Genetik Algoritmalar ile Optimal Portföy Seçimi: BİST-30 Örneği

Optimal Portfolio Selection with Genetic Algorithm: An Example of BIST-30

Feyyaz ZEREN

Namık Kemal Üniversitesi,
İktisadi ve İdari Bilimler Fakültesi,
İşletme Bölümü, Tekirdağ, Türkiye
fzeren@nku.edu.tr

Mehmet BAYĞIN

Fırat Üniversitesi,
Mühendislik Fakültesi, Bilgisayar
Mühendisliği Bölümü, Elazığ, Türkiye
mbaygin@firat.edu.tr

Özet

Finansal yatırım kararlarındaki en temel problemlerden biri optimal portföyün seçimidir. Bu bağlamda hangi yöntem kullanılarak uygun portföye karar verileceği önem arz etmektedir. Genetik algoritmalar ise çok sayıda çözüm kümesinin olduğu durumlarda optimal portföyü tespit edebilecek bir optimizasyon yöntemidir. Bu çalışmada genetik algoritmalar kullanılarak Borsa İstanbul 30 (BİST-30) endeksine ilişkin optimal portföy tespit edilmeye çalışılmıştır. Ocak-2010 Haziran-2013 dönemine ait aylık verilerin kullanıldığı uygulamanın bulgularına göre Lambda (λ) değerinin 0.20 olduğu durumda optimal portföy seçiminin 18 adet hisseden oluşacağı tespit edilmiştir. Risk faktörünün baskınlığı arttıkça ise algoritmanın performansı düşmekte ve optimal portföy seçimi endeksin tamamından oluşmaktadır.

Anahtar Kelimeler: Genetik Algoritmalar, Portföy Seçimi, BİST-30, Risk, Getiri

Abstract

One of the main problem is an optimal portfolio selection in the financial investment decisions. In this context, the determining of optimal portfolio by using which method is a significant for researcher. On the other hand, Genetic algorithm is optimization technical to select optimal portfolio when there are the plurality of cluster solutions. In this study, it is aimed to determine of optimal portfolio for Istanbul Stock Market 30 Indices. When Lambda value (λ) is 0.20, optimal portfolio selection is consist of 18 shares According to the application findings which is used data spanned from January-2010 and June-2013. When a dominance of risk factor increases, performance of algorithm decreases and optimal portfolio selection is consist of all BIST-30 Indices.

Keywords: Genetic Algorithms, Portfolio Selection, BIST-30, Risk, Return

1. Giriş

Yatırım kararları verilirken yatırımcılar tarafından önemsenen iki temel unsur söz konusudur. Bunlar risk ve karşılığında elde edilecek getiridir. Portföy teorilerinin en önemli amacı riski minimum, getiriye ise maksimum yapabilecek bileşimi oluşturmaktadır (Abay, 2013). Bu hususta literatürde modern portföy teorisi bağlamında bir çok tartışmaya rastlamak mümkündür.

Geleneksel portföy teorisine göre riski çeşitlendirmek için eldeki hisse senedi sayısını arttırmak gerekemekteydi. Ancak modern portföy teorisi bu olguyu kırarak yeni bulgulara ulaşmıştır (Korkmaz ve diğerleri, 2013). 1952 yılında Harry Markowitz tarafından ortaya atılan modern portföy teorisi finans tarihinin en önemli dönüm noktalarında biri olmuş ve günümüzde finansın 6 temel yapı taşından biri olarak kabul edilmektedir.

Bu teorinin getirdiği en önemli yenilik ise portföyü oluştururken daha ileri yöntemlerin kullanılmasıdır. Bu teoriye göre dikkat edilmesi gereken en önemli konu portföyü oluşturan varlıklar arasındaki korelasyondur (Saraç, 2012). Portföyün riski, geleneksel portföy teorisinde olduğu gibi portföydeki menkul kıymet sayısını tesadüfi olarak artırmak suretiyle değil, birbirleriyle negatif korelasyonlu varlıkları bir araya getirerek düşürülebilir. Bu yaklaşıma göre etkin portföyler kümesi içerisinde en uygun risk ve getiriye sahip olan bileşim seçilir. Bu yöntem Markowitz tarafından ortalama-varians yöntemi olarak adlandırılmıştır (Demirtaş ve Güngör, 2004).

Markowitz'in modern portföy teorisine göre iki hisse senedi üzerinden portföyün kovaryansı şöyle hesaplanmaktadır:

$$Cov_{AB} = \frac{\sum_{i=1}^n [r_{Ai} - E(r_A)] [r_{Bi} - E(r_B)]}{n - 1}$$

Kovaryans korelasyon katsayısından hareketle şu şekilde de tespit edilebilir:

$$Cov_{AB} = \rho_{AB} \times \sigma_A \times \sigma_B$$

Burada korelasyon katsayısı ise şu formülle gösterilmektedir:

$$\rho_{AB} = \frac{\sigma_{AB}}{\sigma_A \times \sigma_B}$$

Standart sapma ise şu şekilde ifade edilir:

$$\sigma_P = \sqrt{(w_A^2 \times \sigma_A^2) + (w_B^2 \times \sigma_B^2) + 2(w_A \times w_B \times \rho_{A,B} \times \sigma_A \times \sigma_B)}$$

Bu formüllerde; n gözlem sayısını, w_A^2 ve w_B^2 portföy içerisindeki ağırlıkları, σ_A ve σ_B portföy içerisindeki hisse senetlerinin standart sapmalarını, $E(r_A)$ ve $E(r_B)$ ise beklenen değerleri ifade etmektedir.

