



Sharpe Oranı ve Treynor Endeksi Performans Ölçülerine Dayalı Genetik Algoritma Yaklaşımı

Azize Zehra ÇELENLİ BAŞARAN*¹

¹*Ondokuz Mayıs Üniversitesi, Çarşamba Ticaret Borsası MYO, Finans, Bankacılık ve Sigortacılık Bölümü, 55500, Samsun, Türkiye*

* yazışılan yazar e-posta: azize.celenli@omu.edu.tr

(Alınış / Received: 14.08.2020, Kabul / Accepted: 12.01.2021, Yayınlanma / Published: 27.05.2021)

Özet: Yatırımcı her zaman kendisine en yüksek faydayı sağlayacak olan portföyü oluşturmak istemektedir. Bu durum optimize edilmesi gereken portföy problemini ortaya çıkartır. Literatürde portföy optimizasyon problemi çözümünde genellikle bir klasik optimizasyon yöntemlerinden biri olan karesel programlama yöntemi kullanılmaktadır. Son yıllarda yapılan çalışmalar incelendiğinde yapay zeka algoritmalarının optimizasyon problemlerinde gösterdiği başarılarından yola çıkarak bu çalışmada genetik algoritma yaklaşımının portföy optimizasyon problemindeki başarısı ölçülmek istenmektedir. Portföy optimizasyon problemi için karesel programlama ile genetik algoritma yöntemleri portföy performans ölçüleri açısından karşılaştırılmıştır. Karşılaştırmada 2019 yılına ait BIST-30 endeksinde işlem gören hisse senetleri kullanılmıştır. Portföy performansını değerlendirmek için sharpe oranı ile treynor endeksi performans ölçüleri iki optimizasyon yönteminde de amaç fonksiyonu olarak kullanılmıştır. İki optimizasyon yönteminde de amaç; en yüksek performans ölçüsü oranına sahip portföyün belirlenmesidir. Yapılan analiz sonucunda genetik algoritma yönteminin her iki portföy performans ölçüsüne göre de optimum sonuca ulaştığı gözlemlenmiş ve treynor endeksinin sharpe oranına göre daha yüksek performans ölçüsü oranına sahip bir portföy oluşturduğu belirlenmiştir.

Anahtar kelimeler: Portföy optimizasyonu, Genetik algoritma, Sharpe oranı, Treynor endeksi

Sharpe Ratio and Treynor Index Performance Measures Based A Genetic Algorithm Approach

Abstract: The investor always wants to create a portfolio that will benefit him with the highest benefit. This situation presents the portfolio problem that needs to be optimized. In the literature, quadratic programming method, which is one of the classical optimization methods, is used to solve the portfolio optimization problem. In recent years, it has been observed that artificial intelligence methods give better results. In this study, genetic algorithm method was used for portfolio optimization problem. For the portfolio optimization problem, quadratic programming and genetic algorithm methods were compared in terms of portfolio performance measures. The stocks listed in the BIST-30 index of 2019 were used for comparison. Sharpe ratio and treynor index performance measures were used to evaluate portfolio performance. The goal in both optimization methods; it is the determination of the portfolio with the highest performance measure ratio. As a result of the analysis, it was observed that the genetic algorithm method reached the optimum result according to both portfolio performance

measures. treynor index has been determined to form a portfolio with a higher performance measure ratio compared to the sharpe ratio.

Key words: Portfolio optimization, Genetic algorithm, Sharpe ratio, Treynor index

1. Giriş

Her birey elinde bulunan birikimini en iyi şekilde değerlendirmek ister. Birikimin en iyi şekilde değerlendirmek isteyen her birey bir yatırımcıdır. Yatırımcı birikimini, kendisine kâr ya da getiri sağlayacak şekilde finansal nitelikte yatırım araçları ile değerlendirir. Yatırımcının elinde bulunan finansal nitelikteki yatırım araçlarının tamamı portföyü oluşturur. Portföy, kişinin veya kurumun elinde bulunan, üzerinde her türlü işlemi yapabilen finansal nitelikteki yatırım araçlarının tamamına denir. Portföy finansal nitelik taşıyan hisse senedi, tahvil, hazine bonusu, döviz gibi çeşitli yatırım araçlarından oluşabilir.

Portföy, içerisine dahil edilecek menkul kıymet çeşitliliği, menkul kıymetlerin portföy içi ağırlık oranları, portföyün hedeflenen beklenen getirisi, portföyün riski ve benzeri gibi sorular portföy optimizasyon problemini ortaya çıkarmıştır.

Geçmişten günümüze yatırımcı için en uygun portföyü oluşturmak ve en iyi şekilde değerlendirmek, portföy teorilerinin ortaya çıkmasını ve üzerinde araştırmalar yapılmasını sağlamıştır. Literatürde Geleneksel portföy teorisi ve Modern portföy teorisi olmak üzere iki temel portföy teorisi vardır. Geleneksel portföy teorisi II. Dünya savaşı sonlarına kadar ekonomi ve finans alanında kabul görmüştür [1]. Portföyün çeşitlendirilmesi esasına dayanan Geleneksel portföy teorisi, portföyü oluşturan menkul kıymetlerin getirileri arasındaki istatistiksel ilişkileri göz ardı ederek, sadece menkul kıymet sayısını artırarak riski düşürebileceği savunmaktadır. Geleneksel portföy teorisi, getirisi yüksek olan menkul kıymetlerin portföye dahil edilmesi gerektiğini savunur. Ayrıca bu teori de portföye ne kadar çok menkul kıymet dahil edilirse portföye ait riskin azalacağı düşünülmektedir. Her yatırımcı sahip olduğu portföyden getiri elde etmek ister fakat geleceğe yönelik yapılan yatırım her zaman belirsizlik hali yüzünden risk içerir. Bu nedenle yatırımcı, portföye ait riskin ne ile ölçüleceğini bilemediği için portföy riskinden kaçmamaktadır [2].

İkinci portföy teorisi ise risk ve getiri kavramlarını istatistiksel olarak bir model ile tanımlayan Markowitz'in (1952) Modern portföy teorisidir. Sadece portföy çeşitlendirmesine gidilerek riskin azaltılamayacağını, portföyde yer alan menkul kıymetler arasındaki ilişkinin de riskin azaltılması yönünde etkili olduğunu Markowitz tarafından geliştirilen Ortalama-Varyans Modeli ile göz önüne getirilmiştir [3]. Markowitz, portföy yönetimi kavramına önemli katkılar sağlamıştır. Birincisi; portföy riski, portföyü oluşturan varlıkların riskinden daha düşük olabilmektedir. Portföydeki varlıklar arasındaki korelasyon katsayı değeri azaldıkça portföy riski de azalabilmektedir. İkincisi; yatırımcı bazı portföy çeşitlerini aynı risk düzeyinde daha yüksek getirili olanı tercih edeceklerdir. Modern portföy teorisinde, sadece portföydeki menkul kıymet sayılarının artırılmasıyla riskin dağıtılması amacına ulaşamayacağı, portföye dahil edilen menkul kıymet getirilerinin, risk dağıtımında son derece önemli olduğu gösterilmiştir [4]. Finansal varlık getirileri arasındaki ilişkilerin dikkate alınması ve tam negatif ilişki içinde bulunan varlıkların aynı portföyde birleştirilmesi, hedeflenen beklenen getiriden vazgeçilmeden risk değerini düşürebilmekte olduğu gösterilmiştir.

