektedir. En küçüklemeyle dayalı bir amaç fonksiyonu için amaç fonksiyon değeri küçük olan bireylerin amaç fonksiyon değeri büyük olan bireylerden daha büyük bir seçilme olasılığına sahip olması gerekir. Portföy optimizasyonunda GA'da amaç fonksiyonu en küçüklemeyle dayalı olduğundan f_i gösterimi i . kromozomun amaç fonksiyon değeri olmak üzere i . kromozomun seçilme olasılığı

$$p_{seçilme,i} = \frac{1/f_i}{\sum_{j=1}^N (1/f_j)} \quad (11)$$

eşitliği ile belirlenir. Bu çalışmada seçim için rulet çarkı seçim yaklaşımı kullanılmıştır.

3.2.4.Çaprazlama

Çaprazlama adımı, genetik algoritmanın dördüncü adımıdır ve seçilen kromozomların genetik bilgilerini birleştirerek yeni yavrular (yeni aday çözümler) oluşturmak için kullanılır. Çaprazlama operatörü, genetik bilginin ebeveynlerden yavrulara aktarıldığı üreme sürecini simüle eder.

Çaprazlama, bir veya daha fazla yavru kromozom oluşturmak için iki ebeveyn kromozomun genetik bilgisini birleştirmek için kullanılır. Popülasyona yeni genetik varyasyonlar eklemek ve çözümlerin çeşitliliğini artırmak için kullanılır.

Geçiş adımını uygulamak için birkaç yöntem vardır, en yaygın olanlardan bazıları şunlardır:

Tek Noktalı Çaprazlama: Bu yöntem, kromozomda tek bir nokta seçer ve bu noktanın sağındaki genetik bilgiyi iki ebeveyn kromozom arasında değiştirir.

İki Noktalı Çaprazlama: Bu yöntem, kromozomda iki nokta seçer ve aralarındaki genetik bilgiyi iki ebeveyn kromozom arasında değiştirir.

Üniforma Çaprazlama: Bu yöntem, her geni bağımsız olarak belirli bir olasılıkla seçer ve iki ebeveyn kromozom arasında değiştirir.

Çok Noktalı Çaprazlama: Bu yöntem, kromozomdaki birden fazla noktayı seçer ve bunlar arasındaki genetik bilgiyi iki ebeveyn kromozom arasında değiştirir.

Çaprazlama yönteminin ve parametrelerin seçimi, çözmeye çalıştığınız özel soruna ve nihai çözümün istenen özelliklerine dayanmalıdır. Bazı yöntemler, belirli problemler için diğerlerinden daha uygun olabilir.

Ana kromozomlardan yararlı genetik bilgi kaybına da neden olabileceğinden, çaprazlama adımının dikkatle uygulanması gerektiğine dikkat etmek önemlidir. Çaprazlama oranı, ebeveyn kromozomlarından yararlı genetik bilginin korunması ile yeni genetik varyasyonların getirilmesini dengeleyecek şekilde seçilmelidir.

Seçim aşamasından sonra seçilen kromozomlardan rassal olarak ebeveyn çiftleri oluşturulur ve çaprazlama işlemi gerçekleştirilir. Ebeveyn çiftlerinin çaprazlanma işlemine tabi olup olmayacağına $[0,1]$ aralığında üretilen rassal sayının kullanıcı tarafından belirlenen çaprazlama olasılığı ile karşılaştırılması ile karar verilir. Üretilen rassal sayı çaprazlama olasılığından küçük ise çaprazlama gerçekleştirilir. Çaprazlama olasılığı genelde 0.95 veya 0.99 olarak belirlenir.

Çaprazlama işleminde ebeveyn çiftleri arasında rassal olarak belirlenen çaprazlama noktalarına göre gen değişimi gerçekleştirilir. Bu çalışmada tek noktalı çaprazlama kullanılmıştır. Portföydeki varlık sayısı N olmak üzere bir birey için $N - 1$

aralık söz konusu olduğundan çaprazlama noktasının belirlenmesinde kesikli düzgün dağılımından 1, $N - 1$ parametreleri ile rassal sayı üretilir. Üretilen rassal sayı çaprazlama noktası kabul edilir ve çaprazlama noktasından sonraki genler ebeveyn çiftleri arasında değiştirilir. Portföy optimizasyonunda bu aşamada gen değişim sonrası yeni yavrulardaki genler toplamının 1 olma koşulunu sağlamak için yavru kromozomdaki her gen kendi yavru kromozomundaki genler toplamına oranlanır. Çaprazlama noktası 1 olmak üzere 4 varlıktan oluşan bir portföyde bir ebeveyn çiftinin örnek çaprazlaması Şekil 3.2’de gösterilmiştir.

Ebeveyn Kromozom I	0.37	0.23	0.11	0.29
Ebeveyn Kromozom II	0.16	0.22	0.35	0.27
Yavru Kromozom I	0.37	0.22	0.35	0.27
Yavru Kromozom II	0.16	0.23	0.11	0.29

Kısıtlar İçin Uyarlama				
Yavru Kromozom I	0.306	0.182	0.289	0.223
Yavru Kromozom II	0.203	0.291	0.139	0.367

Şekil 3.2. GA’da portföy optimizasyonu için tek noktalı çaprazlama örneği

3.2.5. Mutasyon

Mutasyon, yavru kromozomların genetik bilgisine küçük rastgele değişiklikler getirmek için kullanılır. Popülasyona yeni genetik varyasyonlar eklemek ve çözümlerin çeşitliliğini artırmak için kullanılır. Mutasyon işlemi ile optimizasyon probleminin çözüm alanını yön değişikliklerini sağlayarak yerel en iyi çözüme takılmayı önlemektir.

Mutasyon adımını uygulamak için birkaç yöntem vardır, en yaygın olanlardan bazıları şunlardır:

Bit Çevirme Mutasyonu: Bu yöntem, kromozomda rastgele bir bit seçer ve çevirir. Çoğunlukla kromozom ikili dizi olarak temsil edildiğinde kullanılır.

Gauss Mutasyonu: Bu yöntem, bir Gauss dağılımından örneklenen rastgele bir değeri kromozomda rastgele seçilen bir gene ekler.

Polinom Mutasyon: Bu yöntem, kromozomda rastgele seçilen bir geni, bir polinom fonksiyonuna göre hesaplanan bir değerle değiştirir.

Tekdüze Mutasyon: Bu yöntem, kromozomda rastgele bir gen seçer ve onu rastgele oluşturulmuş yeni bir değerle değiştirir.

Mutasyon yönteminin ve parametrelerin seçimi, çözmeye çalıştığınız özel soruna ve nihai çözümün istenen özelliklerine bağlı olmalıdır. Bazı yöntemler, belirli problemler için diğerlerinden daha uygun olabilir.

Yavru kromozomlardan yararlı genetik bilgi kaybına da neden olabileceğinden, mutasyon adımının dikkatle uygulanması gerektiğine dikkat etmek önemlidir. Mutasyon oranı, yavru kromozomlardan yararlı genetik bilginin korunması ile yeni genetik varyasyonların ortaya çıkışını dengeleyecek şekilde seçilmelidir. Çok yüksek bir mutasyon oranı, genetik bilginin zamanla bozulmasına neden olabilirken, çok düşük bir mutasyon oranı, popülasyonun yetersiz bir çözüme yaklaşmasına neden olabilir.

Mutasyon işleminde her gen için $[0,1]$ aralığında rassal bir sayı üretilir. Üretilen rassal sayı mutasyon olasılığından daha küçük ise gen mutasyon işlemine tabi tutulur. Mutasyon olasılığı genelde 0.01 gibi küçük bir olasılıkla ifade edilir. Mutasyona uğrayacak gen için sürekli düzgün dağılımından $-1, 1$ parametreleri ile rassal sayı üretilir ve üretilen rassal sayı kullanıcı tarafından algoritma öncesi $[0,1]$ aralığında belirlenen Δ katsayısı ile çarpılarak gen değerine eklenir. Portföy optimizasyonunda mutasyon işlemi sonrası negatif olmama ve ağırlıklar toplamının 1 olma koşulu kontrol edilmelidir. Eğer gen değeri mutasyon işlemi sonrası negatif oluyorsa gen değeri 0 olarak alınır. Ayrıca mutasyon işlemi sonrası kromozomu oluşturan gen değerleri kromozomdaki genler toplamına oranlanarak ağırlıklar toplamının 1 olma koşulu sağlanır. Mutasyon olasılığı 0.01 olmak üzere 4 varlıktan oluşan bir portföyde yavru kromozomlar için örnek bir mutasyon gösterimi Şekil 3.3'te verilmiştir.

