

T.C.
ANKARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI

**GENETİK ALGORİTMALARLA
PORTFÖY OPTİMİZASYONU**

Yüksek Lisans Tezi

Hayrettin Genel

Ankara – 2004

T.C.
ANKARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI

**GENETİK ALGORİTMALARLA
PORTFÖY OPTİMİZASYONU**

Yüksek Lisans Tezi

Hayrettin Genel

Tez Danışmanı
Doç. Dr. Yalçın Karatepe

Ankara -2004

T.C.
ANKARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI

GENETİK ALGORİTMALARLA PORTFÖY OPTİMİZASYONU

Yüksek Lisans Tezi

Tez Danışmanı : Doç. Dr. Yalçın Karatepe

Tez Jürisi Üyeleri

Adı ve Soyadı

İmzası

Doç. Dr. Yalçın Karatepe

.....

Doç. Dr. Onur Özsoy

.....

Doç. Dr. A. Argun Karacabey

.....

Tez Sınavı Tarihi: 27 Mayıs 2004

İÇİNDEKİLER

İÇİNDEKİLER	i
ŞEKİLLER	vi
TABLolar	viii
GİRİŞ	1
BİRİNCİ BÖLÜM	5
MODERN PORTFÖY TEORİSİ VE PORTFÖY OPTİMİZASYONU	5
1.1. Yatırımın Risk ve Getirisi	6
1.1.1. Risk Nedir ?	6
1.1.2. Risk Çeşitleri.....	6
1.1.2.1. Sistematik Olmayan Risk Unsurları.....	7
1.1.2.2. Sistematik Risk Unsurları	8
1.1.3. Riskin Ölçülmesi.....	9
1.1.4. Risk ve Beklenen Getiri İlişkisi	9
1.1.5. Çeşitlendirme ile Riskin Azaltılması	12
1.2. Modern Portföy Teorisi	14
1.2.1. Markowitz (Ortalama - Varyans) Modeli	15

1.2.2. Markowitz Modeline Göre Optimal Portföyler ve Etkin Sınır	17
1.2.3. Markowitz Modeline Kısıtların Eklenmesi	19
1.3. MPT'ye göre Portföy Optimizasyon Süreci.....	21
İKİNCİ BÖLÜM	23
GENETİK ALGORİTMALAR VE KULLANIM ALANLARI	23
2.1. Genetik Algoritmalar	24
2.2. Genetik Algoritmaların Çalışması.....	25
2.2.1. Gösterim (Kodlama)	26
2.2.2. Başlangıç Populasyonunun Oluşturulması.....	26
2.2.3. Uygunluk Fonksiyonu.....	27
2.2.4. Genetik İşlemler	28
2.2.4.1. Seçim.....	28
2.2.4.2. Çaprazlama.....	29
2.2.4.3. Mutasyon.....	30
2.2.5. Yeni Bireylerin Değerlendirilerek Yeni Neslin Oluşturulması.....	31
2.2.6. Bitiş	32
2.3. Genetik Algoritmaların Özellikleri	32
2.3.1. Genetik Algoritmaların Avantajları	33
2.3.2. Genetik Algoritmaların Dezavantajları	35

2.4. Genetik Algoritmaların Finans Uygulamaları	36
ÜÇÜNCÜ BÖLÜM	37
GENETİK ALGORİTMALAR İLE PORTFÖY OPTİMİZASYONU: İMKB'DE BİR UYGULAMA.....	37
3.1. Genetik Algoritmalarla Portföy Optimizasyonu.....	37
3.1.1. Optimizasyon Yöntemleri	37
3.1.2. Portföy Optimizasyon Problemi.....	39
3.1.3. Genetik Algoritmaların Kullanılma Sebepleri	42
3.2. Geliştirilen Uygulama: Yöntemler ve Varsayımlar	43
3.2.1. Uygulama Geliştirme Ortamı.....	43
3.2.2. Veri Seçimi	43
3.2.3. Uygulama Adımları.....	44
3.2.3.1. Veri Analizi.....	44
3.2.3.2. Optimal Portföyün Oluşturulması.....	45
3.2.3.3. Elde Edilen Sonuçların Değerlendirilmesi.....	46
3.3 Standart Markowitz Modeline Göre Portföy Optimizasyonu	47
3.4. Standart Markowitz Modeline Göre Genetik Algoritma Portföy Optimizasyonu.....	47
3.4.1. Çözümlerin Kodlanması.....	47
3.4.2. Başlangıç Populasyonunun Oluşturulması.....	48

3.4.3. Yeni Nesil İçin Aday Bireylerin Oluşturulması (Genetik İşlemler)	49
3.4.3.1. Seçim ve Çaprazlama	49
3.4.3.2. Mutasyon.....	51
3.4.4. Yeni Nesle Aktarılabacak Bireylerin Seçilmesi	52
3.5. Kısıtlı (Genişletilmiş) Markowitz Modeline Göre Genetik Algoritma Portföy Optimizasyonu.....	53
3.5.1. Çözümlerin Kodlanması.....	54
3.5.2. Başlangıç Populasyonunun Oluşturulması.....	55
3.5.3. Yeni Nesil İçin Aday Bireylerin Oluşturulması (Genetik İşlemler)	56
3.5.3.1. Seçim ve Çaprazlama	56
3.5.3.2. Mutasyon.....	57
3.5.4. Yeni Nesle Aktarılabacak Bireylerin Seçilmesi	60
3.6. Portföy Optimizasyon Sonuçları.....	60
3.6.1. Standart Markowitz Modeline Göre Portföy Optimizasyonu	61
3.6.1.1. Genetik Algoritma İçin Kullanılan Parametreler	61
3.6.1.2. Genetik Algoritmanın Çalışmasının Test Edilmesi	61
3.6.1.3. Etkin Sınır	61
3.6.1.4. Elde Edilen Optimal Portföylerin 2. 6 Aylık Dönemdeki Getirisi.....	63
3.6.2. Kısıtlı Markowitz Modeline Göre Portföy Optimizasyonu	64
3.6.2.1. Genetik Algoritma İçin Kullanılan Parametreler	64