Son yıllarda portföy optimizasyonu probleminde kullanılan klasik yöntemler sezgisel algoritmalarla elde edilen sonuçlar ile karşılaştırılmış ve klasik yöntemlerin sezgisel algoritmaların gerisinde kaldığı gözlemlenmiştir. Sezgisel algoritma yöntemlerin kolay uygulanabilir olması, kısa sürede en iyi çözüme ulaşma imkânı sağlaması, sezgisel teknikleri araştırmacılar tarafından tercih edilir hale getirmiştir. Sezgisel algoritmalar; gelişime ve sürü zekâsına dayalı algoritmalar olmak üzere iki gruba ayrılmıştır. Gelişime dayalı teknikler en iyi sonucu bulma konusunda sürekli iyileşme sağlayan, sürü zekâsına dayalı algoritmalar ise ortaklaşa hareket eden canlılardan esinlenerek

ortaya çıkmış optimizasyon teknikleridir. Gelişime dayalı algoritmalarından Genetik Algoritma (GA), Holland [5] tarafından optimizasyon problemlerine çözüm bulmak amacıyla üretilen bir yöntemdir. Diyar, Çetinyokuş [6], karmaşık yapıda bulunan portföy optimizasyonu probleminde Karar destek sistemleri (KDS) geliştirilerek GA tekniği yardımıyla yatırımcıya portföy çeşitliliği sunmuştur. Oh, Kim [7], tarafından KOSPI (Kore Menkul Kıymetler Borsası) endeks verileri ile yapılan analiz sonucunda GA tekniğinin portföy performansını artırdığı gözlemlenmiştir. Lin, Li [8], Portföy optimizasyon probleminde işlem maliyetleri ve minimum işlem lotları için bir ortalama varyans modeli önermiştir ve önerilen modeli, sayısal bir örnek kullanarak, GA'nın portföy optimizasyon problemlerindeki performansını değerlendirmiştir. Lai, Yu [9], optimum portföyü bulmak için, GA ile portföy optimizasyonu problemini iki aşamaya ayırır. ilk aşamasında kaliteli menkul kıymetleri belirler, ikinci aşamasında ise Markowitz'in Modern portföy teorisine dayanan kaliteli menkul kıymetlerin portföye uygun şekilde dağıtmaktadır. Lin, Gen [10], portföyün beklenen getirisinin riske oranı ile portföye dahil edilecek menkul kıymetlerin optimal ağırlıklarını hesaplarken çok boyutlu portföy optimizasyonu problemi için GA tekniğinin kullandığı bir yöntem önermişlerdir. Belirli yatırım dönemi için farklı kısıtlar kullanarak çok amaçlı GA teknikleri kullanılmış ve yapılan analizler sonucu bulanık mantık kullanılmasının bu problemler için performansı arttırdığı gözlemlenmiştir [11]

Lin, Liu [12], Markowitz'in ortalama varyans modeline dayanan portföy optimizasyonundaki minimum işlem lotu problemini çözmek için GA tekniğinden faydalanmıştır. Chang, Yang [13], GA yöntemi ile farklı risk ölçümlerine (yarı varyans, ortalama mutlak sapma ve çarpıklık varyansı) karşı portföy optimizasyonu problemlerine sezgisel bir yaklaşım getirmiştir ve performansı CCMV modeli etkin sınırdaki ortalama varyans modeliyle karşılaştırmıştır. Soleimani, Golmakani [14], Markowitz ortalama varyans seçim modelini, karma tamsayı doğrusal olmayan programı çözmek için farklı piyasa verileri ile Lingo ve GA tekniği kullanılmış ve karşılaştırılmıştır. Chang, Wang [15], TSE 50 (Tayvan 50) endeki verilerini kullanarak optimum portföyü GA ile elde etmiş ve bu portföyü yatırım yapılan dönemdeki faiz oranlarının getirileri ile karşılaştırarak riski en düşük seviyede tutmak için portföye dahil edilmesi gereken 20 adet hisse senedi olması gerektiğini savunmuştur.

Pandari, Azar [16] çalışmasında, optimum portföyü belirlemek için Tahran Borsası verileri kullanılarak sistematik risk ve sistematik olmayan riski minimum seviyede tutmak ve getiri oranını yükseltmek için GA tekniğini kullanarak klasik yöntemler ile karşılaştırılmıştır. Kalayci, Ertenlice [17], Markowitz'in ortalama varyans modelinde maksimum getiri ve minimum riski hedefleyen portföy için etkin sınırı hesaplayarak karmaşık yapıya sahip portföy optimizasyonu problemi için GA kullanmış ve literatürde bu alanda yapılan çalışmalar incelemiştir.

2. Materyal ve Metot

2.1. Portföy Optimizasyonu

Geleneksel portföy teorisinde, portföye dahil edilecek menkul kıymet sayısı ne kadar fazla olursa riskin o kadar az olabileceği savunulurken risk sayısal olarak ifade edilememiştir. İktisadi anlamda portföyün beklenen getirisi ve portföyün riski ilk defa bir model ile 1952 yılında Harry Markowitz tarafından literatüre kazandırılmıştır [3]. Önerilen bu model ile portföyün beklenen getirisi ve riski hesaplanmıştır. Portföy çeşitlendirilirken, portföy içerisine dahil edilecek menkul kıymetlerin birbiriyle olan ilişkisinin (korelasyon) göz ardı edilmemesi gerektiği savunulmuştur [18]. Markowitz, çeşitlendirmenin hisse senetlerinin getirileri arasındaki ilişkiye dayanması gerektiğini ve

belli sayıdaki hisse senedinden sonra portföye eklenecek hisse senedinin portföyün riskini azaltmada fayda sağlamadığını savunmaktadır.

Yatırım analizinde ortalama varyans modelinin kullanılmasında iki temel değişken, beklenen getiri ve varyanstır [19]. Her yatırımcı minimum riske karşı maksimum getiri istemektedir. Markowitz ortalama varyans modelinde portföyün ortalaması; portföye dahil edilecek menkul kıymetlerin portföy içindeki ağırlıkları ile menkul kıymet getirilerinin çarpılıp ayrı ayrı toplanması ile elde edilir. Portföye ait risk ise portföyün standart sapmasıdır. Modelin temel amacı riski minimize ederek, getiriye maksimum seviyeye ulaştırmaktır. O halde Markowitz ortalama varyans modeli için beklenen getiri ve risk aşağıdaki denklemler ile tanımlanır:

$$\sigma_p^2 = \sum_{i=1}^n \sum_{j=1}^n x_i x_j \sigma_{ij} \quad (1)$$

σ_p^2 : Portföyün riski

σ_{ij} : i. ile j. Menkul kıymetler arasındaki kovaryans değeri

x_i : i. Menkul kıymetin portföy içindeki ağırlığı

x_j : j. Menkul kıymetin portföy içindeki ağırlığı

n: Portföydeki Menkul kıymet sayısı

$$R_p = \sum_{i=1}^n x_i r_i \quad (2)$$

R_p : Yatırım yapılan portföyün beklenen getirisi

r_i : i.nci hisse senedinin getirisi

Markowitz ortalama varyans modeli karesel programlama ile çözümlenen bir modeldir. Karesel programlamada, amaç fonksiyonu olan portföy riski belirli kısıtlamalar altında, minimize edilir. Markowitz Ortalama Varyans Modelinin amaç fonksiyonu ve kısıtları şu şekilde tanımlanmıştır;

$$\text{Amaç Fonksiyonu: } \text{Min. } \sum_{i=1}^n \sum_{j=1}^n x_i x_j \sigma_{ij} \quad (3)$$

$$\text{Kısıtlar: } R_p = \sum_{i=1}^n x_i r_i \quad (4)$$

$$\sum_{i=1}^n x_i = 1,$$

$$0 \leq x_i \leq 1 \quad i = 1, 2, \dots, n$$

Yatırım yapılan portföyün performansının sürekli değerlendirilmesi gerekir. Çünkü yatırımcı seçtiği portföyün hem mutlak performansını, hem de diğer portföylerle karşılaştırılmalı performansını görmek ve değerlendirmek ister [20].