Şekil 3.3'te yavru kromozomlardaki her gen için $[0,1]$ aralığında rassal sayılar üretilmiştir. Şekil 3.3'te incelendiğinde yavru kromozom I 'deki 1. gen ve yavru kromozom II 'deki 2. gen için üretilen rassal sayılar 0.01'den küçük olduğundan mutasyon işlemine tabii tutulduğu görülmektedir. Yavru kromozom I 'deki 1. gen değer mutasyon işlemi sonucu -0.218 değerini almıştır. Gen değeri mutasyon işlemi sonrası negatif oluyorsa gen değeri 0 olarak alınmıştır. Mutasyon işlemi sonrası kromozomu oluşturan gen değerleri kromozomdaki genler toplamına oranlanarak ağırlıklar toplamının 1 olma koşulu sağlanmıştır.

Her gen için mutasyona işleminin uygulanıp uygulanmayacağını belirlemek için üretilen [0,1] aralığındaki rassal sayılar				
	0.008	0.123	0.942	0.421
Yavru Kromozom I	0.306	0.182	0.289	0.223
Yavru Kromozom II	0.203	0.291	0.139	0.367
Her gen için mutasyona işleminin uygulanıp uygulanmayacağını belirlemek için üretilen [0,1] aralığındaki rassal sayılar				
	0.237	0.002	0.623	0.512
Yavru Kromozom I	-0.218	0.182	0.289	0.223
Yavru Kromozom II	0.203	0.207	0.139	0.367
Yavru Kromozom I	0	0.182	0.289	0.223
Yavru Kromozom II	0.203	0.207	0.139	0.367
Yavru Kromozom I	0	0.262	0.417	0.321
Yavru Kromozom II	0.221	0.226	0.152	0.401

Şekil 3.3. GA'da portföy optimizasyonu için mutasyon örneği

3.2.5. Tekrarlama

Tekrarlama adımları, algoritmanın genetik operatörleri (Seçim, Çaprazlama ve Mutasyon) çoklu nesiller için popülasyona yinelemeli olarak uyguladığı bir genetik algoritmadaki altıncı adımdır. Bu adımın amacı, tatmin edici bir çözüm bulmak veya bir durdurma kriterine ulaşmaktır.

Nesil sayısı, dikkatle seçilmesi gereken bir parametredir. Daha fazla sayıda nesil, optimal bir çözüm bulma şansını artırabilir, ancak aynı zamanda hesaplama maliyetini de artırır. Öte yandan, tatmin edici bir çözüm bulmak için az sayıda nesil yeterli olmayabilir. Durdurma kriteri, çözmeye çalıştığınız belirli soruna ve nihai çözümün istenen özelliklerine göre seçilmelidir.

Her nesilde, algoritma seçim, çaprazlama ve mutasyon operatörlerini popülasyona uygular. Bu adımlar, tatmin edici bir çözüm bulunana veya bir durdurma kriteri sağlanana kadar birçok nesil boyunca tekrarlanır. Durdurma kriteri, bulunan en iyi çözümün uygunluğuna, nesil sayısına, geçen süreye veya bu faktörlerin bir kombinasyonuna dayanabilir.

3.2.6.Çözüm

Sonuç adımı, genetik algoritmanın popülasyondaki en uygun birey olarak kabul edilen bulunan en iyi çözümü döndürdüğü son adımdır.

Tekrarlanan adımlardan sonra, algoritma birden fazla nesilden geçti ve popülasyonu geliştirdi. Bulunan en iyi çözüm, nihai popülasyonda en yüksek uygunluk değerine sahip birey olarak kabul edilir. Bu çözüm, algoritmanın çıktısı olarak döndürülür.

Genetik algoritma tarafından bulunan çözümün genellikle genel optimal çözüm değil, yaklaşık bir çözüm olduğuna dikkat etmek önemlidir. Genetik algoritma buluşsal bir yöntemdir, iyi çözümler bulmak için tasarlanmıştır, ancak en iyi çözümler olmayabilir.

Algoritma her çalıştırıldığında döndürülen çözümün aynı olmayabileceğini, genetik algoritmanın stokastik bir yöntem olduğunu ve nihai çözümün başlangıç popülasyonuna, genetik operatörlere ve durdurma kriterine bağlı olduğunu da belirtmek gerekir.

Bazı durumlarda, algoritma birden fazla çözüm döndürebilir, buna Pareto-optimal çözümler denir ve bunlar başka herhangi bir çözümün baskın olmadığı çözümlerdir, çok amaçlı bir optimizasyon probleminde optimal çözümlerdir.


Döndürülen çözümü değerlendirmek ve bunu diğer çözümlerle ve sorunun gereksinimleriyle karşılaştırmak önemlidir.

3.3. Parçacık Sürü Optimizasyonu (PSO)

PSO, sürü halinde hareket kuş, balık ve böceklerden esinlenilerek Kennedy ve Eberhart (1995) tarafından geliştirilen sürü zekasını temel alan popülasyona dayalı stokastik optimizasyon tekniğidir.

PSO, hayali bir senaryoda iyi açıklanabilir (Zhu ve ark., 2011): Bir grup kuş yiyecek aramak için bir alanda uçuyor ve bu alanda yalnızca bir parça yiyecek var. Gruptaki her kuş, yiyeceğin tam yerini bilmiyor, ancak yiyecekle kendileri arasındaki mesafenin farkındalar. Bu sayede yiyeceği bulmanın en kolay yolu, yiyeceğe en yakın olanı takip etmektir.

PSO algoritmasında olası her çözüm, arama uzayında bir parçacık ile temsil edilir ve parçacıklardan oluşan popülasyona sürü denir. PSO algoritması temel olarak sürüde bulunan parçacıkların konumunun, parçacığın kendi en iyi konumuna ve aynı zamanda algoritmada o ana kadar elde edilen en iyi çözüme sahip olan parçacığın konumuna yaklaştırılması esasına dayanır. PSO algoritmasının genel akış şeması Şekil 3.4'te verilmiştir.



Şekil 3.4. PSO algoritmasının genel akış şeması (Erişoğlu ve Erişoğlu, 2022-a)

PSO algoritması sürünün oluşturulması ile başlar ve sürüdeki her parçacık için amaç fonksiyonu değerinin hesaplanması ile devam eder. Amaç fonksiyonu değerine göre sürü içerisinde amaç fonksiyonunu en iyileyen parçacık belirlenir. Bu parçacık başlangıç adımı küresel en iyi çözümü sağlayan parçacık olarak tanımlanır. PSO algoritmasında parçacıkların konumunun değişimi hız vektörüne bağlı olarak gerçekleştirilir. Parçacık hızlarının güncellemesi

$$v_i^{(t+1)} = wv_i^{(t)} + c_1rand_1(\mathbf{pbest}_i^{(t)} - \mathbf{p}_i^{(t)}) + c_2rand_2(\mathbf{gbest}^{(t)} - \mathbf{p}_i^{(t)}) \quad (12)$$

eşitliği ile gerçekleştirilir. Eşitlikte yer alan $\mathbf{p}_i^{(t)}$ gösterimi t . tekrardaki sürünün i . parçacığını, $\mathbf{pbest}_i^{(t)}$ gösterimi t . tekrarda i . parçacığın çözüme en yakın olduğu noktadaki değerlerini, $\mathbf{gbest}^{(t)}$ gösterimi t . tekrarda o ana kadar en iyi çözüm değerine sahip parçacığı, w gösterimi eylemsizlik sabiti, $rand_1$ ve $rand_2$ gösterimleri $[0,1]$ aralığında rassal sayıları, c_1 ve c_2 gösterimleri sırasıyla kişisel ve sosyal öğrenme katsayıları olarak adlandırılan pozitif sabitleri göstermektedir. Başlangıç aşamasında hız vektörleri sıfır vektörü olarak seçilebilir.

PSO algoritmasında hız güncellemesi sonrası sürü güncellemesi

$$X^{(t+1)} = X^{(t)} + V^{(t)} \quad (13)$$

eşitliği ile gerçekleştirilir. Eşitlikte yer alan $X^{(t)}$ gösterimi t . tekrardaki sürü matrisini, $V^{(t)}$ gösterimi ise t . tekrarda elde edilen hız matrisini göstermektedir. Sürü güncellemesinde her parçacığın toplamının 1 ve parçacığın her elemanının negatif olmama koşulu kontrol edilmelidir. Eğer parçacık içerisinde negatif değer varsa o değer 0 yapılmalı ve sonrasında her eleman parçacığın toplamına oranlanmalıdır.