Literatürde yapılan çalışmalar incelendiğinde optimal portföyün tespitinde doğrusal ve doğrusal olmayan programlama, yapay sinir ağları, bulanık mantık ve genetik algoritmalar gibi çeşitli mühendislik metodlarının kullanıldığı görülmüştür. Bu bağlamda çalışmanın bu kısmında ilk olarak genetik algoritmaları kullanarak uygun portföy seçimine karar vermeyi amaçlayan çalışmaların özetine yer verilmiştir.

Sonrasında ise genetik algoritmaların kısa bir izahı ve elde edilen ampirik bulgular sunulmuştur. Çalışmada, genetik algoritmaların optimal portföy seçiminde ne derece etkin ve verimli bir yöntem olduğunun kanıtlanması amaçlanmıştır.

2. Literatür özeti

Lai ve diğerleri (2006) Çin'in Şanghai Borsasını inceledikleri çalışmalarında Ocak 2001-Aralık 2004 dönemlerini ele almışlardır. Rasgele seçilen 100 firmaya ait verilerin incelendiği ve iki aşamalı genetik optimizasyon algoritmalarının kullanıldığı çalışmanın ilk aşamasında genetik algoritma kaliteli hisseleri seçmiştir. İkinci aşamada ise algoritma tarafından portföye uygun optimal dağılım seçilmiştir. Sonuç olarak bu çalışmaya göre oluşturulan genetik algoritma portföye en uygun ve faydalı havuzu oluşturabilme yeteneğine sahiptir.

Lin ve Liu (2006) ise 1997-2000 yılları arasında aylık veriler üzerinden Tayvan yatırım fonlarını inceledikleri çalışmalarında uygun çözüm olarak genetik algoritmaları kullanmışlardır. Oluşturulan portföy belli bir getiri düzeyinde en düşük riske sahip veya belli bir risk düzeyinde en yüksek getiriye sahip portföye ilişkin oluşan etkin sınıra oldukça yakındır.

Endeks fon yönetimi için genetik algoritmaların kullanılmasını öneren bir başka çalışmada ise Oh ve diğerleri (2005) Güney Kore borsası KOSPI'ye ait Ocak-1999 Aralık-2000 arasındaki aylık verileri incelemişlerdir. Çalışmanın sonucunda genetik algoritmalar aracılığıyla önerilerin portföyün önemli performans gösterdiği tespit edilmiştir.

Wang ve diğerleri (2006) çalışmalarında genetik algoritmaları kullanarak uygun portföyü oluşturmak için Tayvan borsasına ilişkin 1995-2003 arasındaki çeyreklik verileri kullanmışlardır. Çalışmanın sonucunda Stokastik Portföy Genetik Algoritma (SPGA) yönteminin etkin bir performans gösterdiği görülmüştür.

Genetik algoritmalar kullanılarak portföy çeşitlendirmesi hakkında Türkiye ile ilgili yapılan ilk çalışmalarda biri ise Gökçe ve Cura'ya (2003) aittir. 1999 başından Haziran-2000 dönemine kadar haftalık verilerin incelendiği çalışmada portföye uygun hisse adedinin 6 ile 14 arasında olması gerektiği belirtilmiştir. Yine İMKB-30'un incelendiği benzer bir çalışmada Demirtaş ve Güngör (2004) uygun hisse adedinin 19 olduğunu tespit etmişlerdir.

Keskintürk ve diğerleri (2010) İMKB-30'a ait Ocak-2001 ve Temmuz-2002 arasındaki haftalık verileri inceledikleri çalışmalarında elde edilen optimal portföylerin çeşitli kriterlere bağlı olarak kaç adet hisse senedinden oluşması gerektiğini araştırmışlardır. Çalışmanın sonuçlarına göre oluşacak portföylerin 3 ile 17 arasında hisseden oluşması gerektiği tespit edilmiştir.

Özdemir (2011) çalışmasında İMKB-100 endeksi ve endeksi oluşturan 100 adet hisse senedinin 15.05.2008–26.06.2009 arasındaki günlük verilerini kullanarak genetik algoritmaların etkin yatırım portföy seçimini araştırmış ve optimal portföy seçiminin 8 hisseden oluşması gerektiğine karar vermiştir.

Görüldüğü üzere literatürde genetik algoritmaların portföy seçiminde kullanımı konusunda yapılan çalışma sayısı oldukça azdır ve bu alandaki eksiklik göze çarpmaktadır. Bu bağlamda çalışmanın en önemli odak noktası portföy optimizasyonu konusunda genetik algoritmaların da bir ölçüm aracı olabileceğini kanıtlamaktır.