3.6.2.2. Genetik Algoritmanın Çalışmasının Test Edilmesi	65
3.6.2.3. Etkin Sınır	65
3.6.2.4. Elde Edilen Optimal Portföylerin 2. 6 Aylık Dönemdeki Getirisi.....	67
SONUÇLAR VE DEĞERLENDİRMELER	68
KAYNAKÇA	70
ÖZET	74
ABSTRACT	75

ŞEKİLLER

<i>Şekil 1.1 – Risk Getiri Değişimi (Piyasa Doğrusu)</i>	<i>10</i>
<i>Şekil 1.2 – Yatırımcı Farksızlık Eğrileri</i>	<i>11</i>
<i>Şekil 1.3 – Çeşitlendirme ile Riskin Azaltılması</i>	<i>13</i>
<i>Şekil 1.4 – İki Menkul Kıymetli Portföyün Korelasyon Katsayısına Göre Riski.....</i>	<i>17</i>
<i>Şekil 1.5 – Etkin Sınır Grafiği.....</i>	<i>18</i>
<i>Şekil 1.6 – (i) 3 Menkul Kıymetten İkisi ile Oluşturulabilecek Portföylerin Etkin Sınırları (ii) Tüm Portföyler için Etkin Sınır</i>	<i>21</i>
<i>Şekil 1.7 – Modern Portföy Teorisine Göre Yatırım Süreci.....</i>	<i>22</i>
<i>Şekil 3.1 – Genetik Algoritmada Portföylerin Gösterimi (Genetik Kod).....</i>	<i>48</i>
<i>Şekil 3.2 – Genetik Algoritma Çaprazlama İşlemi.....</i>	<i>50</i>
<i>Şekil 3.3 – Genetik Algoritma Mutasyon İşlemi.....</i>	<i>51</i>
<i>Şekil 3.4 – Kısıtlı Portföy Optimizasyonu Modelinde Portföylerin Gösterimi</i>	<i>54</i>
<i>Şekil 3.5 – Kısıtlı Portföy Optimizasyonu Modelinde Çaprazlama İşlemi</i>	<i>57</i>

<i>Şekil 3.6 - Kısıtlı Portföy Optimizasyon Modelinde Portföydeki En Düşük Ağırlığa Sahip Hisse Senedinin Portföy Dışı Bir Hisse Senedi ile Yer Değiştirmesi.....</i>	<i>58</i>
<i>Şekil 3.7 – Kısıtlı Portföy Optimizasyon Modelinde Portföye Dahil Hisseler Arası Mutasyon İşlemi.....</i>	<i>59</i>
<i>Şekil 3.8 – Standart Modele Göre Elde Edilmiş Etkin Sınır.....</i>	<i>62</i>
<i>Şekil 3.9 –Etkin Portföylerin 2. Dönem Getirisi.....</i>	<i>63</i>
<i>Şekil 3.10 – Kısıtlı Modele Göre Elde Edilmiş Etkin Sınır.....</i>	<i>66</i>
<i>Şekil 3.11 –Etkin Portföylerin 2. Dönem Getirisi.....</i>	<i>67</i>

TABLolar

<i>Tablo 2.1 – Genetik Algoritmaların Çalışma Adımları</i>	<i>25</i>
<i>Tablo 3.1 – İMKB-30 Hisse Senetlerinin 03.06.2002 - 31.12.2002 Tarihleri Arasındaki 6 Aylık Getirileri.....</i>	<i>44</i>
<i>Tablo 3.2 – İMKB-30 Hisse Senetlerinin 02.01.2003 - 30.06.2003 Tarihleri Arasındaki 6 Aylık Getirileri.....</i>	<i>46</i>
<i>Tablo 3.3 – Test İçin Kullanılan Örnek Portföy Kısıtları</i>	<i>64</i>

GİRİŞ

Finansal piyasalarda yatırım kararlarının iki temel boyutunu getiri ve risk oluşturmaktadır.¹ Yatırım gelecekte belli bir getiri elde etme beklentisiyle yapılır. Ancak, finansal piyasalarda fiyatlar çok sayıda ölçülebilen ve ölçülemeyen ekonomik, politik ve sosyal değişkenin etkileşimi ile oluştuğundan, finansal varlıkların fiyatlarını doğru bir şekilde önceden tahmin etmek mümkün değildir. Dolayısıyla, finansal piyasalarda yatırım kararları önemli ölçüde belirsizlik içermekte ve yatırımlardan beklenen getiri açısından önemli bir risk söz konusu olmaktadır.