Sürü güncellemesinden sonra sürü içerisindeki en iyi çözüm belirlenir ve önceki en iyi küresel çözüm ile karşılaştırılır. Eğer sürüdeki en iyi çözüm küresel çözümden daha iyi ise küresel çözüm $\mathbf{gbest}$ güncellenir. Aynı zamanda parçacıkların çözüme en yakın oldukları konumları da yani $\mathbf{pbest}_i$ vektörü de güncellenir. Bunun için sürüdeki her parçacığın amaç fonksiyonu değeri, parçacıkların o ana kadar çözüme en yakın değerleri ile karşılaştırılır. Sürü ve hız güncellemesi belirlenen durdurma kuralı sağlayıncaya kadar tekrarlanır.

3.4.Yapay Arı Kolonisi (ABC)

Yapay arı kolonisi (ABC) algoritması bal arılarının yiyecek arama alışkanlıkları temel olarak Karaboğa (2005) tarafından optimizasyon problemlerinin çözümü için geliştirilen popülasyon tabanlı meta sezgisel bir algoritmadır. ABC algoritmasının başlıca faydaları, yalnızca üç kontrol faktörünü kullanması gerçeğinden gelir: koloni boyutu,

maksimum döngü sayısı ve limit. Meta sezgisel algoritmaların performansı parametre sayısına ve seçimine bağlı olduğundan, bu karmaşıklığı azaltır.

ABC algoritmasında üç tür yapay arı kullanılır: işçi arılar, gözlemciler ve kâşifler. Çalışan bir arı, bir besin kaynağının (potansiyel bir çözüm) yakınında durur ve bölgeyi inceler. Gözlemciler, çalışan arılardan öğrendikleri bilgilere göre bir besin kaynağına atanır. Kaşifler, önceden belirlenmiş bir sayıda döngüden sonra yeni, rastgele bir besin kaynağını değiştirir (Bacanin ve Tuba, 2012).

ABC ve diğer sürü zekâsı algoritmaları arasındaki temel ayrım, potansiyel çözümleri temsil etmek için popülasyon üyelerinden ziyade besin kaynaklarının kullanılması gerçeğine dayanmaktadır. ABC algoritması besin kaynaklarının yerlerinin rassal olarak üretilmesi ile başlar. Portföy optimizasyonunda aday çözüm değerlerini ifade eden besin kaynakları $\mathbf{x}_i$ vektörü ile gösterildiğinde portföydeki varlık sayısı D olmak üzere $\mathbf{x}_i$ vektörünün her bir elemanı sürekli düzgün dağılımdan 0 ve 1 parametreleri ile rassal olarak oluşturulur. Varlık ağırlıklarının toplamının 1 olma koşulu göz önünde bulundurularak rassal olarak üretilen vektör elemanları vektör toplamına oranlanır. ABC algoritmasında popülasyon büyüklüğü SN olmak üzere $SN \times D$ sayıda besin kaynağı oluşturulur.

ABC algoritmasında uygunluk değeri f_i , $\mathbf{x}_i$ için Eşitlik (8)'de verilen amaç fonksiyonunun değeri olmak üzere

$$uygunluk_i = \frac{1}{1 + f_i} \quad (14)$$

eşitliği ile hesaplanır. Eşitlik (14)'e göre amaç fonksiyonunu en küçükleyen besin kaynakları, uygunluk değeri en yüksek olan besin kaynaklarıdır.

ABC algoritmasında görevli arılar ilgilendiği besin kaynağının komşuluğunda yeni bir besin kaynağı belirler ve çözüm değerini hesaplar. Elde edilen çözüm daha iyi ise hafızaya alınır. Yeni besin kaynağı

$$v_{ij} = x_{ij} + \emptyset(x_{ij} - x_{kj}) \quad (15)$$

eşitliği ile oluşturulur. Burada $\emptyset$ gösterimi -1 ile 1 arasında sürekli düzgün dağılımdan üretilen rassal bir sayıyı göstermektedir. Eşitlik (15)'de yer alan i indisinin değeri 1 ve SN

parametreleri ile kesikli düzgün dağılımdan rassal olarak üretilirken, j indisinin değeri 1 ve D parametreleri ile kesikli düzgün dağılımdan rassal olarak üretilir. Eşitlik (15)'deki k indisi GA'daki seçime benzer şekilde rulet çarkı seçimi ile belirlenir. Yeni üretilen besin kaynağının portföy optimizasyonundaki koşullara uyumu için eğer $v_{ij} < 0$ ise $v_{ij} = 0$ alınır. Yeni belirlenen v_{ij} besin kaynağı $\mathbf{x}_i$ vektörünün j . elemanı olarak yerleştirilir ve portföy optimizasyonundaki koşullara uyumu sağlanarak yeni $\mathbf{x}_{yeni}$ vektörü oluşturulur.

ABC algoritmasında yeni oluşturulan $\mathbf{x}_{yeni}$ vektörünün uygunluk değeri, $\mathbf{x}_i$ vektörünün uygunluk değerinden daha büyükse yani $uygunluk_{yeni} > uygunluk_i$ ise $\mathbf{x}_i$ vektörü $\mathbf{x}_{yeni}$ vektörü olarak güncellenir.

ABC algoritmasının her bir iterasyonunda besin kaynaklarının yarısı yenilenir. Algoritma istenilen durdurma kuralı sağlanıncaya kadar tekrarlanır.

3.5. Diferansiyel Gelişim Algoritması

DE algoritması, Storn ve Price (1997) tarafından optimizasyon problemlerinin çözümü amacıyla geliştirilen popülasyon tabanlı meta-sezgisel bir algoritmadır. DE algoritması, zaman içinde bir amaç fonksiyonunu en aza indirmek için bir popülasyon üzerinde biyolojiden ilham alan çaprazlama, mutasyon ve seçim süreçlerini kullanan bir genetik algoritmadır.

DE algoritmasının başlangıç aşamasında en küçükleme dayalı optimizasyon problemindeki değişken sayısı d ve kullanıcı tarafından belirlenen alternatif çözüm sayısı N olmak üzere rastgele olarak $N \times d$ boyutlu alternatif çözüm kümesi oluşturulur. Alternatif çözümler için amaç fonksiyonunun değerleri belirlenir ve bu değerler arasından en küçük değere sahip alternatif çözüm o an için en iyi çözüm $\mathbf{x}_{enk}$ olarak belirlenir. Daha sonrasında alternatif çözümler yinelemeli olarak iyileştirilmeye çalışılır. Alternatif çözümlerin iyileştirilmesi mutasyon ve çaprazlama işlemi ile gerçekleştirilir (Erişoğlu ve Erişoğlu, 2022-b). Mutasyon işlevinde,

$$\mathbf{x}_{capraz} = \mathbf{x}_{enk} + F(\mathbf{x}_{r1} - \mathbf{x}_{r2}) \quad (16)$$

eşitliği ile çaprazlamada kullanılacak çaprazlama çözümü oluşturulur. Eşitlik (16)'da yer alan $\mathbf{x}_{r1}$ ve $\mathbf{x}_{r2}$ alternatif çözüm kümesinden rastgele belirlenen çözümleri gösterirken

$F \in [0,2]$ ölçekleme faktörüdür. Seçili alternatif çözüm $\mathbf{x}_S$ ile $\mathbf{x}_{\text{çapraz}}$ arasında $i = 1, 2, \dots, d$ olmak üzere çaprazlama işlevi

$$x_{\text{yeni},i} = \begin{cases} x_{\text{çapraz},i} & \text{eğer } rand < CR \\ x_{S,i} & \text{eğer } rand \geq CR \end{cases} \quad (17)$$

eşitliği ile gerçekleştirilir. Eşitlik (17)'de yer $rand$ 0 ile 1 aralığında rastgele oluşturulan sayı, $CR \in (0,1)$ çaprazlama oranını ifade etmektedir. Eşitlik (15) ile oluşturulan çözüm $\mathbf{x}_{\text{yeni}}$ için amaç fonksiyonunun değeri, seçili alternatif çözümün amaç fonksiyonunun değerinden daha küçük $f(\mathbf{x}_{\text{yeni}}) < f(\mathbf{x}_S)$ ise seçili çözüm yeni çözüm ile değiştirilir. Algoritma ya istenilen döngü sayısına ulaşılnca ya da iki ardışık döngüde elde edilen en iyi çözümler arasındaki mutlak fark istenilen farktan küçük olunca sonlandırılır. Algoritma sonunda elde edilen en iyi çözüm optimum çözüm olarak belirlenir.

4. UYGULAMA

Çalışmanın uygulama bölümünde Markowitz'in ortalama-varyans modelinde Eşitlik (8) ile belirtilen amaç fonksiyonunda riskten kaçınma parametresi $\lambda = 0.5$ alınarak Eşitlik (9)-(10)'daki kısıtlar göz önünde bulundurularak iki farklı veri setinde GA, PSO, ABC ve DE algoritmaları ile portföy optimizasyonu gerçekleştirilecektir. Portföy optimizasyonunda kullanılacak algoritmalar için MATLAB programında kod yazımı gerçekleştirilmiştir.