Yatırım, geleceğin belirsizliği karşısında risk unsurunu ortaya çıkartır. Fakat risk ve belirsizlik farklı iki kavramdır. Geleceğin belirsizliğine karşın olasılık tahmini subjektif yapılıyorsa belirsizlikten, objektif olarak yapılıyorsa riskten söz edilir [19]. Finansal açıdan risk kavramı beklenen getirinin gerçekleşen getiriden sapma olasılığı olarak tanımlanmaktadır [19]. Yapılan yatırımla ilgili risk kaynakları, giderilebilen (Sistemik risk kaynakları) ve giderilemeyen (sistemik olmayan risk kaynakları) risk kaynakları olarak literatürde ikiye ayrılır. Yapılan yatırımda asla göz ardı edilmemesi gereken yok edilmesi imkansız olan sistemik risk kaynakları, Enflasyon riski, Faiz oranı riski,

piyasa riski, politik risk ve kur riski olarak tanımlanmaktadır. Bunun yanı sıra giderilmesi mümkün olan çok iyi çeşitlendirilmiş bir portföy ile ortadan kaldırılabilecek olan sistematik olmayan risk kaynakları ise finansal risk, iş ve endüstri riski, yönetim riski olarak özetlenebilir [19].

Yatırımcı yatırım yapmaya karar verdiği portföyün performansının değerlendirilmesini ister. Bu nedenle portföy performansı sürekli ölçülmesi hatta yatırımcıya sunulan başka portföy çeşitleri ile de karşılaştırılması gerekmektedir. Karşılaştırma sonucunda hangi portföyün sağlayacağı performans daha yüksek ise yatırımcı kararını bu yönde değiştirebilir. Elde edilen her portföyün performansını değerlendirmek için literatürde kullanılan çeşitli performans ölçüleri mevcuttur. Bu çalışmada optimum portföyü belirlemek amacıyla toplam riski ile portföy performans ölçümü yapan Sharpe performans oranı ve sistematik risk ölçüsü olan Beta (β) katsayısı kullanarak portföy performans ölçümü yapan Treynor endeks oranı kullanılmıştır.

Sharpe Performans Oranı; portföyün getirisi ve riski arasındaki ilişkiyi ölçmek amacıyla geliştirilmiştir [21]. Sharpe performans oranı, risksiz faiz oranını aşan portföy getirisinin portföyün standart sapmasına bölünmesi suretiyle hesaplanan kolay bir orandır [22].

$$S_p = \frac{R_p - r_f}{\sigma_p} = \frac{\sum_{i=1}^n x_i r_i - r_f}{\sqrt{\sum_{i=1}^n \sum_{j=1}^n x_i x_j \sigma_{ij}}} \quad (5)$$

S_p : Portföyün Shar pe performans oranı

R_p : Portföyün beklenen getirisi

r_i : i.ninci hisse senedinin getirisi

R_f : Risksiz faiz oranı

σ_p : Portföyün riski (Portföyün Standart Sapması)

Portföye ait Sharpe performans oranının yüksek olması o portföyün tercih edilme olasılığını artırmaktadır.

Jack Treynor'un literatüre kazandırdığı portföy performans ölçüsü sistematik risk göstergesi olan Beta katsayısını kullanarak bir model tanımlamıştır [23].

$$T_p = \frac{R_p - r_f}{\beta_p} = \frac{\sum_{i=1}^n x_i r_i - r_f}{\sum_{i=1}^n x_i \beta_i} \quad (6)$$

T_p : Portföyün Treynor endeks oranı

β_p : Portföyün Betası (Sistematik risk göstergesi)

β_i : i.nci menkul kıymetin Betası

2.2. Genetik Algoritma

Genetik Algoritma , Holland, arkadaşları ve öğrencileri tarafından literatüre kazandırılan evrimsel bir algoritmadır [5]. Holland, canlılarda bulunan genetik dizilimi, optimizasyon problemlerine çözüm bulmak için kullanmıştır.

GA yönteminde amaç iyi gene sahip nesillerin kaliteli bireyler üretmesidir. Kötü gene sahip bireyler varlıklarını sürdürmezler. Algoritmada üretilen bireyler iyi gene sahip ise optimal çözüm olabilirken, kötü gene sahip bireyler ise hafızadan silinmesi gereken çözüm anlamını taşımaktadır [6]. GA yönteminin genel yapısı adımlar halinde şu şekildedir:

a. Başlangıç için popülasyon oluşturulur;

GA yönteminde başlangıç için gen ve kromozomlardan oluşan bir popülasyon oluşturulması gerekmektedir. Algoritmada genetik bilgi taşıyan en küçük yapı taşına gen denir. Genlerin bir araya gelmesiyle oluşan yapıya kromozom adı verilmektedir. Her bir kromozom GA'da alternatif bir çözümü temsil etmektedir. Kromozomlardaki genler, gen sayıları ve kromozom sayıları, probleme çözüm arayan kişi tarafından rasgele belirlenir. Böylece başlangıç popülasyonu oluşturulmuş olur. Başlangıç popülasyonu için genetik kodlama çok önemlidir. Kromozom dizilerinden her biri problemin olası bir çözümünü temsil eder.

Popülasyon ile kromozom uzunluğu arasındaki ilişki şöyle tanımlanmaktadır [24].

$$\text{popülasyon büyüklüğü} = 1,65x2^{0,2*uzunluk} \quad (7)$$

GA için her kromozom bir çözümü temsil etmektedir. Genlerden oluşan her kromozoma ait amaç fonksiyonu değeri uygunluk değeri olmaktadır.

b. Elitizm yöntemi için en iyi kromozomları belirle ve eşleştirme havuzuna at

Elitizm, popülasyondaki kaliteli kromozomların doğrudan eşleştirme havuzu adı verilen havuzda tutulmasını ve bir sonraki çaprazlama ve mutasyon operatörleri için bu havuzdaki kromozomların kullanılmasını ve en iyi bireylerin kaybolmamasını sağlamaktadır. Böylece saklanan en iyi bireylerden kaliteli yeni bireyler oluşturulmaktadır. Elitizm popülasyonun maksimum uygunluk değerinin sürekliliğini korumasını sağlayan bir yöntemdir [25].