3. Genetik algoritmalar

Genetik algoritmalar, verilen bir problem için oldukça geniş çözüm uzayında optimal sonucu bulmayı hedefleyen bir optimizasyon tekniğidir (Goldberg, 1989). Başka bir deyişle çözümü oldukça zaman alan ve NP-hard problemler olarak adlandırılan problemlerin çözümünde kullanılan bir yumuşak hesaplama tekniğidir (Reeves, 1995). Genetik algoritmalar literatürde birçok problemin çözümünde aktif olarak kullanılmaktadır (Karakose ve diğerleri, 2014; Shang ve Liu, 2010; Skolpadungket ve diğerleri, 2007). Gerçekleştirilen bu çalışmada da genetik algoritmalar kullanılarak optimal portföy seçimi işlemi gerçekleştirilmiştir. Önerilen yaklaşım sayesinde belirlenen risk değerine göre kullanıcıların en uygun portföy kombinasyonunu seçebilmesine olanak sağlanmıştır. Genetik algoritma yaklaşımı genel olarak 6 temel adımdan oluşmaktadır (Baygın ve Karakose, 2013). Genetik algoritmanın işleyişini gösteren akış diyagramı ve sözde kodu sırasıyla Şekil 1-(a) ve (b)'de verildiği gibidir.

(a) Genetik algoritma akış diyagramı

(b) Genetik algoritma sözde kod

Şekil 1. Genetik Algoritmanın İşleyiş Mekanizması

Genetik algoritmalarda en temel problemler kodlama ve amaç fonksiyonlarının belirlenmesidir. Bu problemler, kullanıcıları en çok zorlayan ve problemin optimal çözümünün bulunması etkileyen ana faktörlerdir. Kodlama aşamasında literatürde çeşitli teknikler bulunmaktadır. Bu kodlama çeşitlerine ikilik kodlama, permütasyon kodlama gibi çeşitli örnekler verilebilmektedir. Probleme göre literatürdeki kodlama çeşitlerinden herhangi bir tanesi seçilebilmektedir. Bu çalışma kapsamında tasarlanan genetik algortmada permütasyon kodlama yöntemi tercih edilmiştir. Gerek kullanım kolaylığı gerekse portföylerin ifade edilmesiyle daha esnek bir kullanım sunan permütasyon kodlama tekniği ile problemin çözümü elde edilmiştir. Diğer bir temel problem olan amaç fonksiyonu ise problemden probleme değişen ve kullanıcıların hedefledikleri optimal çözümü sağlayacak olan faktördür (Tang ve diğerleri, 1996; Deb

ve diğerleri, 2002). Bu çalışmada kullanılan amaç fonksiyonu gelecek alt bölümlerde detaylı bir şekilde verilmektedir.

3.1. Kodlama işlemi

Genetik algoritma ile optimizasyon işlemlerinde kontrol parametrelerinin seçimi oldukça önemlidir (Grefenstette, 1986). Bölüm başında da belirtildiği üzere gerçekleştirilen bu çalışmada tasarlanan genetik algoritma için permütasyon kodlama tekniği kullanılmıştır. Permütasyon kodlama tekniği kullanılarak problemde yer alan menkul kıymetler ifade edilmiş ve problemin çözümünde kullanılmıştır. Bu çalışmada toplam 28 menkul kıymetten oluşan bir havuz oluşturulmuştur. Başlangıç çözüm kümesinde bu menkul kıymetlerin ağırlıkları rasgele belirlenmiştir. Bu ağırlıklar daha sonra kullanılmak üzere uygunluk fonksiyonuna gönderilmektedir.

28 menkul kıymet için rastgele başlangıç değerleri üretilerek popülasyon boyutunca kromozomlar oluşturulmaktadır. Daha sonra bu kromozomların her birinin kümülatif değeri hesaplanarak kromozomlardaki menkul kıymetlerin ağırlıkları belirlenmektedir. Bu işlemi bir kromozom için gösteren blok diyagram Şekil 2-(a) ve (b)'de verildiği gibidir. Şekil 2'den de görülebileceği üzere başlangıçta 28 menkul kıymet için [0,50] arasında rastgele değerler belirlenmiştir. Bu işlemin ardından belirlenen bu değerlere göre kümülatif değerler hesaplanmış ve kromozomdaki menkul kıymetlerin portföy içerisindeki ağırlıkları belirlenmiştir. Son olarak bu ağırlık değerleri problemin çözümünde kullanılmak üzere amaç fonksiyonuna gönderilmektedir.

Menkul Kıymetler	10	19	7	45	28	49	36	20	6	37	20	19	31	12
	46	6	5	47	38	0	9	47	39	17	10	22	45	0

(a) Rastgele üretilen menkul kıymet değerleri

Kümülatif Toplam	0,015	0,028	0,010	0,067	0,042	0,073	0,054	0,030	0,009	0,055	0,030	0,028	0,047	0,018
	0,069	0,009	0,007	0,070	0,057	0,002	0,013	0,070	0,059	0,030	0,015	0,033	0,067	0,002

(b) Üretilen değerlerin kümülatif değerleri

Şekil 2. Kodlama İşlemi

3.2. Amaç fonksiyonu

Gerçekleştirilen çalışmada kullanılan amaç fonksiyonu temel olarak risk ve getiri arasındaki ilişkiye dayanmaktadır. Başlangıç popülasyon sayısına göre üretilen kromozomlar bilindiği üzere farklı çözümler kümesini oluşturmaktadır. Daha sonra amaç fonksiyonu sayesinde bu çözümler giderek amaç fonksiyonunda belirlenen optimal sonuca doğru ilerlemektedir. Önerilen yaklaşımda kullanılan temel amaç fonksiyonu aşağıdaki denklemde verildiği şekildedir (Keskintürk 2007, 82).

$$amaç_{fonksiyonu} = [(1 - \lambda) \times getiri] - [\lambda \times risk]$$

Bu denklemde lambda değeri kullanıcı tanımlı olup, hedeflenen portföydeki getiri ve riskin yüzde cinsinden değerini ifade etmektedir. Bu şekilde bir katsayı

kullanılarak kullanıcının ne oranda getiri elde etmek istediği ve bu getirinin karşılığında ne oranda riske katlanmak istediği sorusunun cevabı aranmaktadır. Buradaki temel amaç en yüksek getiri ve en düşük riski sağlayacak optimal seçimi belirlemek olacaktır.