4.1. BİST30 Örneğinde Meta Sezgisel Algoritmalarla Portföy Optimizasyonu

Çalışmanın uygulama bölümünde ilk olarak Borsa İstanbul'da işlem gören piyasa ve işlem hacmi bakımından en yüksek 30 hisse senedinden oluşan BİST30'da yer alan hisse senetlerinin 03.01.2020 ile 14.12.2022 tarihleri arasındaki günlük getiri değerlerinden oluşan veri seti için incelenen meta sezgisel algoritmalarla portföy optimizasyonu gerçekleştirilmiştir. Veri seti <https://tr.investing.com/> internet sayfasından derlenmiştir. BİST30'da yer alan hisse senetlerinin günlük getiri değerlerine ilişkin tanımlayıcı istatistikler Tablo 4.1' de verilmiştir.

Tablo 4.1'de yer alan BİST30 hisse senetlerinin günlük getiri değerlerine ilişkin tanımlayıcı istatistikleri incelediğimizde, hisse senetlerinin genel olarak farklı performanslar sergilediğini görmekteyiz. Ortalama getiri değerleri hisse senetleri arasında değişiklik gösterirken, standart sapma değerleri de hisse senetlerinin risk düzeylerini yansıtmaktadır.

Sonuçlar incelendiğinde, bazı hisse senetlerinin daha yüksek getiriler ve daha düşük risklerle ön plana çıktığı görülmektedir. Örneğin, GUBRF, HEKTS ve SASA hisse senetleri, yüksek ortalama getiri değerleri ve nispeten düşük standart sapma değerleriyle dikkat çekmektedir. Bu hisse senetleri, portföy optimizasyonunda potansiyel olarak iyi performans gösterebilecek hisseler olarak değerlendirilebilir.


Diğer yandan, bazı hisse senetlerinin daha yüksek risklerle birlikte orta düzeyde getiriler sunduğu görülmektedir. Örneğin, PGSUS ve TTKOM hisse senetleri, yüksek standart sapma değerleriyle birlikte ortalama getiri sağlamaktadır. Bu hisse senetleri, daha riskli yatırımlar olarak değerlendirilebilir ve yatırımcılar tarafından dikkatlice değerlendirilmelidir.

Tablo 4.1. BİST30’da yer alan hisse senetlerinin günlük getiri değerlerine ilişkin tanımlayıcı istatistikler


	Ortalama	Standart Sapma	En Küçük	En Büyük	Değişim Aralığı	Birinci Çeyreklik	Medyan	Üçüncü Çeyreklik
AKBNK	0.0016	0.0271	-0.1002	0.1000	0.2002	-0.0117	0.0000	0.0141
AKSEN	0.0047	0.0304	-0.0997	0.0999	0.1996	-0.0127	0.0020	0.0228
ARCLK	0.0026	0.0237	-0.0999	0.0998	0.1997	-0.0100	0.0018	0.0141
ASELS	-0.0020	0.0269	-0.1160	0.1112	0.2272	-0.0154	-0.0007	0.0110
BIMAS	0.0018	0.0218	-0.1000	0.0991	0.1992	-0.0100	0.0013	0.0137
EKGYO	0.0028	0.0292	-0.0999	0.0998	0.1997	-0.0114	0.0000	0.0157
EREGL	0.0027	0.0257	-0.0998	0.0998	0.1996	-0.0115	0.0011	0.0156
FROTO	0.0033	0.0306	-0.0999	0.1000	0.1999	-0.0138	0.0011	0.0198
GARAN	0.0017	0.0275	-0.0999	0.1000	0.1999	-0.0119	0.0000	0.0153
GUBRF	0.0051	0.0357	-0.0999	0.1582	0.2582	-0.0141	0.0000	0.0217
HEKTS	0.0057	0.0347	-0.0999	0.1002	0.2001	-0.0146	0.0020	0.0201
ISCTR	0.0024	0.0283	-0.1001	0.0999	0.2000	-0.0115	0.0000	0.0151
KCHOL	0.0023	0.0247	-0.0997	0.0944	0.1940	-0.0109	0.0027	0.0162
KOZAA	0.0026	0.0312	-0.1027	0.1157	0.2183	-0.0153	0.0019	0.0182
KOZAL	0.0031	0.0302	-0.1000	0.1000	0.2000	-0.0143	0.0008	0.0173
KRDMD	0.0030	0.0314	-0.0998	0.1000	0.1998	-0.0151	0.0007	0.0209
PETKM	0.0028	0.0281	-0.0997	0.0999	0.1996	-0.0124	0.0023	0.0177
PGSUS	0.0029	0.0357	-0.1129	0.1000	0.2129	-0.0162	0.0005	0.0179
SAHOL	0.0024	0.0237	-0.0996	0.0997	0.1993	-0.0099	0.0013	0.0150
SASA	0.0056	0.0384	-0.1488	0.1522	0.3010	-0.0151	0.0018	0.0213
SISE	0.0032	0.0251	-0.1000	0.1209	0.2209	-0.0101	0.0015	0.0157
TAVHL	0.0021	0.0290	-0.1000	0.1000	0.2000	-0.0145	0.0005	0.0160
TCELL	0.0017	0.0237	-0.1000	0.0996	0.1996	-0.0108	0.0000	0.0144
THYAO	0.0034	0.0281	-0.1176	0.1000	0.2175	-0.0118	0.0018	0.0173
TKFEN	0.0016	0.0264	-0.1003	0.1000	0.2003	-0.0117	0.0009	0.0153
TOASO	0.0031	0.0275	-0.1000	0.1002	0.2002	-0.0127	0.0027	0.0182
TTKOM	0.0021	0.0272	-0.1332	0.1001	0.2333	-0.0112	0.0015	0.0154
TUPRS	0.0022	0.0258	-0.0999	0.0998	0.1997	-0.0113	0.0006	0.0153
VESTL	0.0029	0.0283	-0.1697	0.1009	0.2705	-0.0120	0.0014	0.0172
YKBNK	0.0025	0.0288	-0.1000	0.0999	0.1999	-0.0132	0.0000	0.0176

Sonuç olarak, hisse senedi portföyü optimizasyonunda yatırımcılar, farklı hisse senetlerinin performanslarını ve risklerini dikkate almalıdır. Tablo 4.1'deki veriler, hisse senetlerinin getiri ve risk düzeyleri hakkında fikir vermektedir. Ancak, yatırımcılar portföylerini oluştururken tek başına bu istatistiklere dayanmamalı, aynı zamanda kendi risk toleransları, yatırım hedefleri ve diğer faktörleri de dikkate almalıdır. Yatırımcılar, portföylerini çeşitlendirmek ve risklerini yönetmek için birden fazla hisse senedi kullanabilirler.

BİST30’da yer alan hisse senetlerinin günlük getiri değerlerinin zaman serisi grafikleri Şekil 4.1’de verilmiştir.




Şekil 4.1. BİST30’da yer alan hisse senetlerinin günlük getiri değerlerinin zaman serisi grafikleri



Şekil 4.1. devam. BİST30’da yer alan hisse senetlerinin günlük getiri değerlerinin zaman serisi grafikleri

BİST30’da yer alan hisse senetlerinin ilgili zaman aralığında günlük getirileri için kutu grafikleri Şekil 4.2’de verilmiştir.



Şekil 4.2. BİST30’da yer alan hisse senetlerinin günlük getirilerinin kutu grafiği

Bu çalışmada, hisse senetlerinin günlük getiri değerlerinin kutu grafiği analizi ile incelenmesi hedeflenmiştir. Kutu grafiği analizi, her bir hisse senedinin günlük getiri değerlerinin istatistiksel dağılımını görselleştirmek ve aykırı değerleri belirlemek için kullanılan bir yöntemdir.

Çalışmanın sonuçları, hisse senetlerinin günlük getiri değerleri arasında belirgin farklılıklar olduğunu göstermektedir. Bu farklılıklar, her bir hisse senedinin risk ve getiri profili hakkında önemli bilgiler sunmaktadır.

Öncelikle, HEKTS hisse senedinin günlük getiri değerlerinin diğer hisse senetlerine kıyasla daha yüksek bir ortalama değere sahip olduğu tespit edilmiştir. Bu, yatırımcılar için HEKTS hisse senedinin potansiyel olarak daha yüksek getiri sağlayabileceği anlamına gelir. Ayrıca, HEKTS hisse senedinin günlük getiri değerlerinin daha düşük bir standart sapma ile daha düşük bir değişkenlik gösterdiği görülmüştür. Bu durum, hisse senedinin fiyat hareketlerinin daha istikrarlı ve tahmin edilebilir olduğunu göstermektedir.