GA için uygunluk değerlerine göre kromozomlar en iyiden en kötüye doğru sıralanarak belirlenen elitizm oranı kadar seçilir ve eşleştirme havuzuna atılır.

c. Çaprazlama ve Mutasyon

Elitizm yöntemine göre belirlenen kaliteli kromozomlar eşleştirme havuzunda toplanır. GA yönteminde çaprazlama işlemi ile eşleştirme havuzundan kaliteli 2 kromozom seçilerek yeni bireyler oluşturulur. Eşleştirme havuzundan rasgele seçilen 2 kromozoma çaprazlama işlemi uygulanıp uygulanmayacağına; çaprazlama oranının, [0,1] aralığında üretilen rasgele sayı ile karşılaştırılması sonucunda karar verilir. Çaprazlama işlemi uygulanmasına karar verilen kromozomlar arasında tek noktalı çaprazlama işlemi kullanılarak çaprazlama gerçekleştirilir. GA'da çaprazlama tekniklerinden en basiti tek noktalı çaprazlama tekniğidir [26]. Eşleşme havuzunda seçilen iki kromozomun aynı uzunlukta gen sayıları mevcuttur. Bu uzunluğa kromozom uzunluğu adı verilir ve L ile gösterilir. [1,L-1] aralığında rasgele bir k tamsayısı seçilir. Kromozomların k+1'den L'ye kadar olan genleri yer değiştirir. Böylece eski iki kromozomdan yeni bireyler üretilmiş olur [27]. Çaprazlama sonucu üretilen yeni bireyler eskilerinin yerini alır.

Çaprazlama işleminden sonra kromozomların arasından rasgele bir kromozom belirlenerek mutasyon işlemi yapılıp yapılmayacağına karar verilir. Mutasyon oranının $[0,1]$ aralığında üretilen bir sayı ile karşılaştırılarak mutasyon işlemine karar verilir. Dizilere ne kadar çaprazlama operatörü uygulansa da ilerleyen nesillerde dizi çeşitliliği sağlanamamaktadır. Bu yüzden var olan kromozomlardan yeni ve farklı birey üretmeye yarayacak bir operatör olarak mutasyon kullanılır [28]. Mutasyon işlemi, L uzunluğundaki bir kromozomdan $[1, L]$ aralığında iki rasgele tamsayı seçilir. Rasgele belirlenen iki genin değerleri birbirleriyle yer değiştirir. Mutasyon arama uzayında daha önce keşfedilmemiş çözümlere ulaşılmasını sağlar. Ayrıca mutasyon işlemi GA'nın minimum çözümlere takılmasını engelleyerek daha önceden popülasyondan çıkarılmış çözümlerin tekrar popülasyona girmesini sağlar [29]. Mutasyon çözümden çıkarılmış kromozomların tekrar çözüme dahil edilmesi ile daha iyi çözümlere ulaşılabilir [30].

GA ile probleme çözüm aramaya başlarken durdurma kriterinin belirlenmesi gerekmektedir. Aksi halde çalıştırılan program hata verecektir. Çözüm arayışına başlamadan önce iterasyon sayısının belirlenmesi algoritma için durdurma kriteridir. İterasyon sayısı tamamlanınca elde edilen optimum çözüm son iterasyondaki çözümdür. Bir başka durdurma kriteri ise amaç fonksiyonunun belli bir değere ulaşmasıdır. Amaç fonksiyonu için önceden belirlenen değere ulaşıldığı halde probleme çözüm arayışı durur ve durduğu iterasyondaki elde edilen çözüm optimum çözüm olmaktadır.

GA yönteminde elitizm oranı, mutasyon oranı, çaprazlama oranı, kromozom sayısı ve iterasyon sayısı algoritmaya dahil edilecek olan parametre değerleridir.

3. Bulgular

Portföy optimizasyon problemi için farklı risk değerleri içeren portföy performans ölçüleri GA ile çözümlenerek optimum portföy hedeflenmiştir. Ayrıca GA ile elde edilen portföy çeşitleri portföy optimizasyon probleminde kullanılan karesel programlama yöntemi ile elde edilen portföy çeşitleri ile karşılaştırılarak en yüksek performans ölçüsüne sahip portföyü veren yöntem belirlemiştir. Çalışmanın amacı bir yapay zeka yöntemi olan genetik dizilimden esinlenerek ortaya çıkan GA yönteminin klasik bir yöntem olan karesel programlamaya göre daha iyi sonuç verdiğini kanıtlamak ve farklı risk değerlerine göre hesaplanan sharpe performans oranı ile treynor endeks değerlerinin karşılaştırılarak optimum portföye ait portföyün beklenen getirisi, portföyün riski, portföyün içerdiği hisse senet sayısı ve her bir hisse senedinin portföy içi ağırlık oranları değerlerine ulaşmaktır.

Çalışma için 2019 yılı içerisinde BIST 30 endeksinde işlem gören 30 adet hisse senedinin gün sonu kapanış fiyatları kullanılmıştır. Her bir hisse senedine ait gün sonu kapanış fiyatlarından oluşan veri seti GA ve karesel programlama için kullanılmıştır. Her iki yönteme ait oluşturulan algoritmalar MATLAB (R2015a) programında çözümlenmiştir. Çalışmada kullanılan 2019 yılı BIST-30 endeksine ait hisse senetleri ve kodları tablo1'de verilmiştir.

Tablo 1. Hisse senet kodları

Hisse senet kodları					
AKBNK	EKGYO	HALKB	KRDMD	SODA	TOASO
ARCLK	ENJSA	ISCTR	PETKM	TAVHL	TTKOM
ASELS	EREGL	KCHOL	PGSUS	TCELL	TUPRS
BIMAS	FROTO	KOZAA	SAHOL	THYAO	VAKBN
DOHOL	GARAN	KOZAL	SISE	TKFEN	YKBNK

Her iki yöntemde de tüm çözümler sırasında kullanılan amaç fonksiyonları ve kısıtlar aynıdır. Çalışmada kullanılan Treynor endeksi ve Sharpe performans oranı amaç fonksiyonları ve kısıtları denklem 8 ve denklem 9’da verilmiştir:

$$Max S_p = \frac{R_p - r_f}{\sigma_p} \frac{\sum_{i=1}^n x_i r_i - r_f}{\sqrt{\sum_{i=1}^n \sum_{j=1}^n x_i x_j \sigma_{ij}}} \quad (8)$$

Treynor endeks değeri için amaç fonksiyonu;

$$Max T_p = \frac{R_p - r_f}{\beta_p} \frac{\sum_{i=1}^n x_i r_i - r_f}{\sum_{i=1}^n x_i \beta_i} \quad (9)$$

Kısıtlar:

$$\sum_{i=1}^n x_i r_i > 0$$

$$\sum_{i=1}^n x_i = 1$$

$$0 \leq x_i \leq 1$$

r_f değeri risksiz faiz oranı olup 2019 yılı Merkez Bankası tarafından belirlenen faiz oranlarına göre hesaplanarak 0,05 olarak alınmıştır. Analizde kullanılan kısıtlar, beklenen getiriyi temsil eden R’nin 0’dan büyük olması her daim yatırımcıya kâr sağlaması hedeflenmiştir. Ayrıca hisse senetlerinin ağırlık oranları toplamı 1 olmak zorundadır.

3.1. Karesel Programlama ile Portföy Optimizasyonu

Markowitz ortalama varyans modelinin çözümlenmesinde kullanılan klasik optimizasyon yöntemi olan karesel programlama yöntemi ile portföy optimizasyon problemi için optimum portföy hedeflenmiştir. Bu çalışma için karesel programlama yönteminde sharpe performans oranı ve treynor endeksi amaç fonksiyonu, markowitz ortalama varyans modeli kısıtları ise kısıt olarak kullanılmıştır. Çözümleme sonucunda her iki maksimum performans ölçüsüne (Treynor endeks ve Sharpe oranı) sahip portföy çeşitleri ve bilgileri tablo 2’de verilmiştir.