Finansal piyasalardaki bu kaçınılması güç belirsizlik ve risk, yatırımcıların aldıkları finansal kararların başarısını doğrudan etkilemektedir. Bu nedenle finansal piyasalarda yatırım yaparken doğru kararlar alabilmenin çok zor bir iş olduğu açıktır, aksi takdirde herkes kolaylıkla zengin olabilirdi. Bu nedenle finans biliminde en önemli konulardan birisi, belki de en önemlisi, hangi yatırım kararlarının doğru olduğunun belirlenmesi ve yatırım kararlarının sonuçlarının öngörülebilmesidir.

Finansal kararların sonuçlarının ne denli farklı olabileceğine çarpıcı bir örnek aşağıda verilmiştir.² Eğer bir yatırımcı, Ocak 1926 yılında, en az riskli yatırım araçlarından biri olarak, bir aylık ABD Hazinesi bonosuna 1 dolar yatırmış olsaydı

¹ Karan, Mehmet Baha, *Yatırım Analizi ve Portföy Yönetimi*, Gazi Kitabevi, Ankara, 2001, s. 131

²Farmer J. D., Lo, A. W., *Frontiers of Finance : Evolution and Efficient Markets*, Proc. Natl. Acad. Sci. USA, Vol. 96, August 1999, s. 9991

ve 1996 yılı Aralık ayına kadar her ay sonundaki mevcut parayı tekrar yatırmaya devam etseydi 1 dolarlık yatırımı bu süre sonunda 14 dolara çıkmış olacaktı. Bunun yerine çok daha riskli bir yatırım aracı olarak bu 1 dolar S&P 500'e yatırılmış olsaydı, aynı 71 yıllık süreçte getiri çok daha fazla bir değer olan 1370 dolar olacaktı.

Şimdi bu yatırımcının, her ay başında bir sonraki ayda bu iki yatırım aracından hangisinin daha çok getirisi olacağını tahmin edebileceğini ve başlangıçtaki 1 dolarlık yatırımı her ay getirisi yüksek olan yatırıma yatırdığını varsayalım. Böyle bir mükemmel öngörü durumunda başlangıçta yapılmış olan 1 dolarlık yatırım acaba Aralık 1996'da ne kadara ulaşır? Sonuç oldukça çarpıcıdır: Tam tamına 2,296,183,456 dolar!.

Finansal piyasalarda böyle mükemmel öngörülerde bulunma ve doğru kararlar alma imkanı olmaması gerçeğine rağmen, bu örnek, yatırım kararlarının sonucu ne kadar değiştirebileceğini açıkça göstermektedir. Tabi yukarıda verilen örneğin tersini, yani getiri yerine yatırımın kısmen ya da tamamen değerini kaybedebileceği örnekler vermek de mümkündür. Bu nedenle yatırım kararlarının belirlenmesi sadece sezgisel olarak yapılamaz ve gelişmiş ve güvenilir hesaplama tekniklerinin kullanılması gerekir.

Modern ekonominin en önemli özelliği ekonomik aktivitenin geleneksel endüstri sektöründen hizmet sektörüne kaymış olmasıdır. Hizmet sektöründe de son yıllarda özellikle de finansal hizmetler gelişme kaydetmiştir.

Enformasyon ve iletişim teknolojilerindeki gelişmeler bu dönüşümde çok önemli bir rol oynamıştır. Gelişen bilişim teknolojileri finansal kaynaklara erişimi ve bilgi paylaşımını kolaylaştırmıştır. Ayrıca, son yıllarda karmaşık finansal ürünlere olan olağanüstü talep artışı, bu ürünlerin analizi ve kullanılması için yeni tekniklerin gelişmesine yol açmıştır. Bunun sonucu olarak da, bilişim teknolojileri ekonomik ve finansal sistemlerde modelleme, analiz ve karar verme süreçlerinin önemli bir parçası haline gelmiştir.

Bundan yirmi yıl önce, finansal mühendislik, finansal matematik ve hesaba dayalı finans teknikleri yaygın olarak bilinen terimler değildi. Ancak, günümüzde

bütün bu alanlar her birinin kendi dergi, konferans ve profesyonel örgütlerinin var olduğu popüler akademik disiplinler haline gelmişlerdir.³ Bu disiplinler, mühendislik ve matematik gibi alanlarda yaygın olarak kullanılmakta olan yöntemleri finans alanındaki problemlere uygulamaktadırlar. Hızla gelişmekte olan bilişim teknolojileri de bu tür uygulamalara ivme kazandırmış ve bu disiplinler için itici bir güç olmuştur.

Günümüzün bilişim teknolojilerinin varmış olduğu nokta ve yaygın kullanımı ise uzman sistemler, bulanık mantık, yapay sinir ağları ve genetik algoritmalar gibi yeni nesil akıllı hesaplama sistemlerinin gelişmesine imkan sağlamıştır. Bilgisayar mühendisliği biliminin bir alanı olarak bu tür akıllı hesaplama yöntemleri insanların karar verme sürecini modellemeye çalışmaktadır. Bu yöntemler esnek olup yeni durumlara adapte olabilmekte ve geçmiş tecrübelerden öğrenebilmektedirler. En önemlisi de bu yöntemler, klasik yöntemlerle çözülemeyen problemlere çözüm üretebilmektedirler.⁴

Bu yöntemlerin finans alanında uygulanmasıyla beraber dinamik finansal sistemlerin modellenmesi ve kontrolünde kullanılması, finansal süreç ve davranışların karmaşık modellerini anlamamızı kolaylaştırmıştır. Finans alanında en küçük gelişmelerin dahi çok önemli kazanımlara dönüştürülebileceği gerçeği bu yöntemlerin değerini ortaya koymaktadır.