3.3. Seçim, çaprazlama ve mutasyon

Genetik algoritmanın diğer aşamaları sırasıyla seçim, çaprazlama ve mutasyon adımlarından oluşmaktadır. Önerilen yaklaşımda çaprazlanacak ve mutasyona uğrayacak bireylerin ilk olarak seçilmesi gerekmektedir. Literatürde elitizm, rulet tekerleği, kümülatif toplam gibi çok çeşitli seçim teknikleri bulunmaktadır. Fakat bu çalışmada gerek kullanım kolaylığı gerekse işlem yükü azlığından ötürü seçim işleminde elitizm yaklaşımı uygulanmıştır. Elitizm yaklaşımında çaprazlanacak bireylerin seçiminde en iyi uygunluk değerine sahip bireylerden bir seçim işlemi yapılmaktadır. Bu işlemdeki temel amaç en iyi uygunluğa sahip bireyleri seçerek, seçilmiş bu bireyleri ebeveyn kabul etmek ve bu ebeveyn bireylerden yeni çocuk bireyler elde etmektir. Bu sayede çaprazlama sonucu meydana gelecek yeni çocuklarda ebeveynlere ait özellikleri taşıyacak ve iyi uygunluğa sahip bireyler olacaklardır.

Algoritma süresince gerçekleştirilen bir diğer işlem ise çaprazlamadır (Patnaik ve Srinivas, 1994). Çaprazlama işleminde ebeveyn bireyler kullanılarak çocuk bireyler oluşturulmaktadır. Bu bölümde de belirtildiği üzere seçme işleminde elitizm yaklaşımı kullanılmaktadır. Bu işlem sayesinde en iyi uygunluğa sahip bireyler seçilerek çaprazlama işlemine tabi tutulmakta ve yeni çocuk bireyler elde edilmektedir. Çaprazlama işlemine örnek oluşturan bir durum ebeveyn ve oluşan yeni çocuk bireyler için Şekil 3’de verildiği gibidir.

Ebeveyn 1	10	19	7	45	28	49	36	20	6	37	20	19	31	12
	46	6	5	47	38	0	9	47	39	17	10	22	45	0
Ebeveyn 2	5	12	3	26	50	16	8	15	2	30	20	48	21	12
	9	13	23	47	24	44	34	16	39	28	11	32	19	8

(a) Popülasyondan seçilen menkul kıymet değerleri

Çocuk 1	10	19	7	45	28	49	36	20	6	37	20	19	31	12
	9	13	23	47	24	44	34	16	39	28	11	32	19	8
Çocuk 2	5	12	3	26	50	16	8	15	2	30	20	48	21	12
	46	6	5	47	38	0	9	47	39	17	10	22	45	0

(b) Çaprazlama sonucu menkul kıymet değerleri

Şekil 3. Çaprazlama İşlemi

Genetik algoritma işleminde çaprazlama işleminden sonraki adım mutasyon sürecidir. Mutasyon işlemi ile çocuk bireyler mutasyona uğratarak hem mevcut uygunluğunu kaybetmeden hem de daha yeni bireyler elde edilebilmesi açısından belirli işlemlere tabi tutulurlar. Mutasyon işlemi temel olarak belirli koşullara bağlı kalmak şartıyla genlerde yapılan ufak değişikliklerdir. Önerilen bu yaklaşımda kullanılan mutasyon işlemi denklemde verilen matematiksel ifadeye göre başlatılmaktadır.

$$Mutasyon_{oran} = e^{-p(Cocuk_{uyg}/\max(Cocuk_{uyg}))}$$

Buradan görülebileceği üzere mutasyon oranı belirli bir matematiksel ifadeye dayalı olarak yapılmaktadır. Bu sayede mevcut en iyi uygunluğa sahip bireylerin kaybolması durumu ortadan kaldırılmaktadır. Mutasyon işlemi genel olarak seçilen bir genin değiştirilmesi sürecidir. Bu süreçte rastgele belirlenen bir gen yine matematiksel bir ifadeye dayanarak değişikliğe uğratılır. Önerilen yöntemde ise rastgele bir sayı üretilmektedir. Eğer üretilen bu sayı “0” olarak çıkarsa belirlenen genin değeri “1” arttırılmaktadır. Tam tersi durumda ise genin değeri “1” azaltılmaktadır. Bu şekilde belirli iterasyon boyunca bu adımlar tekrarlanmakta ve oldukça geniş olan problem uzayından optimal bir çözüm yolu bulunmaktadır.

3.4. Sonlandırma işlemi

Çalışma sürecinde gerçekleştirilen genetik algoritmanın sonlandırma işlemi belirli iterasyon sayısına ulaşma koşulunu taşımaktadır. Bu iterasyon sayısı yapılan çalışmalar sonucunda “4000” adım olarak belirlenmiştir. Algoritmanın iterasyonu bu sayıya ulaştığında işlemler sonlandırılmakta ve nihai sonuç elde edilmektedir. Sistem uygunluk değerlerinin değişimi ile maksimum uygunluğu sağlayan portföy seçimini çıkış olarak vermektedir. Kromozomun nihai uygunluk değeri önerilen yaklaşımın sonucunu oluşturmaktadır.