Tablo 2. Karesel Programlama yöntemine göre farklı performans ölçülerinin kullanılması ile elde edilen portföye ait bilgiler

	P1	P2
Portföy Beklenen getirisi	0,1656	0,1173
Portföy Riski	0,7606	0,9336
Portföy Betası (Sistematik riski)	0,7518	0,5772
İçerdiği hisse senet sayısı	20	18
Treynor endeks değeri	0,1536	-
Sharpe Performans Oranı	-	0,0721

Tablo 2’de Treynor endeksi modeli kullanılarak elde edilen optimum portföy (P1), Sharpe oran modeli kullanılarak elde edilen optimum portföy (P2) olarak gösterilmiştir. Her iki portföy çeşidine ait içerdiği hisse senetleri ve hisse senetlerinin portföy içi ağırlık oranları tablo 3’de verilmiştir.

Tablo 3. Portföy çeşitlerinin içerdiği hisse senetleri ve hisse senet ağırlık oranları

	P1	P2	P1	P2
--	----	----	----	----

AKBNK	0	0	KRDMD	0	0
ARCLK	0,0428	0,0171	PETKM	0,0239	0,0648
ASELS	0,023	0	PGSUS	0,0456	0,0144
BIMAS	0,1469	0,1188	SAHOL	0	0

Tablo 3 devamı. Portföy çeşitlerinin içerdiği hisse senetleri ve hisse senet ağırlık oranları

	P1	P2		P1	P2
DOHOL	0	0,0782	SİSE	0,0787	0
EKGYO	0,008	0,0015	SODA	0,0464	0,1659
ENJSA	0,033	0,1182	TAVHL	0,0218	0,0487
EREGL	0,1557	0,0582	TCELL	0,0999	0,0494
FROTO	0,0185	0,0538	THYAO	0	0
GARAN	0	0	TKFEN	0,0005	0,0144
HALKB	0	0	TOASO	0,0983	0,0112
ISCTR	0	0	TTKOM	0,0661	0
KCHOL	0,0071	0,0227	TUPRS	0,0797	0,0797
KOZAA	0,0017	0,0162	VAKBN	0	0
KOZAL	0,0021	0,0666	YKBNK	0	0

3.2. Genetik Algoritma ile portföy optimizasyonu

Yatırımcıya maksimum getiriye karşılık minimum risk sunabilmek için amaç fonksiyonun maksimum olması gerekmektedir. Optimizasyon problemini çözmek için GA yöntemi ile optimum portföy hedeflenmiştir. Portföy optimizasyonu problemi için GA yöntemi şu şekildedir;

Adım 1: Başlangıç çözümü için kromozomdaki genler yani portföy optimizasyon problemi için hisse senetleri $[0,1]$ aralığında rasgele ağırlıklandırılır.

Adım2: Ağırlık oranları ile her bir kromozoma (portföy) ait amaç fonksiyon değeri hesaplanır. Uygunluk değerleri maksimumdan minimuma doğru sıralanır. Sıralama sonucunda iyi olan kromozomlar elitizm yöntemi ile bir sonraki aşamalar için eşleşme havuzuna atılır.

Uygulamada elitizm oranı 0,30 olarak belirlenmiştir ve kromozomların en iyi uygunluk değerine sahip olanlarının %30'u eşleşme havuzuna atılmıştır. Bu yöntemin amacı bir sonraki adımda gerçekleşecek olan çaprazlama işlemi için yeni bireylerin üretilmesi amacıyla kaliteli ebeveynleri bir havuzda toplamaktır.

Adım 3: Eşleşme havuzundan rasgele 2 kromozom seçilir. Çaprazlama oranı ile $(0,1)$ aralığında üretilen rasgele bir sayı karşılaştırılır ve çaprazlama işlem olup olmayacağına karar verilerek, işlem uygulanır. Çaprazlama işlemi için tek noktalı çaprazlama tekniği uygulanmıştır. Çaprazlama sonucu elde edilen yeni bireyler yani kromozomlar eski kromozomlar ile karşılaştırma yapılmadan yer değiştirir.

Adım 4: Rasgele bir kromozom seçilir. Önceden belirlenen mutasyon oranı ile $(0,1)$ aralığında üretilen rasgele sayı karşılaştırılır ve mutasyon işlemi uygulanıp uygulanmayacağına karar verilir. Mutasyon işlemi uygulanan kromozom eski kromozom ile yer değiştirir.

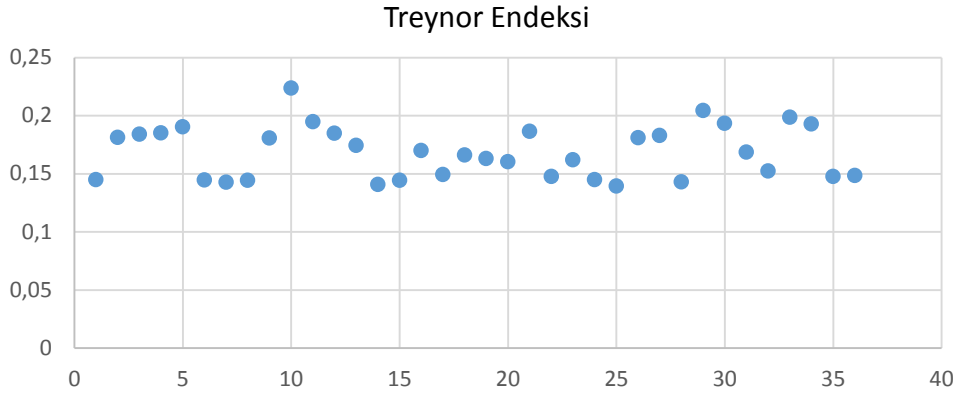
Adım 5: Durdurma kriteri sağlanıyorsa program durur, aksi halde adım 2'den tekrar optimum çözüm arayışı devam eder. Programda durdurma kriteri olarak önceden belirlenen iterasyon sayısı kullanılmıştır. İterasyon sayısını tamamlayan program optimum portföye ulaşmıştır.

Portföy optimizasyon problemine GA yönteminin kullanılması ile optimum portföy hedeflenmiştir. GA yönteminde durdurma kriteri olan iterasyon sayısı, optimum portföye ulaşmada önemli bir etkidir ve çalışmada durdurma kriteri olarak 1000 iterasyon sayısı kullanılmıştır. Birçok deneme sonucunda GA parametre değerlerine karar verilmiştir. Farklı parametre değerleri içeren set grupları ve parametre değerleri tablo 4’de oluşturulmuştur.

Tablo 4. GA ile portföy optimizasyonu için kullanılan parametre değerleri ve set grupları

Mutasyon oranı 0,001				
Çaprazlama Oranı	Popülasyon Büyüklüğü			
	100	110	120	130
0,5	GA 1. Set	GA 2. Set	GA 3. Set	GA 4. Set
0,75	GA 5. Set	GA 6. Set	GA 7. Set	GA 8. Set
1	GA 9. Set	GA 10. Set	GA 11. Set	GA 12. Set
Mutasyon oranı 0,01				
Çaprazlama Oranı	Popülasyon Büyüklüğü			
	100	110	120	130
0,5	GA 13. Set	GA 14. Set	GA 15. Set	GA 16. Set
0,75	GA 17. Set	GA 18. Set	GA 19. Set	GA 20. Set
1	GA 21. Set	GA 22. Set	GA 23. Set	GA 24. Set
Mutasyon oranı 0,1				
Çaprazlama Oranı	Popülasyon Büyüklüğü			
	100	110	120	130
0,5	GA 25. Set	Ga 26. Set	GA 27. Set	GA 28. Set
0,75	GA 29. Set	GA 30. Set	GA 31. Set	GA 32. Set
1	GA 33. Set	GA 34. Set	Ga 35. Set	GA 36. Set

Farklı parametre değerleri ile oluşturulan GA set grupları hem treynor endeks değeri için hem de sharpe performans oranı için çözümlenmiştir. Farklı parametre değeri ile çözümlenen farklı portföy performans oranlarına sahip portföy çeşitleri elde edilmiştir. GA için her bir set grubu 1000 iterasyon sayısı kadar çözümlenmiş ve ulaşılan en yüksek portföy performans oranına sahip portföy optimum portföy olarak belirlenmiştir. GA ile portföy optimizasyonunda kullanılan Treynor endesk oranına göre elde edilen değerler şekil 1’de gösterilmiştir. Çözümleme sonucunda set gruplarına ait portföy bilgileri tablo 5’de verilmiştir.