Genetik algoritmalar, bahsedilen akıllı hesaplama teknikleri arasında basit ve güçlü olmalarıyla ön plana çıkmaktadırlar. Genetik algoritmaların artan şekilde çeşitli finansal problemlere uygulanması sonucu oldukça ümit verici sonuçlar elde edilmiş ve genetik algoritmalar, diğer akıllı hesaplama yöntemleriyle beraber,

³ Haugh, Martin B., Lo, Andrew W., *Computational Challenges in Portfolio Management*, IEEE Computing in Science & Engineering, Vol. 3, No.3, 2001, s. 54

⁴ Drake, Adrian E., Marks, Robert E., *Genetic algorithms in economics and finance: Forecasting stock market prices and foreign exchange- A review*, In Shu-Heng Chen (Ed.) *Genetic Algorithms and Genetic Programming in Computational Finance*, 2000, s. 29

geleneksel istatistiksel yöntemlerin geliştirilmesine veya bu yöntemlerin yerine geçmeye aday olmuştur.⁵

Bu yönüyle, gelecek vadeden bir araştırma alanı olarak, finansal piyasalara artık biyolojik bir çerçeveden bakılmaya başlanmıştır:⁶ Piyasalar, araçlar, kurumlar ve yatırımcılar bir “ekonomik seçim kuramına” (law of economic selection) göre etkileşmekte ve dinamik olarak gelişmektedirler. Bu bakış açısına göre finansal aktörler optimum davranmasalar da rekabet etmekte ve oluşan koşullara adapte olmaktadır.

Bu tezin amacı, portföy optimizasyon probleminin ve genetik algoritmaların incelenerek, genetik algoritmaların portföy seçimi problemine uygulanabilirliğinin araştırılması ve test edilmesidir.

1. bölümde Modern Portföy Teorisi, 2. bölümde ise genetik algoritmalar anlatılacaktır. 3. bölümde ise önceki iki bölümde anlatılmış teorik altyapı doğrultusunda genetik algoritmaların portföy seçiminde kullanılması ele alınacak ve İMKB verileri kullanılarak yapılmış olan örnek bir uygulama çalışması anlatılacaktır. Son bölümde ise yapılan çalışma ile ilgili sonuçlar ve değerlendirmeler özetlenecektir.

⁵ Feldman, Konrad and Treleven, Philip, *Intelligent systems in finance*, Applied Mathematical Finance, Vol 1, No. 2, December, 1994, s. 195

⁶ Farmer J. D., Lo, A. W., a.g.e., s. 9991

BİRİNCİ BÖLÜM

MODERN PORTFÖY TEORİSİ VE PORTFÖY OPTİMİZASYONU

20. yüzyılın başlarında gelişmeye başlayan yatırım bilimi başlangıçta menkul kıymetlerin bireysel olarak ele alınarak incelenmesi ve seçilmesine odaklanmıştı. 1950'lerin ortalarında Markowitz tarafından temelleri atılan Modern Portföy Teorisi (MPT) ise yatırım bilimine yeni bir bakış açısı getirmiştir. Yatırım kararları alınırken, menkul kıymetleri tek tek ele almak yerine piyasayı bir bütün olarak ele alan MPT, yatırımcılar için sistematik bir yaklaşım ortaya koymuştur. Modern portföy teorisi rasyonel bir yatırımcının portföydeki varlıkların oranlarını portföyün beklenen getirisini maksimize ederken riskini en aza indirecek şekilde seçtiği varsayımına dayanır.

Günümüzde yatırım portföylerinin oluşturulması ve portföydeki varlıkların belirlenmesi en önemli yatırım kararları olarak kabul edilmektedir. Portföy yönetimi, uzun dönemli yatırım amaçlarına ulaşabilmek için, yatırımcının getiri beklentisi ve risk tercihi ile planlanan yatırım süresi doğrultusunda mevcut fonların menkul kıymetlere en uygun şekilde dağıtılmasını ve oluşturulan portföyün gelişen koşullar doğrultusunda güncellenmesini amaçlamaktadır. Dolayısıyla, yatırımcılar riski ve getiriye nasıl ölçeceklerini ve beklenti ve tutumlarına en uygun yatırım kombinasyonlarını nasıl seçeceklerini bilmek zorundadırlar.

1.1. Yatırımın Risk ve Getirisi

1.1.1. Risk Nedir ?

Yatırım yaparken, araba sürerken veya sokakta yürürken herkes risk altındadır. Finansal açıdan risk, bir yatırımdan elde edilen getirinin, beklenen getiriden farklı olması olarak tanımlanmaktadır. Yatırım yapmanın amacı kazanç elde etmektir. Ancak yatırımın sonucu gelecekte ortaya çıkacağından, elde edilen sonuç beklenenden farklı olabilir, çünkü, yatırımın değerini pek çok faktör etkileyebilmektedir. Riskli bir yatırım sonucunda kişi yatırımının bir kısmını ya da tamamını kaybedebilir.