4. Veri ve simülasyon sonuçları

Çalışmanın kapsamındaki Ocak-2010 Haziran-2013 dönemine ait 42 aylık veri Borsa İstanbul’un resmi internet sitesinden elde edilmiştir. Analizler sırasında Matlab 9.0 programı kullanılmıştır. Bununla birlikte, çalışmadan elde edilen sonuçlar sunulurken incelenen firmaların isimleri gizlilik açısından okuyucuya sunulmamış olup, bunun yerine firmalar 1’den 28’e kadar numaralandırılmıştır. Bununla birlikte literatürde hem aylık hem günlük verilerin kullanıldığı çeşitli çalışmalar görülmektedir. Bu çalışmada aylık verilerin kullanılmasının sebebi, günlük verilerde volatilitenin daha yüksek olması sebebiyle doğru sonuçlar elde etme aşamasında yaşanabilecek olası problemlerin önüne geçmektir. Zira, spekülörler ve manipölörler haricindeki yatırımcılar için önemli olan uzun vadede sağlayacağı kalıcı kazançtır ve bunun da aylık veriler ile analiz edilmesi daha doğru olacaktır. Ayrıca BIST-30 endeksi 30 adet hisse senedinden oluşmasına rağmen, firmalardan 2 tanesi ele alınan veri aralığının tamamında değil de 2012 içerisinde endekse dahil olduğu için analiz dışında bırakılmıştır.

Gerçekleştirilen çalışmada portföy seçimi için genetik algoritma yöntemi kullanılmıştır. Bu çalışma ile en iyi getiriye sahip menkul kıymetlerin belirlenen risk değerine göre oluşturabileceği en iyi çözüm saptanmıştır. Bu amaçla bir amaç fonksiyonu belirlenmiş ve bu fonksiyona göre sistem çalıştırılmıştır. Önerilen yaklaşımda tasarlanan genetik algoritmanın özellikleri Tablo-1’de verildiği gibidir. Ayrıca çalışmada önerilen yöntemi özetleyen bir akış diyagramı Şekil-4’de verildiği gibidir.

Tablo 1. Genetik Algoritmanın Uygulama Parametreleri

Parametreler	Değerler
Popülasyon Boyutu	50
İterasyon Adımı	4000
Çaprazlama Oranı	%100
Mutasyon Oranı	%25
Girişler	Kovaryans, Getiri, Katsayı, Popülasyon
Çıktılar	Uygunluk Değişimi, Getiri, Risk, Optimum Portföy Seçimi

Şekil 4. Önerilen Yaklaşım

Önerilen yaklaşım üretilen rastgele popülasyonu, kovaryans matrisini, getiri değerlerini ve belirlenen λ değerini giriş parametresi olarak almaktadır. Bu giriş parametrelerini kullanarak uygunluk değerinin değişimini ve oluşan portföy durumunu çıkış olarak vermektedir. Amaç fonksiyonuna bağlı olarak değişen uygunluk fonksiyonunda hedef; söz konusu denklemde verilen matematiksel ifadenin maksimize edilmesidir. Çalışmadan elde edilen kovaryans matrisi 28x28 boyutlarına sahiptir. Çalışmada belirlenen λ değerleri ise [0,1] aralığında 5 parçaya bölünmüştür ve tasarlanan genetik algoritma bu 5 parça için de ayrı ayrı çalıştırılmaktadır.

Önerilen yaklaşım sonucu elde edilen uygunluk değerlerinin $\lambda=[0,1]$ aralığındaki değerleri için iterasyon adımına bağlı olarak değişim durumlarını gösteren grafikler Şekil 5’de verilmektedir. Ayrıca bu değerlere bağlı olarak ortaya çıkan başlangıç ve sonuç uygunluk değerleri ile bu değerler arasındaki değişim miktarını yüzde cinsinden veren ifade Tablo-2’de sunulmuştur.

Tablo 2. Genetik Algoritma ile Uygunluk Değerleri Değişimi

Katsayılar	Başlangıç Uygunluk	Sonuç Uygunluk	Yüzde
$\lambda=0.0$	0.0137	0.0343	150.3
$\lambda=0.2$	0.1053	0.1091	3.61
$\lambda=0.4$	0.1970	0.1996	1.32
$\lambda=0.6$	0.2904	0.2924	0.69
$\lambda=0.8$	0.3832	0.3860	0.73
$\lambda=1.0$	0.4764	0.4798	0.71

Şekil 5. Lambda [0,1] Aralığı İçin Uygunluk Fonksiyonunun Değişimi

Tablo 2’den de görülebileceği üzere genetik algoritmanın uygunluk fonksiyonu üzerindeki etkisi sürekli pozitif yönde olmuştur. Genel ortalama olarak incelendiğinde algoritmanın yüzdesel bazda değişimi yaklaşık %26’dır. En büyük değişim oranı ise $\lambda=0.0$ değeri için başka bir deyişle getirinin maksimum, riskin ise minimum olarak seçildiği noktada yaşanmıştır. Bu noktada yaklaşık 1.5 kat gelişim gösterilmiştir. Ayrıca

λ değerinin yükselmesine ters olarak yüzdesel değişim miktarı azalma göstermektedir. Bu λ değerleri sonucu elde edilen portföy dağılımları ise Tablo-3’de verildiği gibidir.