Öte yandan, ASELS hisse senedinin günlük getiri değerleri diğer hisse senetlerine kıyasla daha düşük bir ortalama ve daha yüksek bir standart sapma ile daha yüksek bir değişkenlik göstermektedir. Bu durum, ASELS hisse senedinin daha yüksek risk taşıdığını ve fiyat hareketlerinin daha volatil olduğunu göstermektedir. Bu nedenle, ASELS hisse senedi yatırımcıları için potansiyel olarak daha fazla risk içeren bir seçenek olabilir.

Ayrıca, kutu grafiği analizi sonucunda aykırı değerlerin varlığı gözlemlenmiştir. Aykırı değerler, hisse senedinin beklenmeyen olaylar veya piyasa koşulları karşısında daha belirgin fiyat değişikliklerine maruz kalabileceğini göstermektedir. Bu durum, yatırımcıların risk yönetimi stratejilerini gözden geçirmelerini ve aykırı değerlerin potansiyel etkilerini dikkate almalarını vurgulamaktadır.

Sonuç olarak, bu çalışma hisse senetlerinin günlük getiri değerlerinin kutu grafiği analizi ile incelenmesinin yatırımcılara önemli bilgiler sağlayabileceğini göstermektedir. Bu analiz yöntemi, yatırımcıların hisse senetlerinin risk ve getiri profillerini daha iyi anlamalarına ve bilinçli yatırım kararları vermelerine yardımcı olabilir. Ancak, kutu grafiği analizi tek başına yeterli değildir ve diğer analiz yöntemleri ve faktörleri dikkate almak önemlidir.

BİST 30 Endeksinde yer alan hisse senetlerinin portföy optimizasyonu için GA'da popülasyon büyüklüğü 100, çaprazlama oranı 0.99, mutasyon oranı 0.2, $\Delta = 0.95$ ve

tekrar sayısı 10000 alınmıştır. PSO algoritmasında parçacık sayısı 100, $w = 1$, $c_1 = c_2 = 2$ ve tekrar sayısı 1000 alınmıştır. DE algoritmasında popülasyon büyüklüğü 100, $F = 0.8$, $CR = 0.5$ ve tekrar sayısı 1000 alınmıştır. ABC algoritmasında $SN = 100$ ve tekrar sayısı 100 alınmıştır. BİST30’da yer alan hisse senetlerinin 03.01.2020 ile 14.12.2022 tarihleri arasındaki günlük getiri değerlerinden oluşan veri seti için GA, PSO, ABC ve DE algoritmaları ile gerçekleştirilen optimizasyon sonucu elde edilen ağırlıklar, amaç fonksiyonunun değeri, beklenen getiri ve risk değerleri Tablo 4.2’de verilmiştir.

Tablo 4.2. Farklı meta sezgisel algoritmalarla portföy optimizasyonundan elde edilen sonuçlar (BIST30)

	AĞIRLIKLAR			
	GA	PSO	DE	ABC
AKBNK	0	0	0	0
AKSEN	0	0.025831929	0.031687564	0.03168741
ARCLK	0	0	0	0
ASELS	0	0	0	0
BIMAS	0	0	0	0
EKGYO	0	0	0	0
EREGL	0	0	0	0
FROTO	0	0	0	0
GARAN	0	0	0	0
GUBRF	0.336914154	0.188339506	0.173167097	0.173166964
HEKTS	0.57575753	0.522880883	0.528212119	0.528212291
ISCTR	0.01193458	0	0	0
KCHOL	0	0	0	0
KOZAA	0	0	0	0
KOZAL	0	0	0	0
KRDMD	0.00879832	0	0	0
PETKM	0	0	0	0
PGSUS	0	0	0	0
SAHOL	0	0	0	0
SASA	0.06366076	0.262947681	0.266933219	0.266933334
SISE	0	0	0	0
TAVHL	0.002934659	0	0	2.26E-14
TCELL	0	0	0	0
THYAO	0	0	0	0
TKFEN	0	0	0	0
TOASO	0	0	0	0
TTKOM	0	0	0	0
TUPRS	0	0	0	0
VESTL	0	0	0	0
YKBNK	0	0	0	0
Amaç Fonksiyonu	-0.00465947	-0.00477319	-0.00477347	-0.00477347
Port Ortalama Getiri	0.00544347	0.00554895	0.00555173	0.00555173
Risk	0.02800001	0.02785239	0.02789727	0.02789728

GA algoritması kullanılarak oluşturulan portföyde beş farklı hisse senedi bulunmaktadır ve her bir hisse senedinin ağırlığı belirlenmiştir. Örneğin, GUBRF hisse senedinin ağırlığı %33,69, HEKTS hisse senedinin ağırlığı %57,58, ISCTR hisse senedinin ağırlığı %1.19, KRDMD hisse senedinin ağırlığı %0,88 ve SASA hisse senedinin ağırlığı %6.37'dir. Amaç fonksiyonunun değeri-0.00465947, portföyün ortalama getirisi 0.00544347 ve riski 0.02800001 olarak belirlenmiştir.

PSO algoritması kullanılarak oluşturulan portföyde dört farklı hisse senedi bulunmaktadır. Bu hisse senetlerinin ağırlıkları şu şekildedir: AKSEN (%2.58), GUBRF (%18,83), HEKTS (%52,29) ve SASA (%26,29). Amaç fonksiyonunun değeri-0.00477319, portföyün ortalama getirisi 0.00554895 ve riski 0.02785239 olarak belirlenmiştir.

DE algoritması kullanılarak oluşturulan portföyde dört farklı hisse senedi bulunmaktadır ve ağırlıkları şu şekildedir: AKSEN (%3.17), GUBRF (%17.32), HEKTS (%52,82) ve SASA (%26,69). Amaç fonksiyonunun değeri-0.00477347, portföyün ortalama getirisi 0.00555173 ve riski 0.02789727 olarak belirlenmiştir.

ABC algoritması kullanılarak oluşturulan portföyde beş farklı hisse senedi bulunmaktadır ve ağırlıkları şu şekildedir: AKSEN (%3.17), GUBRF (%17.32), HEKTS (%52,82), SASA (%26,69) ve TAVHL (%0). Amaç fonksiyonunun değeri-0.00477347, portföyün ortalama getirisi 0.00555173 ve riski 0.02789728 olarak belirlenmiştir.

Sonuçlar incelendiğinde, PSO, DE ve ABC algoritmalarının benzer sonuçlar verdiği görülmektedir. Amaç fonksiyonunun değeri incelendiğinde PSO, DE ve ABC algoritmalarının GA'dan daha başarılı olduğu görülmüştür.

BİST 30 Endeksi için gerçekleştirilen uygulamada HEKTS hisse senedi tüm algoritmaların oluşturduğu portföylerde en yüksek ağırlığa sahiptir. GUBRF ve SASA hisse senetleri de portföye önemli katkı sağlamaktadır.

Sonuç olarak, bu çalışma farklı algoritmaların portföy optimizasyonunda kullanılmasını incelemekte ve elde edilen sonuçları karşılaştırmaktadır. Her bir algoritma belirli bir amaç fonksiyonuna ulaşmak için optimize edilmekte ve portföyün ortalama getirisi ve riski dikkate alınarak en uygun hisse senedi dağılımı belirlenmektedir. Bu çalışma, yatırımcılara farklı algoritmaların kullanımını ve sonuçlarını değerlendirme imkânı sunarak, en uygun portföy seçiminde yardımcı olmaktadır.

4.2. S&P500 Örneğinde Meta Sezgisel Algoritmalarla Portföy Optimizasyonu


Dört farklı meta sezgisel algoritmanın portföy optimizasyonunda kullanımına ilişkin ikinci uygulama S&P500’te yer alan 25 hisse senedinin günlük getiri değerlerine ilişkin gerçekleştirilecektir. S&P500’te yer alan 25 hisse senedinin günlük getiri değerlerine ilişkin tanımlayıcı istatistikler Tablo 4.3’de verilmiştir.