Kişinin ne kadar risk üstlenmeyi kabul edeceği, o kişinin özellikleri ve hayat tarzına bağlıdır. Risk toleransı yatırımcının rahat bir şekilde üstlenmeyi kabul edeceği risk seviyesini gösterir. Eğer borsada yatırım yapmışsanız ve geceleri uyumakta zorluk çekiyorsanız, muhtemelen kabul edebileceğinizden fazla risk üstlenmişsiniz demektir.

Hisse senetlerine, bonolara veya farklı yatırım araçlarına yatırım yapıldığında aslında zannedilenden daha fazla risk söz konusudur. İyi bir yatırımcının göz önünde bulundurması ve hesaba katması gereken çok çeşitli riskler mevcuttur. Risk çeşitleri aşağıda daha detaylı şekilde verilmiştir.

1.1.2. Risk Çeşitleri

Risk, yatırımcının riski kontrol edebilme ve sınırlandırma olanağına göre iki temel kategoride ele alınmaktadır:⁷

- 1. Sistemik Olmayan Risk (Firma Riski)**
- 2. Sistemik Risk (Pazar Riski)**

⁷ Özçam, Mustafa, Varlık Fiyatlama Modelleri Aracılığıyla Dinamik Portföy Yönetimi, SPK, Yayın No: 104, Ekim 1997, Ankara, s. 9-11

Sistemik olmayan risk, menkul kıymetin veya ilgili firmanın kendine has özelliklerinden kaynaklanmaktadır. Bu tür riskler firmanın yönetim özellikleri, tüketici tercihleri, iklim koşulları gibi unsurlardan ortaya çıkar. Grev, yangın veya başka bir tabii afetin meydana gelmesi, satışların düşmesi gibi durumlar bu tür risklere örnektir. Bu tür risklerin tüm firmalar için aynı anda ortaya çıkması olası değildir. Dolayısıyla, sistemik olmayan risk, çeşitlendirme ile ortadan kaldırılabılır. Bu nedenle, rasyonel ve bilgilendirilmiş bir yatırımcı için bu tür bir risk önemli değildir.

Öte yandan, bazı durum ve olaylar tüm firmaları aynı anda etkileyebilir. Bu şekilde, menkul kıymete veya ilgili firmaya dışsal olan unsurlardan kaynaklanan riskler sistemik riski oluştururlar. Sistemik riskin temel kaynakları ekonomik, politik ve sosyal gelişmelerdir. Enflasyon, savaş ve değişen faiz oranları gibi olaylar sadece belli bir firma veya endüstriyi değil, tüm ekonomiyi etkileyecektir. Dolayısıyla, bu tür risklerden çeşitlendirme ile kaçınmak mümkün değildir. Ancak, her menkul kıymetin veya ilgili firmanın sistemik risk unsurları ile etkileşimi aynı olmayacağından sonuçta oluşan risk ağırlığı farklı olacaktır.

Bir menkul kıymetin riski sistemik ve sistemik olmayan risklerin toplamıdır. Sistemik ve sistemik olmayan risk unsurları da kendi içinde alt bölümlere ayrılabilir.

1.1.2.1. Sistemik Olmayan Risk Unsurları

1. İş Riski: Bir firmanın faaliyet gelirleri üretim fonksiyonu ve satış hacmine bağlı olarak gerçekleşir. Ancak, firmanın muhtemel gelirlerinin zaman içindeki dağılımı, firmanın çalıştığı alandan kaynaklanan belirsizlikler içerebilir. Firmanın gelir akımındaki bu belirsizlik firmanın durumunu, dolayısıyla da ilgili menkul kıymet fiyatlarını olumsuz etkileyecektir.

2. Finansal Risk: Firmalar öz kaynakla finansman yanında borçlanma ile finansman yoluna da gidebilir. Böyle bir durumda, borçlu firma yeterli gelir elde edemezse borçların anapara ve faizlerini ödeyemeyebilir. Bu durum, hem hisse senedi sahipleri, hem de borç verenler için bir risk unsurudur.

3. *Likidite Riski*: Likidite bir yatırım aracının fazla maliyete katlanılmadan piyasada her an, kolaylıkla alınıp satılabilmesi demektir. Eđer söz konusu bir yatırım için piyasa likit deęil ise yatırımcı yatırımını satıp elde etmek istedięi fonları elde edemeyebilir ya da elde etme süresi uzayabilir.

4. *Yönetim Riski*: Firmaların önlerine çıkan fırsatları deęerlendirebilmeleri güçlü bir yönetim kadrosunun varlığı ile mümkündür. Eđer yönetim kadrosu firma için oluşan fırsatları deęerlendirebilecek beceriye sahip deęil ve firma kötü yönetiliyorsa, bu durum firmayı olumsuz etkileyecek, dolayısıyla da beklenen getirilerde önemli azalmalar olacaktır. Gelişmiş borsalarda işlem gören hisse senetlerinin ait olduęu firmalardaki yönetici deęişikliklerinin birçok durumda hisse senetlerinin fiyatlarını da etkilemesi bu riskin varlığını göstermektedir.

1.1.2.2. Sistematik Risk Unsurları

1. *Piyasa Riski*: Menkul kıymet fiyatları ilgili firmanın durumundan bağımsız olarak kısa dönemde dalgalanabilmektedir. Bu dalgalanmaların temel sebebi yatırımcıların menkul kıymetlerle ilgili beklenti ve davranışlarındaki deęişimlerdir. Beklenti ve davranışlardaki bu deęişimler bazı somut unsurlardan kaynaklanabileceęi gibi tamamen psikolojik unsurlardan da kaynaklanabilir.