Şekil 1. GA set gruplarının Treynor endeks sonuçları

Tablo 5. Treynor Endeksi kullanılarak GA ile portföy optimizasyon sonuçları

GA numarası	Treynor Endeksi	Portföy Getirisi	Portföy Riski	Portföy Betası	Hisse senet sayısı
1	0,1447	0,1752	1,3137	0,8651	24
2	0,1811	0,2082	1,2944	0,8737	23
3	0,1839	0,2098	1,2893	0,8691	25
4	0,1849	0,1976	1,2212	0,7981	21
5	0,1902	0,1946	1,1814	0,7601	22
6	0,1444	0,1689	1,2065	0,8232	28
7	0,1426	0,1703	1,2519	0,8434	26
8	0,1444	0,1778	1,2687	0,8852	24
9	0,1806	0,2028	1,2293	0,8462	24
10	0,2236	0,2210	1,2335	0,7648	22
11	0,1946	0,2066	1,2605	0,8048	22
12	0,1849	0,2063	1,2616	0,8452	25
13	0,1742	0,2016	1,2937	0,8703	23
14	0,1408	0,1828	1,3445	0,9429	27
15	0,1442	0,1758	1,2573	0,8723	26
16	0,1698	0,2039	1,3358	0,9069	24
17	0,1492	0,1826	1,3367	0,8885	21
18	0,1662	0,1925	1,2601	0,8576	25
19	0,1631	0,1893	1,2394	0,8539	27
20	0,1602	0,1792	1,1939	0,8063	22
21	0,1865	0,2008	1,2332	0,8088	23
22	0,1475	0,1856	1,3159	0,9193	27
23	0,1619	0,1860	1,2303	0,8400	24
24	0,1449	0,1754	1,3029	0,8652	26
25	0,1393	0,1728	1,2772	0,8820	27
26	0,1809	0,2120	1,3332	0,8955	25
27	0,1827	0,1904	1,2076	0,7685	24
28	0,1428	0,1660	1,1828	0,8120	27
29	0,2043	0,2157	1,2571	0,8110	21
30	0,1933	0,2003	1,2212	0,7774	24
31	0,1685	0,1873	1,2123	0,8146	24
32	0,1522	0,1859	1,3138	0,8928	24
33	0,1987	0,2106	1,2666	0,8083	20
34	0,1929	0,2033	1,2114	0,7946	23
35	0,1476	0,1839	1,3225	0,9071	26
36	0,1483	0,1747	1,2233	0,8412	26

Amaç fonksiyon olarak kullanılan Treynor endeksi sonuçlarına göre 36 farklı portföy elde edilmiştir. Tüm portföy çeşitleri incelendiğinde maksimum Treynor endeks oranına sahip portföy 10 nolu set gurubuna ait olup bu set gurubuna ait bilgiler tablo 6 ve tablo 7’de verilmiştir.

Tablo 6. GA 10. Set grubuna ait elde edilen optimum portföy bilgileri

Treynor Endeksi	0,223639
Portföy Getirisi	0,221032
Portföy Riski	1,233507
Portföy Betası	0,764768
İçerdiği Hisse senet sayısı	22
Popülasyon büyüklüğü (kromozom sayısı)	110
Çaprazlama oranı	1
Mutasyon oranı	0,001

Tablo 7. GA 10. Set grubuna ait elde edilen portföyün içerdiği hisse senetleri ve portföy içi ağırlık oranları

KOD	x_i	KOD	x_i
AKBNK	0,050633	KRDMD	0
ARCLK	0	PETKM	0,113924
ASELS	0	PGSUS	0,037975
BIMAS	0,063291	SAHOL	0,012658
DOHOL	0,063291	SİSE	0,012658
EKGYO	0	SODA	0,025316
ENJSA	0,075949	TAVHL	0,025316
EREGL	0,025316	TCELL	0,012658
FROTO	0,037975	THYAO	0
GARAN	0,012658	TKFEN	0,113924
HALKB	0	TOASO	0,012658
ISCTR	0,063291	TTKOM	0,012658
KCHOL	0,101266	TUPRS	0
KOZAA	0,088608	VAKBN	0
KOZAL	0,012658	YKBNK	0

Farklı parametre değerleri içeren set gruplarının GA ile Sharpe performans oranı amaç fonksiyonu kullanılarak çözümlenmesi sonucunda 36 adet farklı bilgiler içeren portföy çeşitleri oluşturulmuştur. Portföy çeşitleri arasından maksimum Sharpe performans oranına sahip portföy 11 nolu set grubu olup 20 adet hisse senedini içeren bu portföyün Sharpe performans oranı 0,143939 olarak belirlenmiştir. Elde edilen sonuçlar tablo 8’de verilmiştir.

Tablo 8. Sharpe oranı kullanılarak GA ile portföy optimizasyon sonuçları

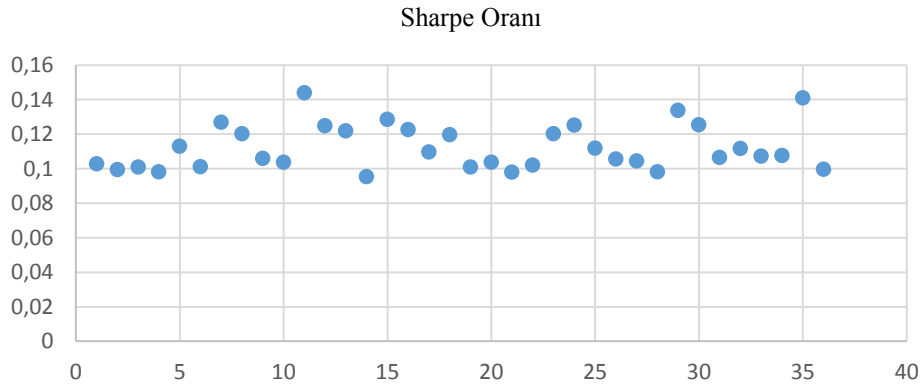
GA numarası	Sharpe Oranı	Portföy Getirisi	Portföy Riski	Portföy Betası	Hisse senet sayısı
1	0,1028	0,1800	1,2652	0,8589	28
2	0,0993	0,1709	1,2174	0,8361	24
3	0,1008	0,1780	1,2696	0,8714	26
4	0,0980	0,1723	1,2473	0,8520	25
5	0,1129	0,1930	1,2663	0,8791	27
6	0,1009	0,1705	1,1937	0,8258	24
7	0,1267	0,2200	1,3415	0,9160	24
8	0,1201	0,2014	1,2611	0,8503	25