Tablo 3. Genetik Algoritma ile Elde Edilen Optimal Portföy Dağılımı

Menkul Kıymet No	Portföy İçerisindeki Yüzdesel Oranı					
	$\lambda=0.0$	$\lambda=0.2$	$\lambda=0.4$	$\lambda=0.6$	$\lambda=0.8$	$\lambda=1.0$
1	-	-	2.349	3.026	3.361	3.567
2	-	8.461	5.580	4.423	3.841	3.444
3	-	-	2.055	2.910	3.361	3.690
4	-	-	2.496	3.143	3.481	3.690
5	-	-	1.615	2.561	3.001	3.321
6	-	-	-	1.979	3.001	3.690
7	-	9.487	6.020	4.773	4.081	3.690
8	-	3.333	3.671	3.608	3.481	3.444
9	-	5.384	4.405	3.958	3.601	3.444
10	-	-	2.202	2.910	3.241	3.444
11	-	6.410	4.845	4.074	3.721	3.444
12	-	-	1.174	2.444	3.121	3.444
13	-	0.769	2.936	3.376	3.601	3.690
14	-	8.974	5.873	4.540	3.961	3.567
15	-	1.795	3.083	3.376	3.481	3.567
16	-	-	1.468	2.677	3.361	3.813
17	-	4.615	4.258	3.841	3.721	3.567
18	-	4.615	4.258	3.841	3.601	3.567
19	-	6.666	4.992	4.307	3.961	3.690
20	-	-	2.643	3.259	3.601	3.690
21	-	4.872	4.258	3.841	3.601	3.444
22	-	1.795	3.230	3.376	3.481	3.567
23	-	8.461	5.580	4.307	3.721	3.444
24	-	4.102	4.111	3.958	3.841	3.813
25	-	4.615	4.258	3.841	3.721	3.567
26	100	12.82	7.342	5.471	4.441	3.813
27	-	2.82	3.377	3.492	3.481	3.444
28	-	-	1.909	2.677	3.121	3.444

Tablo 3’deki bulgulara göre, risk katsayısı (lambda) (λ) 0 iken optimal portföyün tek bir hisseden oluşması gerektiği görülmektedir. Risk katsayısı 0.20 olduğu durumda portföyü oluşturacak uygun hisse senedi sayısı 18 olarak tespit edilmiştir. Lambdanın 0.4’e yükseldiği durumda hisse senedi sayısı 27’ye yükselmiştir. Daha yüksek risk katsayısı olduğu durumlarda ise optimal portföy seçimi için BİST-30 indeksinin tamamından oluşturulmuş bir portföyün gerekliliği ortaya çıkmaktadır. Bu durum aslında risk katsayısı arttıkça algoritmanın performansının düştüğüne işaret etmektedir. Ayrıca tespit edilen bu portföylere ilişkin hisse senetlerinin portföy içerisinde belirlenen optimal ağırlıkları Tablo 3’de görülmektedir. Buna göre lambda değeri 0.2 iken portföy içerisindeki ağırlıkları % 8’in üzerinde olan 2, 7, 14, 23 ve 26 numaralı hisseler, oluşturulacak optimal portföyün yarısını temsil etmektedir.

Şekil-5 ve Tablo-2’den de görülebileceği üzere genetik algoritma tabanlı algoritma işlemi ile önemli ölçüde değişimler yaşanmış ve bu sonuçlar portföy getirisi ile riski üzerine doğrudan yansımıştır. Yine bu değişimlere bağlı olarak meydana gelen getiri ve risk eğrisindeki değişimler Şekil-6’daki etkin sınırlar yardımıyla sunulmaktadır. Ayrıca getiri ve risk değerlerinin başlangıç ve sonuç durumları ile bu değerlerin değişimini gösteren bir durum Tablo-4’de verilmiştir.

Tablo 4. Genetik Algoritma ile Uygunluk Değerleri Değişimi

Katsayılar	Getiri Değerleri			Risk Değerleri		
	Başlangıç	Sonuç	Yüzde	Başlangıç	Sonuç	Yüzde
$\lambda=0.0$	0.0111	0.0343	209	-0.4752	-0.0192	96
$\lambda=0.2$	0.0069	0.0209	202	-0.4758	-0.4618	2.95
$\lambda=0.4$	0.0111	0.0154	38.7	-0.4778	-0.4715	1.32
$\lambda=0.6$	0.0093	0.0125	34.4	-0.4791	-0.4735	1.17
$\lambda=0.8$	0.0085	0.0110	29.4	-0.4797	-0.4745	1.08
$\lambda=1.0$	0.0087	0.0105	20.7	-0.4798	-0.4720	1.63

Şekil 6 ve Tablo 4’den de görülebileceği üzere $\lambda=0.0$ değeri için yani getirinin maksimum, riskin ise sıfır olduğu nokta için değişim miktarı neredeyse 2 kat olmuştur ve pozitif yönde eğilim göstermiştir. Bu getiri değerleri riski ifade eden λ değerlerinin artışına bağlı olarak giderek düşüş göstermektedir. Fakat önceki bölümlerde verilen denklemler göz önüne alındığında ve tamamıyla riskli bir yatırım portföyü seçildiğinde bile yapılan tercihler sonucu yaklaşık %21 oranında getiri sağlanabilmektedir. Bu durum ise önerilen yaklaşımın performansını ve etkinliğini tam bir şekilde ortaya koymaktadır.