2. *Faiz Oranı Riski*: Faiz oranlarındaki deęişmeler menkul kıymet fiyatlarını pek çok yönden etkileyebilir. Her menkul kıymet için etkisi farklı oranlarda olmakla birlikte, faiz oranları düştüğünde genelde tüm menkul kıymetlerin fiyatları yükselmekte, yükseldiğinde ise düşmektedir.

3. *Enflasyon Riski*: Enflasyon satın alma gücünü azaltacağından yatırımcının gelecekte elde edeceęi mal ve hizmetlerin reel tutarını, dolayısıyla da cari menkul kıymet fiyatlarını etkileyecektir.

1.1.3. Riskin Ölçülmesi

Risk anlaşılması, tanımlanması ve ölçülmesi zor bir kavramdır. Genelde riski ölçmek için bir yatırımın beklenen getirilerinin olasılık dağılımı, yani gerçekleşen getirinin beklenen getiriden farklılaşma miktarı kullanılır. Olasılık dağılımının ölçülmesinde ise varyans ve varyansın karekökü olan standart sapma kullanılır.

$$\sigma = \sqrt{\sum_{i=1}^n (R_i - R)^2 \cdot P_i} \quad (1.1)$$

σ : Standart Sapma

n : Menkul kıymetin farklı getirileri

R : Menkul Kıymetin ortalama getirisi

R_i : Menkul kıymetin i.nci getirisi

P_i : i.nci getirinin gerçekleşme olasılığı

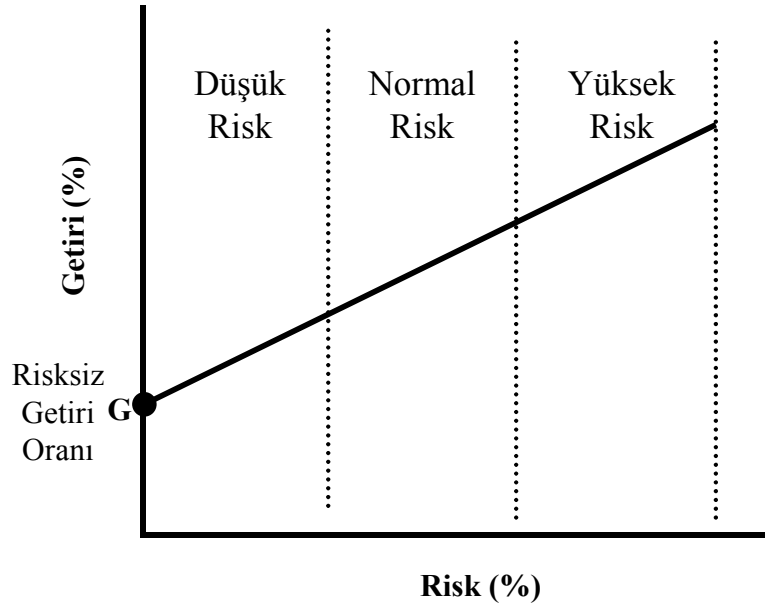
Standart sapma küçüldükçe olasılık dağılımı, dolayısıyla da risk azalır; standart sapma büyüdüğü de beklenen getirinin riski de artar.

Riskin ölçülmesi için çoğunlukla varyans veya standart sapma kullanılmakla birlikte başka ölçü birimleri de kullanılabilir.

1.1.4. Risk ve Beklenen Getiri İlişkisi

Risksiz bir yatırımda beklenen getirinin elde edilmesi konusunda bir güvence söz konusudur. Yatırımcılar riskli yatırım araçlarına yatırım yaptıklarında ise beklenen getirinin elde edilememesi ya da yatırımın kaybedilmesi olasıdır. Beklenen getirideki belirsizlik, yani yatırımın riski arttıkça, yatırımcıların talep edecekleri getiri oranı da artacaktır. Yatırımcılar daha fazla risk üstlenmeyi ancak daha yüksek getiri beklentisi ile kabul edecektir. Risk ve getiri arasında bu genel ilişkiyi gösteren piyasa doğrusu aşağıdaki şekilde gösterilmiştir. (Şekil 1.1).⁸

⁸ Özçam, Mustafa, a.g.e, s. 13

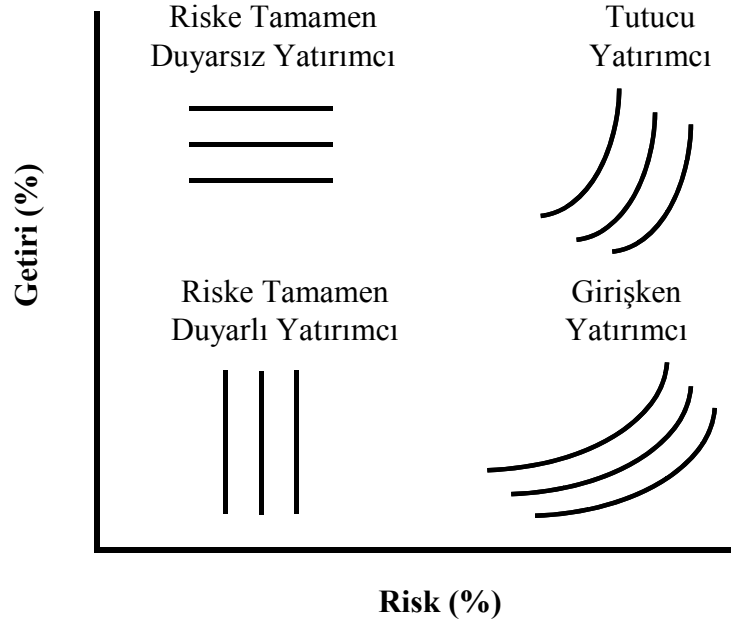


Şekil 1.1 – Risk Getiri Değişimi (Piyasa Doğrusu)