9	0,1059	0,1750	1,1797	0,7940	24
10	0,1036	0,1863	1,3151	0,8893	24
11	0,1439	0,2295	1,2472	0,7828	20
12	0,1247	0,2040	1,2349	0,8544	25
13	0,1219	0,2068	1,2860	1,0000	24
14	0,0952	0,1793	1,3579	0,9529	25
15	0,1285	0,2067	1,2200	0,8132	24
16	0,1226	0,1986	1,2114	1,0000	26
17	0,1095	0,1922	1,2986	0,9123	27
18	0,1196	0,1950	1,2119	0,8178	26
19	0,1009	0,1830	1,3171	0,8994	27
20	0,1037	0,1908	1,3582	0,9222	26
21	0,0980	0,1707	1,2326	0,8465	26
22	0,1020	0,1800	1,2743	0,8848	26

Tablo 8 devamı. Sharpe oranı kullanılarak GA ile portföy optimizasyon sonuçları

GA numarası	Sharpe Oranı	Portföy Getirisi	Portföy Riski	Portföy Betası	Hisse senet sayısı
23	0,1202	0,2092	1,3239	0,8803	21
24	0,1252	0,2056	1,2429	0,8435	23
25	0,1118	0,1917	1,2678	0,8700	27
26	0,1055	0,1868	1,2961	0,8981	26
27	0,1044	0,1904	1,3453	0,9292	27
28	0,0980	0,1718	1,2426	0,8526	27
29	0,1337	0,2299	1,3453	0,8962	20
30	0,1253	0,2146	1,3131	0,8953	24
31	0,1063	0,1950	1,3636	0,9449	25
32	0,1116	0,1918	1,2707	0,8696	25
33	0,1071	0,1903	1,3104	0,9138	27
34	0,1075	0,1796	1,2056	0,8208	27
35	0,1409	0,2225	1,2244	0,7968	21
36	0,0995	0,1714	1,2195	0,8346	24

GA ile portföy optimizasyonda performans ölçüsü olan Sharpe oranının kullanılması sonucunda 36 farklı bilgiler içeren portföy çeşitlerinin Sharpe oranları şekil 2’de verilmiştir.



Şekil 2. GA set gruplarının Sharpe oranı sonuçları

Çözümleme sonucunda ulaşılan optimum portföye ait bilgiler tablo 9’da verilmiştir. 11. Set grubunun içerdiği hisse senetleri ve hisse senetlerinin portföy içi ağırlık oranları tablo 10’da verilmiştir.

Tablo 9. GA 11. Set grubuna ait elde edilen portföy bilgileri

Sharpe Oranı	0,143939
Portföy Getirisi	0,229521
Portföy Riski	1,247203
Portföy Betası	0,782806
İçerdiği Hisse senet sayısı	20
Popülasyon büyüklüğü (kromozom sayısı)	120
Çaprazlama oranı	1
Mutasyon oranı	0,001

Tablo 10. GA 11. Set grubuna ait elde edilen portföyün içerdiği hisse senetleri ve portföy içi ağırlık oranları

KOD	x_i	KOD	x_i
AKBNK	0	KRDMD	0,010753
ARCLK	0,053763	PETKM	0
ASELS	0	PGSUS	0,096774
BIMAS	0	SAHOL	0,010753
DOHOL	0,096774	SİSE	0,032258
EKGYO	0,010753	SODA	0
ENJSA	0,075269	TAVHL	0,064516
EREGL	0,010753	TCELL	0
FROTO	0,021505	THYAO	0
GARAN	0,010753	TKFEN	0
HALKB	0	TOASO	0,096774
ISCTR	0,021505	TTKOM	0,086022
KCHOL	0,064516	TUPRS	0,064516
KOZAA	0,096774	VAKBN	0
KOZAL	0,043011	YKBNK	0,032258

Tablo 11. Karesel programlama ve GA sonuçlarının karşılaştırması

	P1		P2	
	GA	KP	GA	KP
Treynor Endeks	0,223639	0,1536	-	-
Sharpe Oranı	-	-	0,143939	0,0721
Portföy Getirisi	0,221032	0,1656	0,229521	0,1173
Portföy Riski	1,233507	0,7606	1,247203	0,9336
Portföy Betası	0,764768	0,7518	0,782806	0,5772
İçerdiği Hisse senet sayısı	22	20	20	18

4. Sonuç ve Yorum

Markowitz tarafından literatüre kazandırılan ortalama varyans modeli karesel programlama ile çözümlenen bir model olup optimum portföy için çalışmalarda genellikle karesel programlama kullanılmıştır. Son yıllarda optimizasyon problemlerinde kullanılan yapay zeka yöntemlerinin iyi sonuçlar verdiği gözlemlenmiştir. Genetik dizilimden esinlenerek literatüre kazandırılan GA yöntemi ile portföy optimizasyonu problemi daha önce çözümlenmiştir. literatürde yapılan çalışmalardan farklı olarak bu çalışmada optimum portföye ulaşmak için karesel programlama ve GA kullanılmıştır. Yatırımcı her zaman kendisine minimum riske

karşılık maksimum getiri sağlayacak portföyü tercih eder. Yatırımcıya en uygun portföyü sunabilmek için performansını değerlendirmek gerekir. Bu nedenle çalışmada sistematik ve sistematik olmayan riski içeren sharpe oranı ile sadece sistematik riski içeren treynor endeksi kullanılmıştır. 2019 yılına ait BİST 30 endeks bünyesinde işlem göre 30 adet hisse senedinin gün sonu kapanış fiyatlarından oluşturulan veri seti hem karesel programlama ile hem de GA ile çözümlenmiştir. Her iki optimizasyon yönteminde de amaç fonksiyonu olarak farklı risk hesaplamaları içeren performans oranları (Sharpe oranı ve treynor endeksi) kullanılmıştır. Çalışmada sadece iki farklı yöntem karşılaştırmakla kalmayıp iki farklı portföy performans ölçüsü de karşılaştırılmıştır.

İlk olarak karesel programlama yöntemi sharpe oranı ve treynor endeksi performans ölçüleri kullanılarak çözümlenmiştir. Çözümleme sonucunda Sharpe oranı 0,0721 ve Treynor endeksi 0,1536 olarak bulunmuştur. Karesel programlama ile çözümlenen her iki portföy performans ölçüsü karşılaştırıldığında Treynor endeksi ile elde edilen portföyün diğer portföye göre yatırımcıya düşük risk ve yüksek getiri sağladığı görülmüştür.

İkinci olarak GA farklı parametre değerlerine göre oluşturulan set gruplarının 1000 iterasyon sayısı kadar çözümlenmesi sonucundan ulaşılan maksimum performans değeri çözümlenen set grubu için optimum portföy olarak belirlenmiştir. Öncelikle sharpe oranı ile 36 farklı parametre değeri içeren set grubu oluşturulmuş ve her biri 1000 iterasyon sayısı kadar çözümlenmiştir. Çözümleme sonucunda 36 set grubu arasından optimum portföye ait maksimum Sharpe oranı 0,143939 olarak hesaplanmıştır. 20 adet hisse senedinden oluşan bu portföy yatırımcıya 1,247203 riske karşılık 0,229521 getiri imkanı sunmuştur.