Tablo 4.3. S&P500’te yer alan 25 hisse senetlerinin günlük getiri değerlerine ilişkin tanımlayıcı istatistikler


	Ortalama	Standart Sapma	En Küçük	En Büyük	Değişim Aralığı	Birinci Çeyreklik	Medyan	Üçüncü Çeyreklik
AAPL	0.00117	0.02327	-0.12865	0.11981	0.24846	-0.01065	0.00073	0.01425
MSFT	0.00091	0.02195	-0.14739	0.14217	0.28956	-0.00965	0.00076	0.01234
AMZN	0.00026	0.02464	-0.14049	0.13536	0.27585	-0.01261	0.00068	0.01224
GOOGL	0.00068	0.02176	-0.11634	0.09241	0.20875	-0.00958	0.00112	0.01206
GOOG	0.00068	0.02166	-0.11101	0.09402	0.20502	-0.00963	0.00138	0.01144
BRK.B	0.00054	0.01617	-0.09592	0.11610	0.21202	-0.00730	0.00061	0.00803
UNH	0.00110	0.02093	-0.17277	0.12799	0.30076	-0.00809	0.00108	0.00961
JNJ	0.00048	0.01383	-0.07298	0.07998	0.15296	-0.00606	0.00027	0.00681
XOM	0.00111	0.02562	-0.12225	0.12687	0.24912	-0.01252	0.00049	0.01471
JPM	0.00033	0.02401	-0.14965	0.18013	0.32977	-0.01143	-0.00050	0.01216
META	-0.00024	0.03075	-0.26390	0.17594	0.43984	-0.01341	0.00043	0.01487
V	0.00040	0.02120	-0.13547	0.13843	0.27390	-0.00999	0.00073	0.01067
PG	0.00050	0.01527	-0.08737	0.12009	0.20746	-0.00597	0.00087	0.00750
NVDA	0.00208	0.03522	-0.18452	0.17156	0.35609	-0.01744	0.00310	0.02229
HD	0.00088	0.02094	-0.19794	0.13751	0.33545	-0.00819	0.00154	0.01099
CVX	0.00103	0.02692	-0.22125	0.22741	0.44866	-0.01085	0.00073	0.01341
LLY	0.00166	0.02183	-0.09999	0.15680	0.25678	-0.00899	0.00065	0.01018
MA	0.00052	0.02383	-0.12725	0.16611	0.29336	-0.01093	0.00061	0.01266
ABBV	0.00115	0.01685	-0.13002	0.08717	0.21720	-0.00727	0.00178	0.00928
PFE	0.00084	0.01891	-0.07735	0.10855	0.18590	-0.00935	-0.00052	0.00970
MRK	0.00059	0.01622	-0.09863	0.08374	0.18237	-0.00739	0.00000	0.00839
PEP	0.00065	0.01608	-0.11428	0.12937	0.24365	-0.00516	0.00090	0.00745
BAC	0.00030	0.02627	-0.15397	0.17796	0.33194	-0.01303	0.00015	0.01289
KO	0.00045	0.01559	-0.09672	0.06480	0.16152	-0.00550	0.00103	0.00740
TSLA	0.00331	0.04523	-0.21063	0.19895	0.40958	-0.02124	0.00199	0.02509

S&P500 endeksinde yer alan 25 hisse senedinin günlük getiri değerlerine ilişkin tanımlayıcı istatistikleri incelendiğinde TSLA hisse senedi en yüksek günlük getiri ortalamasına sahiptir, ancak aynı zamanda en yüksek riski temsil eden standart sapma değerine sahiptir. META hisse senedi ise en düşük günlük getiri ortalamasına ve risk değerine sahiptir, bu da daha düşük bir getiri potansiyeline sahip olduğunu göstermektedir. JNJ hisse senedi ise düşük riskli ve düşük getirili bir hisse senedi olarak öne çıkmaktadır.


S&P500’te yer alan 25 hisse senedinin günlük getiri değerlerinin zaman serisi grafikleri Şekil 4.3’de, kutu grafikleri ise Şekil 4.4’de verilmiştir.



Şekil 4.3. S&P500’te yer alan 25 hisse senedinin günlük getiri değerlerinin zaman serisi grafikleri



Şekil 4.3 devamı. S&P500’te yer alan 25 hisse senedinin günlük getiri değerlerinin zaman serisi grafikleri



Şekil 4.4. S&P500(25)'de yer alan hisse senetlerinin günlük getirilerinin kutu grafiği

S&P 500 endeksinde yer alan 25 hisse senedinin günlük getiri değerlerinin kutu grafikleri incelendiğinde, hisse senetlerinin günlük getiri değerlerinde çeşitlilik ve farklılık olduğu görülmektedir. Ortalama getiri değerleri analiz edildiğinde, hisse senetleri arasında belirgin farklılıklar olduğu görülmektedir. Örneğin, TSLA hisse senedi en yüksek ortalama günlük getiriye sahipken, META hisse senedi en düşük ortalama günlük getiriye sahiptir.

Grafiğin dikkat çeken bir diğer noktası, hisse senetlerinin getiri değerlerindeki değişkenliktir. Standart sapma değerlerine bakıldığında, hisse senetlerinin getiri değerlerinde önemli ölçüde değişkenlik olduğu görülmektedir. Özellikle NVDA ve TSLA

gibi hisse senetleri, yüksek getiri değerlerinde daha büyük bir değişkenliğe sahiptir. Diğer yandan, BRK.B ve JNJ gibi hisse senetleri daha düşük bir değişkenliğe sahip olarak daha istikrarlı bir performans sergilemektedir.

Aykırı değerler ise grafikte gösterilen çizgilerle temsil edilmektedir. Özellikle META ve TSLA gibi hisse senetleri, beklenmedik şekilde yüksek veya düşük performans sergileyen aykırı değerlere sahiptir.

Bu kutu grafiği analizi, hisse senetlerinin günlük getiri değerlerindeki dağılımı ve farklılıkları görselleştirerek yatırımcılara ve finansal analistlere bilgi sağlamaktadır. Bu bilgiler, risk-getiri değerlendirmesi ve portföy yönetimi kararları gibi finansal analizlerde dikkate alınabilir. Yatırımcılar, bu analiz sonuçlarına dayanarak riskleri değerlendirebilir ve portföylerini çeşitlendirebilirler.

S&P 500 endeksinde yer alan 25 hisse senedinin günlük getiri değerleri kullanılarak gerçekleştirilecek portföy optimizasyonu için GA'da popülasyon büyüklüğü 100, çaprazlama oranı 0.99, mutasyon oranı 0.2, $\Delta = 0.99$ ve tekrar sayısı 10000 alınmıştır. PSO algoritmasında parçacık sayısı 100, $w = 1$, $c_1 = c_2 = 2$ ve tekrar sayısı 1000 alınmıştır. DE algoritmasında popülasyon büyüklüğü 100, $F = 0.8$, $CR = 0.5$ ve tekrar sayısı 1000 alınmıştır. ABC algoritmasında $SN = 100$ ve tekrar sayısı 100 alınmıştır. GA, PSO, ABC ve DE algoritmaları ile gerçekleştirilen optimizasyon sonucu elde edilen ağırlıklar, amaç fonksiyonunun değeri, beklenen getiri ve risk değerleri Tablo 4.4'de verilmiştir.

Tablo 4.4. Farklı meta sezgisel algoritmalarla portföy optimizasyonundan elde edilen sonuçlar S&P500(25)

	AĞIRLIKLAR			
	GA	PSO	DE	ABC
AAPL	0	0	0	0
MSFT	0	0	0	0
AMZN	0	0	0	0
GOOGL	0	0	0	0
GOOG	0.018076	0	0	0
BRK.B	0	0	0	0
UNH	0	0	0	0
JNJ	0	0	0	0
XOM	0	0	0	0
JPM	0	0	0	0
META	0	0	0	0
V	0	0	0	0
PG	0	0	0	0
NVDA	0	0	0	0
HD	0	0	0	0
CVX	0	0	0	0
LLY	0.455792	0.48322	0.48322	0.48322
MA	0	0	0	0
ABBV	0	0	0	0
PFE	0	0	0	0
MRK	0	0	0	0
PEP	0.007595	0	0	0
BAC	0	0	0	0
KO	0	0	0	0
TSLA	0.518537	0.51678	0.51678	0.51678
Amaç Fonksiyonu	-0.00178	-0.0018	-0.0018	-0.0018
Port Ortalama Getiri	0.002488	0.00251	0.00251	0.00251
Risk	0.026629	0.026577	0.026577	0.026577

GA algoritması, optimize etmek için kullanıldığı portföyde GOOG, LLY, PEP ve TSLA hisselerini içermektedir. Portföyün amaç fonksiyonu-0.00178, ortalama getirisi ise 0.002488 olarak hesaplanmıştır. Risk değeri ise 0.026629'dur. Bu sonuçlar, GA algoritmasının verilen parametreler altında en uygun portföyü seçmeye çalıştığını göstermektedir.

PSO algoritması, S&P500 hisse senetlerinden oluşan bir portföy için uygulanmıştır. Ortaya çıkan portföy, LLY hissesinin %48.322 ağırlığında ve TSLA hissesinin %51.678 ağırlığındadır. Amaç fonksiyonu değeri-0.0018, ortalama getiri ve risk sırasıyla 0.00251 ve 0.026577'dir.