Şekilde G noktası risksiz getiri oranını, piyasa doğrusunun eğimi ise risk birimi başına talep edilen ek getiriye göstermektedir. Bu doğru, risk ile getiri arasındaki genel ilişkiyi açıklamaktadır. Ancak, tüm yatırımcıların riske karşı duyarlılığı aynı değildir. Bazı kişiler için kazandıkları paranın değeri yüksek olduğu için riske kaçınma eğilimindedir. Diğer yanda ise bir kısım insanlar daha yüksek getiri beklentisiyle risk almaktan hoşlanırlar.

Yatırımcıların risk ve getiri tercihleri arasındaki ilişki farklılık (kayıtsızlık) eğrileri ile gösterilmektedir. (Şekil 1.2).⁹ Farklılık eğrileri bir yatırımcı için farklı beklenen getiri ve riske sahip olmakla birlikte aynı düzeyde fayda sağlayan yatırımları birleştiren eğrilerdir. Bu eğriler yatırımcıların aldıkları risk karşısındaki getiri beklentilerini göstermektedir. Grafikte ikisi uç durumları temsil etmek üzere, risk-getiri değişimi karşısında dört yatırımcı tipi gösterilmektedir.

⁹ Özçam, Mustafa, a.g.e, s. 14



Şekil 1.2 – Yatırımcı Farksızlık Eğrileri

Riske Tamamen Duyarlı Yatırımcı: Bu tür bir yatırımcı, yatırım kararlarını sadece risk düzeyine göre belirlemektedir. Dolayısıyla da, belirli bir risk düzeyi, getiri ne olursa olsun aynı faydayı sağlamaktadır. Bu durum, getiri eksenine paralel farksızlık eğrisiyle gösterilmektedir.

Riske Tamamen Duyarsız Yatırımcı: Farksızlık eğrisi risk eksenine paralel olan böyle bir yatırımcı için yatırım kararları beklenen getiri düzeyine göre belirlenmektedir. Belirli bir getiri düzeyi, riskten bağımsız olarak, aynı faydayı sağladığı için, bu getirin hangi risk düzeyinde sağlandığı önemli değildir.

Riske tamamen duyarlı ya da tamamen getiriye odaklanmış (riske tamamen duyarsız) yatırımcı tipleri gerçekçi değildir. Gerçek hayatta yatırımcıların risk-getiri tercihleri bu iki uç noktanın arasında yer alır:

Tutucu Yatırımcı: Tutucu bir yatırımcı açısından yatırımın riski beklenen getirisine göre daha önemlidir. Bunun sonucu olarak, bu tip bir yatırımcı, küçük bir risk artışını ancak daha büyük bir getiri artışı karşılığında kabullenecektir.

Girişken Yatırımcı: Tutucu yatırımcının aksine olası bir getiri artışı için daha büyük miktarlarda risk üstlenme eğiliminde olan yatırımcı tipidir. Bu tür bir yatırımcı için elde edilecek getiri riskten daha önemlidir.

Gerçekçi olmayan uç yatırımcı tipleri dikkate alınmazsa, yatırımcıların aynı fayda düzeyini koruyabilmeleri için risk-getiri değişimi gerekli görülmektedir. Normal bir yatırımcı daha fazla bir riski ancak daha fazla bir getiri beklentisi ile kabul edecektir.

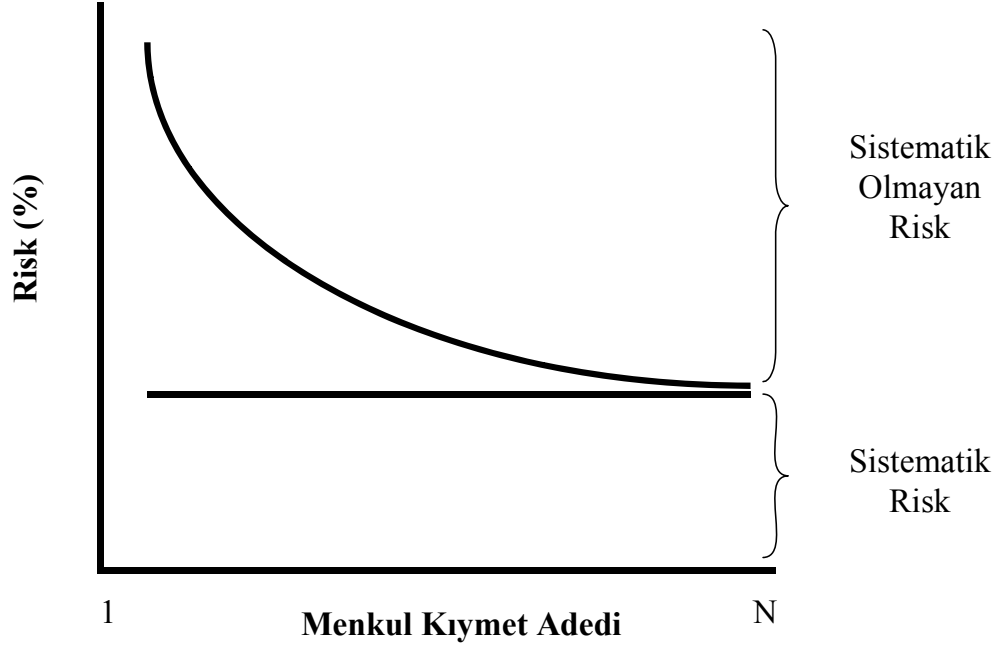
Ne kadar bir riski kabul edebileceği yatırımcı için önemli bir karardır. Herkesin risk kabul etme derecesi farklıdır ve kişinin risk toleransı sabit olmayıp yaşam boyunca değişme eğilimindedir. Genellikle kişiler yaşlandıkça emeklilik gibi zorunluluklar nedeniyle doğal olarak daha az risk üstlenme eğiliminde olurlar.