GA için treynor endeks modeli amaç fonksiyonu olarak 36 farklı set grubu için çözümlenmiş ve her bir set gurubu 1000 iterasyon sayısı kadar çözüme ulaşmıştır. 1000 çözüm arasından en yüksek treynor endeks değerine sahip portföy çözümlenen set grubu için optimum portföy olarak belirlenmiştir. Analiz sonucunda 36 farklı bilgiler içeren portföy elde edilmiş ve bu portföy çeşitleri arasından maksimum treynor endeks değerine sahip portföy belirlenmiştir. Bu portföyün treynor oranı 0,223639 olup 22 adet hisse senedi içermektedir.

Her iki yöntem karşılaştırıldığında; çalışmada kullanılan veri seti için yapılan analizler sonucunda GA ile elde edilen portföy çeşitlerinin performanslarının karesel programlama yöntemine göre daha iyi sonuçlar verdiği gözlemlenmiştir. Ayrıca GA karesel programlama yöntemine göre yatırımcıya maksimum getiri sağladığı ayrıca portföy çeşitlendirilmesi açısından yatırımcıya daha iyi imkan sunduğu görülmüştür.

Çalışma da kullanılan portföy performans oranları incelendiğinde; treynor endeksinin sharpe oranına göre her iki yöntemde de daha iyi portföy çeşitlendirdiği ve risk bakımından yatırımcıyı daha güvenilir bir portföy sunduğu görülmüştür.

Gelecek çalışmalarda farklı yapay zeka yöntemleri ile farklı veri setleri oluşturularak çözümlenmeler yapılabilir.

Araştırmacıların Katkı Oranı Beyanı

Azize Zehra ÇELENLİ BAŞARAN: Metodoloji, Araştırma, Orijinal Taslak Yazımı, Biçimsel Analiz, Denetim/Gözlem/Tavsiye.

Destek ve Teşekkür Beyanı

Bu çalışmanın yazarı olarak herhangi bir destek ve teşekkür beyanımın bulunmadığını bildiririm.

Çatışma Beyanı

Bu çalışmanın yazarı olarak herhangi bir çatışma beyanımın bulunmadığını bildiririm.

Etik Kurul Onayı ve/veya Aydınlatılmış Onam Bilgileri

Bu çalışmanın yazarı olarak herhangi bir etik kurul onayı ve/veya aydınlatılmış onam bilgileri beyanımın bulunmadığını bildiririm.

Kaynakça

- [1] C. Shenoy and K.C. McCarthy, *Applied Portfolio Management*, John Wiley & Sons, Inc., New Jersey, 28-29, 1988.
- [2] F. K. Reilly and K. C. Brown, *Investment Analysis and Portfolio Management*, 2002.
- [3] H. Markowitz, "Portfolio selection," *J. Finance*, 7, 77-91, 1952.
- [4] S. Canbaş, and H. Doğukanlı, *Finansal Pazarlar*, Adana, Karahan Kitabevi, 2007.
- [5] J.H. Holland, *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Application to Biology, Control, and Artificial Intelligence*, Ann Arbor, MI: University of Michigan Press, 1975.
- [6] A. Diyar, T. Çetinyokuş, and M. Dağdeviren, "Portföy seçimi problemi için kds/ga yaklaşımı," *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 17(4), 2002.
- [7] K.J. Oh, T.Y. Kim, and S. Min, "Using genetic algorithm to support portfolio optimization for index fund management," *Expert Syst. Appl.*, 28(2), 371-379, 2005.
- [8] D. Lin, X. Li, and M. Li., "A genetic algorithm for solving portfolio optimization problems with transaction costs and minimum transaction lots," *International Conference on Natural Computation*, (3612), 808-811, 2005.
- [9] K. K. Lai, L. Yu, S. Wang, and C. Zhou, "A double-stage genetic optimization algorithm for portfolio selection," *Neural Information Processing*, LNCS, 4234, 928-937, 2014.
- [10] C. M. Lin, and M. Gen, "An effective decision-based genetic algorithm approach to multiobjective portfolio optimization problem," *Appl Math. Sci.*, 1(5), 201-210, 2007.
- [11] S. Skolpadungket, K. Dahal, and N. Harnpornchai, "Portfolio optimization using multi-objective genetic algorithms," in *Proc. IEEE Congr. Evol. Comput. (CEC)*, sep., 516-523, 2007.
- [12] C.C. Lin and Y. T. Liu, "Genetic algorithms for portfolio selection problems with minimum transaction lot," *Eur. J. Ope. Res.*, 185(1), 393-404, 2008.
- [13] T. J. Chang, S.C. Yang and K. J. Chang, "Portfolio optimization problems in different risk measures using genetic algorithm," *Expert Syst. Appl.*, 36(7), 10529-10537, 2009.
- [14] H. Soleimani, H.R. Golmakani, and M.H. Salimi, "Markowitz-based portfolio selection with minimum transaction lots, cardinality constraints and regarding sector capitalization using genetic algorithm," *Expert Syst. Appl.*, 36(3/1), 5058-5063, 2009.
- [15] J. F. Chang, T.C. Wang and Y. T. Min, "Using Genetic Algorithms to construct a low-risk fund portfolio based on the Taiwan 50 Index," *Computational Aspects of Social Networks (CASoN), 2010 International Conference on*, IEEE, 2010.
- [16] A.R. Pandari, A. Azar, and A.R. Shavazi, "Genetic algorithms for portfolio selection problems with non-linear objectives," *African Journal of Business Management*, 6(20), 6209, 2012.
- [17] C.B. Kalayci, O. Ertenlice, H. Akyer and H. Aygoren, "A review on the current applications of genetic algorithms in mean-variance portfolio optimization," *Pamukkale University Journal of Engineering Sciences*, 23(4), 470-476, 2017.
- [18] H. Markowitz, *Portfolio Selection, Efficient Diversification of Investments*, J. Wiley. 1959.
- [19] A. Ceylan and T. Korkmaz, *Borsada Uygulamalı Portföy Yönetimi*, Bursa, Ekin Kitabevi, 3. 1998.
- [20] A.G. Karaşin, *Sermaye piyasası analizleri*, Sermaye Piyasası Kurulu, 1987.
- [21] W.F. Sharpe, "Mutual fund performance," *The Journal of Business*, 39(1), 119-138, 1966.
- [22] E. Aksoy, *Uluslararası Portföy Yönetimi*, Ankara, Detay Yayıncılık, 2014.
- [23] J. Treynor, *How to rate management of investment funds*, 1965.
- [24] D.E. Goldberg and K. Deb, "A comparative analysis of selection schemes used in genetic algorithms," *Foundations of Genetic Algorithm*, 1, 69-93, 1991.
- [25] T. Bäck, D. B. Fogel, and Z. Michalewicz, *Evolutionary Computation 1: Basic Algorithms and Operators*, Bristol, U.K., 2000.
- [26] M. Srinivas and L.M. Patnaik, "Genetic algorithms: A survey," *Computer*, 127(6), 17-26, 1994.
- [27] D.E. Goldberg and J.H. Holland, "Genetic algorithms and machine learning," *Machine Learning*, 3(2), 95-99, 1988.

- [28] G. G. Emel, Ç. Taşkın, “Genetik algoritmalar ve uygulama alanları,” *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21(1): 129-152, 2009.
- [29] K. De Jong, “An analysis of the behavior of a class of genetic adaptive systems,” Ph.D. dissertation, Dept. Comput. Sci., Univ. Michigan, Ann Arbor, MI, 1975.
- [30] A. Z. Çelenli Başaran, V.R. Uslu, “The portfolio optimization based on sharp performance ratio,” *Turkish Journal of Forecasting*, 3(1):7-14, 2019.