DE algoritması da S&P500 hisse senetlerinden oluşan aynı portföye uygulanmıştır. Ortaya çıkan portföy, LLY hissesinin %48.322 ağırlığında ve TSLA hissesinin %51.678 ağırlığındadır. Amaç fonksiyonu değeri, ortalama getiri ve risk ise sırasıyla -0.0018, 0.00251 ve 0.026577'dir. Bu sonuçlar, DE algoritmasıyla elde edilen portföyün PSO algoritmasıyla elde edilen portföy ile aynı olduğunu göstermektedir.

ABC algoritması da aynı portföye uygulanmış ve sonuç olarak LLY hissesinin %48.322 ağırlığında ve TSLA hissesinin %51.678 ağırlığında bir portföy elde edilmiştir. Amaç fonksiyonu değeri, ortalama getiri ve risk sırasıyla -0.0018, 0.00251 ve 0.026577 değerleri PSO ve DE algoritmasıyla elde edilen sonuçlarla aynıdır.

Sonuç olarak, PSO, DE ve ABC algoritmalarının aynı portföye uygulanmasıyla elde edilen portföylerin ağırlıkları aynıdır. LLY hissesine %48.322 ve TSLA hissesine %51.678 ağırlık verilmiştir. Bu algoritmaların amacı, verilen kısıtlar altında en uygun portföyü seçmektir ve sonuçlar bu amaç doğrultusunda başarılı olduğunu göstermektedir.

GA algoritması ise farklı bir strateji izleyerek portföyde dört farklı hisse senedini içermiştir. Bu durum, diğer algoritmalara kıyasla daha dağınık bir portföy oluşturduğunu göstermektedir.

LLY hissesine tüm algoritmalar tarafından yüksek ağırlık verilmesi, bu hissenin diğer hisselerle kıyasla daha istikrarlı bir performans gösterdiğini ve düşük risk taşıdığını göstermektedir. TSLA hissesine de ağırlık verilmesi ise yüksek getiri potansiyeli gösteren bir hisse olması nedeniyle tercih edilmiş olabilir.

Bu uygulama bölümü, farklı portföy optimizasyon algoritmalarının kullanımını ve hisse senetlerinin performansını değerlendirmeyi amaçlamıştır. Elde edilen sonuçlar, yatırımcılara farklı stratejileri denemek ve portföylerini optimize etmek için rehberlik edebilir. Ancak, daha kapsamlı bir analiz için diğer faktörlerin ve piyasa koşullarının dikkate alınması gerektiğini unutmamak önemlidir.

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Bu çalışmada, GA, PSO, DE ve ABC algoritmaları kullanılarak hisse senedi portföyü optimizasyonu yapılmıştır. Çalışmanın amacı, farklı algoritmaların performanslarını ve en uygun hisse senedi dağılımını belirlemektir. Performans ölçütü olarak, portföyün ortalama getirisi ve riski kullanılmıştır.

BİST 30 Endeksi için gerçekleştirilen uygulama sonuçları incelendiğinde, üç algoritmanın da benzer sonuçlar verdiği görülmüştür. HEKTS hisse senedinin portföyde en yüksek paya sahip olduğu tespit edilmiştir. Bunun yanı sıra, GUBRF ve SASA hisse senetleri de portföye önemli katkı sağlamıştır. PSO, DE ve ABC algoritmaları benzer sonuçlar verirken, GA algoritmasının sonuçları diğer algoritmalarla karşılaştırıldığında biraz daha düşük çıkmıştır. BİST 30 Endeksi uygulamasında amaç fonksiyonunun optimizasyonunda PSO, De ve ABC algoritmaları GA'dan daha başarılı bulunmuştur.

S&P500 Endeksinde yer alan 25 hisse senetti için gerçekleştirilen uygulama sonuçlarında da benzer şekilde PSO DE ve ABC algoritmalarının sonuçlarının aynı olduğu görülmüştür. S&P500 Endeksinde yer alan 25 hisse senetti için GA algoritma ile gerçekleştirilen portföy optimizasyonu sonucunda portföyde 4 farklı hisse bulunması, diğer algoritmalarla kıyasla daha dağınık bir portföy oluşturduğunu göstermektedir. PSO, DE ve ABC algoritmaları ise daha konsantre bir portföy oluşturmuşlar ve sadece LLY ve TSLA hisselerini seçmişlerdir. Bu sonuçlar, farklı algoritmaların farklı portföyler oluşturma stratejileri olduğunu göstermektedir.

Çalışmada farklı algoritmaların performanslarını karşılaştırırken, genel olarak benzer sonuçlar elde edildiği görülmüştür. Bu durum, bu dört algoritmanın portföy optimizasyonunda etkili olabileceğini ve benzer sonuçlar verebileceğini göstermektedir. Ancak, bazı farklılıklar da gözlemlenmiştir.

GA algoritması, daha dağınık bir portföy yapısı oluşturmuş ve daha fazla hisse senedine ağırlık vermiştir. Bu durum, yatırımcıların riski daha iyi dağıtmalarını sağlayabilir. PSO, DE ve ABC algoritmaları ise daha konsantre bir portföy yapısı oluşturmuş ve belirli hisse senetlerine yoğunlaşmıştır. Bu durumda, belirli hisselerin daha güçlü performans göstermesi durumunda daha yüksek getiri elde edilebilir.

Performans metrikleri incelendiğinde, tüm algoritmaların pozitif ortalama getiri değerleri ürettiği görülmüştür. Bu da portföylerin genel olarak kâr sağladığını göstermektedir. Amaç fonksiyonu değerleri negatif çıkmıştır, bu portföylerin beklenen getirilerinin riskten büyük olduğu anlamına gelmektedir.

Sonuç olarak, bu çalışma farklı algoritmaların kullanımının hisse senedi portföyü optimizasyonunda etkili olabileceğini göstermektedir. Her bir algoritmanın farklı stratejileri ve sonuçları olduğu için yatırımcılar bu algoritmalarından birini seçerken dikkatli olmalıdır. Ayrıca, bu çalışma sadece belirli bir döneme ve veri setine dayalı olduğu için, daha geniş bir veri setiyle ve daha uzun bir dönemi kapsayan analizlerin yapılması, sonuçların daha da sağlamlaştırılmasını sağlayabilir.

5.2 Öneriler

Portföy optimizasyonu üzerine yapılan bu çalışma, farklı algoritmaların kullanımının önemine dikkat çekmektedir. Gelecekteki çalışmalarda, daha fazla algoritma kullanılarak daha kapsamlı bir karşılaştırma yapılması önerilmektedir. Bu sayede, portföy yönetimi konusunda daha iyi bir anlayış elde edilebilir. Ayrıca farklı riskten kaçınma parametre değerlerine göre elde edilen sonuçlar karşılaştırılarak riskten kaçınma parametresinin algoritmalar üzerindeki etkisi incelenebilir.

Portföy optimizasyonu konusunda, farklı varlık sınıflarının dahil edilmesi de önemli bir konudur. Tahviller, emtialar ve gayrimenkuller gibi farklı varlık sınıfları, portföylerin daha çeşitli bir şekilde yönetilmesine yardımcı olabilir. Bu sayede, yatırımcı Ayrıca, portföy optimizasyonunda dikkate alınması gereken diğer faktörler vardır. Örneğin, likidite, piyasa etkinliği, vergi düzenlemeleri gibi faktörler portföy performansını etkileyebilir. Bu faktörlerin daha detaylı bir şekilde analiz edilmesi ve portföy optimizasyonunda dikkate alınması, daha sağlam ve gerçekçi sonuçlar elde etmeyi sağlayabilir.

Yatırımcıların risk toleransına ve tercihlerine göre portföy optimizasyonu yapılması da önemlidir. Kimi yatırımcılar düşük riskli portföyleri tercih ederken, kimileri yüksek getiri potansiyeline sahip ancak daha yüksek risk içeren portföylere yönelebilir. Bu nedenle, portföy optimizasyonu yapılırken yatırımcının risk-getiri tercihleri dikkate alınmalı ve buna uygun olarak portföy yapısı oluşturulmalıdır.

Teknik analiz ve temel analiz gibi farklı analiz yöntemlerinin de portföy optimizasyonunda kullanılması önerilebilir. Teknik analiz, fiyat hareketlerini ve geçmiş verileri analiz ederek gelecekteki performansı tahmin etmeye çalışırken, temel analiz şirketlerin temel verilerini ve ekonomik faktörleri inceler. Bu analiz yöntemlerinin kullanılması, portföy optimizasyonunda daha kapsamlı bir perspektif sağlayabilir.