Şekil 6. [0,1] Aralığı için Farklı Lambda Değerlerinde Etkin Sınır Eğrileri

Sonuç ve Tartışma

Çalışma kapsamında gerçekleştirilen genetik algoritma tabanlı portföy seçimi işlemi elde edilen sonuçlardan da gözlenebileceği üzere özellikle lamda değerinin 0.2 olduğu durumda oldukça etkili ve verimli bir şekilde sonuç vermektedir. Önerilen yaklaşım sayesinde getiri ve risk değerlerinin ne oranda tercih edileceği kullanıcıya bırakılmış olup, yapılan simülasyon çalışmalarında 6 farklı katsayı değeri için bu algoritmanın performansı değerlendirilmiştir. Ayrıca tablolardan da görülebileceği üzere sürekli olarak bir pozitif yönlü bir getiri değeri elde edilebilmektedir. Sistem maksimum getiri ve minimum risk durumunda yaklaşık %210 performans artışı sağlarken, maksimum risk ve minimum getiri dengesinde ise yaklaşık %20 oranında performans sağlamaktadır. Bu amaçlar doğrultusunda ileride yapılacak çalışmalar aşağıda verilen amaçları içermektedir:

- Önerilen yöntemin yapay sinir ağları, DNA hesaplama algoritması gibi farklı optimizasyon yöntemleriyle incelenmesi,
- Veri boyutunun büyütülerek sistemin genel eğiliminin daha detaylı bir şekilde incelenmesi,

Öte yandan çalışmamızdan elde edilen sonuçlar BİST-30 indeksini inceleyen Demirtaş ve Güngör'ün (2004) bulguları ile de örtüşmektedir. Demirtaş ve Güngör (2004) seçilecek optimal hisse senedinin 19 olduğunu belirtirken, bu çalışmada ise lamda değerinin 0.2 olduğu durumda optimal hisse adedinin 18 olarak seçilmesi gerektiği tespit edilmiştir.

Kaynakça

- Abay, R. (2013). “Markowitz Karesel Programlama ile Portföy Seçimi: İMKB 30 Endeksinde Riskli Portföylerin Seçimi”, Çukurova Üniversitesi, Sosyal Bilimler Enstitüsü Dergisi, yıl: 22, sayı: 2, s. 175-194
- Baygin M. ve Karakose M. (2013). “Immunity-Based Optimal Estimation Approach for a New Real Time Group Elevator Dynamic Control Application for Energy and Time Saving” The Scientific World Journal, vol. 2013, pp. 1-12.
- Borsa İstanbul Resmi Web Sitesi
- Deb K., Pratap A., Agarwal S. ve Meyarivan T. (2002). “A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II” IEEE Transactions on Evolutionary Computation, vol. 6, no. 2, pp. 182-197.
- Demirtaş, Ö. ve Güngör, Z. (2004). “Portföy Yönetimi ve Portföy Seçimine Yönelik Uygulama”, Havacılık ve Uzay Teknolojileri Dergisi, yıl: 1, sayı: 4, s. 103-109.
- Grefenstette J. J. (1986). “Optimization of Control Parameters for Genetic Algorithms” IEEE Transactions on Systems, Man and Cybernetics, vol. 16, no. 1, pp. 122-128.
- Goldberg D. E. (1989). “Genetic Algorithms in Search Optimization and Machine Learning” Addison Wesley Publishing Company, USA.
- Gökçe, G. A. ve Cura, T. (2003). “İMKB Hisse Senedi Piyasalarında İyi Çeşitlendirilmiş Portföy Büyüklüğünün Araştırılması”, Yönetim, yıl: 14, sayı: 44, Şubat, s. 63-81
- Karakose M., Murat K., Akin E. ve Parlak K. S. (2014). “A New Efficient Reconfiguration Approach Based on Genetic Algorithm in PV Systems” International Symposium on Industrial Electronics, 1-4 June 2014, Bogazici University, Istanbul, pp. 23-28.
- Keskintürk, T. (2007). “İyi Çeşitlendirilmiş Portföy Büyüklüğünün Genetik Algoritma Tekniği Kullanılarak İncelenmesi”, Yönetim, yıl: 18, sayı: 56, s. 78-90
- Keskintürk, T., Demirci, E. ve Tolun, S. (2010). “İyi Çeşitlendirilmiş Portföy Büyüklüğünün Genetik Algoritma Tekniği Kullanılarak İncelenmesi”, Sosyal Bilimler Dergisi, 2, s. 1-5
- Korkmaz, T., Aydın, N. ve Sayılğan, G. (2013). “Portföy Yönetimi”, Açıköğretim Fakültesi, Yayını, 1. Baskı
- Lai, K. K., Yu, L., Wang, S. ve Zhou, C. (2006) “A Double-Stage Genetic Optimization Algorithm for Portfolio Selection”, Lecture Notes in Computer Science vol: 42, no: 34, pp. 928-937
- Lin, C. C. ve Liu, Y. T. (2008). “Genetic Algorithms for Portfolio Selection Problems with Minimum Transaction Lots” European Journal of Operational Research, no: 185, pp. 393-404