Yatırımcıların portföylerini düzenli olarak gözden geçirmeleri ve güncellemeleri de önemlidir. Piyasa koşulları, ekonomik faktörler ve şirket performansı gibi değişkenler zamanla değişebilir. Bu nedenle, yatırımcılar portföylerini düzenli olarak yeniden değerlendirmeli ve güncel verilere dayanarak optimizasyon yapmalıdır.

Son olarak, portföy optimizasyonu sürecinde duygusal kararların önüne geçmek için otomatik işlem stratejileri kullanılabilir. Otomatik işlem stratejileri, belirli bir algoritma veya programlama diline dayalı olarak portföy yönetimini gerçekleştirir ve duygusal etkileri ortadan kaldırır. Bu stratejiler, disiplinli ve objektif bir şekilde portföy optimizasyonunu sağlayabilir.

Tüm bu öneriler, portföy optimizasyonu sürecinde daha iyi kararlar almanıza ve yatırım performansınızı artırmanıza yardımcı olabilir. Ancak, her yatırımcının risk profili ve hedefleri farklı olduğundan, önerilerin uygulanması önceden dikkatlice değerlendirilmeli ve kişisel gereksinimlere uygun şekilde uyarlanmalıdır.

6. KAYNAKLAR

- Abay, R. (2013). Markowitz Karesel Programlama ile Portföy Seçimi: İMKB 30 Endeksinde Riskli Portföylerin Seçimi. *Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 22(2), 175-194. <https://dergipark.org.tr/en/pub/cusosbil/60454> adresinden erişildi.
- Acar, E. (2021). Genetik algoritma kullanımı ile farklı getiri ölçümlerindeki yatırım optimizasyonu problemi. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 10(1), 266-288.
- Ackora-Prah, J., Gyamerah, S. A. ve Gyamfi, D. (2014). A Genetic Algorithm to Price an European Put Option Using the Geometric Mean Reverting Model. *Applied Mathematical Sciences*, 8(143), 7125-7135. doi:10.12988/ams.2014.46424
- Akyer, H., Kalaycı, C. B., Aygören, H. (2018). Ortalama-Varyans portföy optimizasyonu için parçacık sürü optimizasyonu algoritması: Bir Borsa İstanbul uygulaması. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(1), 124-129.
- Aranha, C. ve Iba, H. (2009). The Memetic Tree-based Genetic Algorithm and its application to Portfolio Optimization. *Memetic Computing 2009 1:2*, 1(2), 139-151. doi:10.1007/S12293-009-0010-2
- Bacanin, N. ve Tuba, M. (2012). Artificial Bee Colony (ABC) Algorithm for Constrained Optimization Improved with Genetic Operators. *Studies in Informatics and Control*, 21, 137-146. doi:10.24846/v21i2y201203
- Boztosun, D., Yalçın, K. ve Atan, M. (2005). Karesel Programlama Yönteminin İmkb 100 Endeksine Uygulanması ve Portföy Optimizasyonu. *İktisat İşletme ve Finans*, 20(232), 70-83. <https://ideas.repec.org/a/iif/iifjrn/v20y2005i232p70-83.html> adresinden erişildi.
- Corazza, M., Fasano, G. ve Gusso, R. (2013). Particle Swarm Optimization with non-smooth penalty reformulation, for a complex portfolio selection problem. *Applied Mathematics and Computation*, 224, 611-624. doi:10.1016/J.AMC.2013.07.091
- Cura, T. (2009). Particle swarm optimization approach to portfolio optimization. *Nonlinear Analysis: Real World Applications*, 10(4), 2396-2406. doi:10.1016/J.NONRWA.2008.04.023
- Çelenli, A. Z., Eğrioğlu, E., Çorba, B. Ş. (2015). İMKB 30 İndeksini Oluşturan Hisse Senetleri İçin Parçacık Sürü Optimizasyonu Yöntemlerine Dayalı Portföy Optimizasyonu. *Doğuş Üniversitesi Dergisi*, 16(1), 25-33.
- Demirtaş, Ö. ve Güngör, Z. (2004). Portföy yönetimi ve portföy seçimine yönelik uygulama. *Journal of Aeronautics and Space Technologies*, 1(4), 103-109.
- Erişoğlu M, Erişoğlu Ü (2022-a), Genetik Algoritma ve Parçacık Sürü Optimizasyonu İle Portföy Optimizasyonu, İstatistiksel Tekniklerle Güncel Analizler Editör: Gündüz F.F, Gazi Kitabevi, 1. Basım, 1-17, ISBN:978-625-035-3, Ankara
- Erişoğlu Ü, Erişoğlu M (2022-b), Holt-Winters Üstel Düzleştirme Yöntemi İle Fşnansal Gelişmişlik Endeksinin Tahmini, Fen ve Matematik Bilimlerinde Güncel Yaklaşımlar, Editörler: Akpınar, A., Güler A., Livre De Lyon, 1. Basım, 107-123, ISBN:978-2-38236-501-4.
- Guo, Q., Li, J., Zou, C., Guo, Y. ve Yan, W. (2011). A class of multi-period semi-variance portfolio for petroleum exploration and development. <http://dx.doi.org/10.1080/00207721.2011.555011>, 43(10), 1883-1890. doi:10.1080/00207721.2011.555011
- Karaboğa, D. (2005). An Idea Based on Honey Bee Swarm for Numerical Optimization, Technical Report - TR06. *Technical Report, Erciyes University*.

- Kartal, B. (2015). Yapay Arı Kolonisi Algoritması ile Finansal Portföy Optimizasyonu. Yayınlanmamış Doktora Tezi, İstanbul: İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.
- Kennedy, J., Eberhart, R. (1995). Particle swarm optimization. In Proceedings of ICNN'95-international conference on neural networks (Vol. 4, pp. 1942-1948). IEEE.
- Keskintürk, T., Demirci, E., Tolun, S., Demirci, E., Keskintürk, T. ve Tolun, S. (2012). İyi Çeşitlendirilmiş Portföy Büyüklüğünün Genetik Algoritma Tekniği Kullanılarak İncelenmesi. *Sosyal Bilimler Dergisi*, (2), 1-5. <https://dergipark.org.tr/tr/pub/iusosbil/118648> adresinden erişildi.
- Küçükkocaoğlu, G. (2002). Optimal Portföyün Seçimi ve İMKB Ulusal-30 Endeksi Üzerine Bir Uygulama Earnings Management View project Market Microstructure View project. <https://www.researchgate.net/publication/268173075> adresinden erişildi.
- Liagkouras, K. ve Metaxiotis, K. (2014). A new Probe Guided Mutation operator and its application for solving the cardinality constrained portfolio optimization problem. *Expert Systems with Applications*, 41(14), 6274-6290. doi:10.1016/J.ESWA.2014.03.051
- Markowitz, Harry. (1952). Portfolio Selection. *The Journal of Finance*, 7(1), 77-91. doi:10.1111/j.1540-6261.1952.tb01525.x
- Markowitz, H. (1956). The optimization of a quadratic function subject to linear constraints. *Naval Research Logistics Quarterly*, 3, 111-133.
- Mercangöz, B. A. (2018). Parçacık Sürü Optimizasyonu ile Portföy Optimizasyonu: Borsa İstanbul Ulaştırma Sektörü Hisseleri Üzerine Bir Uygulama. *Yaşar Üniversitesi E-Dergisi*, 14, 126-136.
- Özdemir, M. (2011). Genetik algoritma kullanılarak portföy seçimi. *Iktisat Isletme ve Finans*, 26(299), 43-66. <https://ideas.repec.org/a/iif/iifjrn/v26y2011i299p43-66.html> adresinden erişildi.
- Sadeghi, A. ve Zandieh, M. (2011). A game theory-based model for product portfolio management in a competitive market. *Expert Systems with Applications*, 38(7), 7919-7923. doi:10.1016/J.ESWA.2010.11.054
- Sharpe, W. F. (1966). Mutual Fund Performance. *The Journal of Business*, 39(1), 119-138. <http://www.jstor.org/stable/2351741> adresinden erişildi.
- Sharpe, W. F. (1994). The Sharpe Ratio. *The Journal of Portfolio Management*, 21(1), 49-58. doi:10.3905/JPM.1994.409501
- Yaman, I. (2014). Portföy Optimizasyonunda Değiştirilmiş Parçacık Sürü Optimizasyonu Yaklaşımı. *Clinical Epigenetics*. doi:10.2/JQUERY.MIN.JS
- Zhu, H., Wang, Y., Wang, K. ve Chen, Y. (2011). Particle Swarm Optimization (PSO) for the constrained portfolio optimization problem. *Expert Systems with Applications*, 38(8), 10161-10169. doi:10.1016/J.ESWA.2011.02.075