- Markowitz H. (1952). “Portfolio Selection”, The Journal of Finance, vol: 7, no: 1, pp. 77-91.
- Oh, K. J., Kim, T. J., Min, S. H., Lee, H. Y. (2006). “Portfolio Algorithm Based on Portfolio Beta using Genetic Algorithm”, Expert Systems with Applications, vol: no: 30, pp. 527–534
- Özdemir, M. (2011). “Genetik Algoritma Kullanarak Portföy Seçimi”, İktisat İşletme ve Finans, yıl: 26, sayı: 299, s. 43-66
- Patnaik L. M. ve Srinivas M. (1994). “Adaptive Probabilities of Crossover and Mutation in Genetic Algorithms” IEEE Transactions on Systems, Man and Cybernetics, vol. 24, no. 4, pp. 656-667.
- Reeves C. R. (1995). “Modern Heuristic Techniques for Combinatorial Problems” McGraw-Hill Book Company Inc., Europe.
- Saraç, M. (2012). “Finansal Yönetim”, Sakarya Kitabevi, Sakarya, 1. Baskı
- Shang Z. ve Liu H. (2010). “The Research on Portfolio Optimization Model and Strategy for Multiple Objectives” 2010 IEEE 2nd Symposium on Web Society, 16-17 August, Beijing, pp. 291-295.
- Skolpadungket P., Dahal K. ve Harnpornchai N. (2007). “Portfolio Optimization Using Multi-Objective Genetic Algorithms” IEEE Congress on Evolutionary Computation, 25-28 Sept. 2007, Singapore, pp. 516-523
- Tang K.S., Man K. F., Kwong S. ve He Q. (1996). “Genetic Algorithms and Their Applications”, IEEE Signal Processing Magazine, vol. 13, no. 6, pp. 22-37.
- Wang, S. M., Chen, J. C., Wee, H. M., ve Wang, K. J. (2006). “Non-linear Stochastic Optimization Using Genetic Algorithm for Portfolio Selection”, International Journal of Operations Research, vol: 3, no: 1, pp. 16-22

Optimal Portfolio Selection with Genetic Algorithm: An Example of BIST-30

Feyyaz ZEREN

Namık Kemal University,
Faculty of Economics and Administrative
Sciences, Department of Business
Administration, Tekirdağ, Turkey
fzeren@nku.edu.tr

Mehmet BAYĞIN

Fırat University,
Faculty of Engineering,
Department of Computer Engineering,
Elazığ, Turkey
mbaygin@firat.edu.tr

Extensive Summary

Genetic algorithms, which aims to find optimal results in very large solution space for a given problem is an optimization technique. In other words, it is a soft computing techniques used in solving problems that quite time-consuming and called as NP-hard problems. Genetic algorithms are used actively in the solution of many problems in the literature. In this paper, the optimal portfolio selection process is performed by using genetic algorithms. The user is enabled to select the most suitable portfolio combination according to the risk level with the proposed approach.

The most fundamental problems of genetic algorithms is to determine coding and the goal functions. These problems are the main factors the most challenging users and influencing the presence of an optimal solution. Any one of the coding variants in the literature can be chosen according to the problem. The permutation coding method is preferred in designed genetic algorithm under this paper. The solution of the problem is obtained with this coding method because it offers ease of use. Another major problem is the objective function. This function varies from problem to problem and provides the optimal solution for the users.

One of the main problem is an optimal portfolio selection in the financial investment decisions. In this context, the determining of optimal portfolio by using which method is a significant for researcher. On the other hand, genetic algorithm is optimization technical to select optimal portfolio when there are the plurality of cluster solutions. Moreover, there are main basic elements while investment decision is taken by investors. These elements are risk and return. According to modern portfolio theory the most significant subject is correlation between securities. Portfolio risk can be decreased by bringing together high negative correlation assets in this theory, instead of the increasing randomly a number of securities in conventional portfolio theory.

An object function that contains the values of return and risk is created in this proposed approach and the relationship between risk and return is tried to be maximized by using a coefficient value. A portfolio pools consisting of 28 different securities is formed in this study. Genetic algorithm steps that coding, fitness value, selection, crossover and mutation operations were applied to the data on this portfolio to find the

optimal solution, respectively. The designed genetic algorithm under this paper is taken covariance matrix, return values and coefficient values obtained from portfolios as the input parameters. The optimal portfolio distribution and the change of affinity values are obtained from the proposed method as the output parameters. In this study, the coefficient values used in the objective function is user-defined and it is $[0,1]$ in the range. Six different coefficient values was used to examine the performance of the algorithm and the optimal result was obtained with the 0.2 coefficient value. This coefficient values indicate fundamentally impact on the objective function of the return and risk factors. In other words, the selection of 0.2 coefficient value is applied to the objective function value of 80% return and 20% risk values. The difference between gaining values and risk values is dawned to the maximum point by the used of objective function. Algorithm is terminated when this difference is maximum and portfolio combination is outputted just as this value obtained. The most important reason for preferring genetic algorithm under this study, this optimization technique is to produce fast and effective results. An improvement of about 26% is provided for all coefficients in the objective function with the proposed genetic algorithm-based portfolio selection approach.

When Lambda value (λ) is 0.20, optimal portfolio selection is consist of 18 shares According to the application findings which is used data spanned from January-2010 and June-2013. When a dominance of risk factor increases, performance of algorithm decreases and optimal portfolio selection is consist of all BIST-30 Indices. In addition, when examining the results of the algorithm will be seen that the proposed method provides a fast and effective results significantly in the selection of the portfolio.