Elde edilmek istenen getiri ve bu getiri için kabul edilebilecek riski belirlemek için yatırımcı mümkün olan en düşük risk beklentisi ile mümkün olan en yüksek getiri beklentilerini dengelemek durumundadır. Risk ve getiri arasındaki doğru dengeye ulaşmak yatırımcının finansal hedeflerine ulaşmasını sağlarken geceleri de rahat uyuyabilmesine olanak verecektir.

1.1.5. Çeşitlendirme ile Riskin Azaltılması

Belirsizlik ortamında sürekli dalgalanmakta olan finansal piyasalarda bireysel ve kurumsal yatırımcıların güvencesi çeşitlendirmedir. Çeşitlendirme, her ne kadar riski sıfırlayıp zarardan kurtulmayı garantilemese de, riski minimize etmek suretiyle uzun vadeli finansal hedeflere ulaşmada önemli bir araçtır.

Çeşitlendirmenin mantığı çoğu kez bütün yumurtaları aynı sepete koymamak olarak ifade edilmektedir. Çeşitlendirme ile yukarıda bahsedilen sistematik olmayan riski elimine etmek mümkündür. Bu durumda iyi çeşitlendirilmiş bir portföy sadece sistematik riskten kaynaklanan riske sahip olacaktır (Şekil 1.3). Dolayısıyla da yatırımcılar aslında sadece sistematik riski üstlenmeyi kabul edeceklerdir. Bu nedenle, finansal yatırım sürecinde mevcut yatırım araçlarından uygun bir portföy oluşturulmalıdır.



Şekil 1.3 – Çeşitlendirme ile Riskin Azaltılması

Portföy yönetiminde amaç, yatırımcının getiri beklentileri ve riske karşı tutumu doğrultusunda, portföye dahil edilecek varlıklar ve bu varlıkların oranlarına karar vermek ve gelişen koşullarla birlikte portföyü güncellemektir.¹⁰

Geleneksel portföy yönetiminde riskin birden fazla menkul kıymete dağıtılması amaçlanmıştır. Bu amaç doğrultusunda 10 farklı menkul kıymetten oluşturulmuş bir portföyün 2 menkul kıymet içeren bir portföye göre 5 kat daha az riskli olduğu kabul edilmiştir.

Geleneksel portföy yönetiminde iyi bir çeşitlendirme yapılabilmesi için portföye dahil edilecek menkul kıymetlerin farklı endüstrilerden seçilmesi öngörülmüştür. Ancak, portföye dahil edilen menkul kıymetlerin getirileri arasındaki ilişkiler ele alınmadan sadece portföydeki menkul kıymet sayısı artırılarak riskin azaltılabileceği kabul edilmiştir. Modern portföy teorisi ile beraber bu yaklaşım geçerliliğini yitirmiştir.

¹⁰ Ertuna, İ. Özer, Yatırım ve Portföy Analizi (Bilgisayar Uygulama Örnekleriyle), Boğaziçi Üniversitesi, 1991, s. 16

1.2. Modern Portföy Teorisi

Modern portföy teorisi (MPT), rasyonel bir yatırımcının, riskini minimize edip beklenen getirisini maksimize edecek şekilde portföyündeki varlıkların optimum oranlarını seçmesine dayanır. Günümüz piyasalarında, MPT arařtırmacılar ve portföy yöneticileri tarafından riskinin izlenmesi ve portföyün getirisinin deęerlendirilmesi amacıyla kullanılmaktadır.

Modern Portföy Teorisi; piyasada bilgilerin nasıl deęerlendirildięi, yatırımcıların nasıl davrandıęı, yatırımcıların davranıřlarının fiyat oluřumlarını nasıl etkiledięi ve bu iliřkilerin nasıl nicelleřtirilebileceęiyle uęrařan bir dizi teorik yapıya dayanır: ¹¹

a) Bütün yatırımcılar rasyonel düşünürler. Yatırımcılar, verilen her risk düzeyi için yüksek getirileri düşük getirilere ya da verilen her getiri düzeyi için düşük riski yüksek riske tercih ederler.

b) Yatırımcılar her yatırımı, belli bir elde tutma dönemi sonunda nihai refahlarına katkıda bulunacak, olasılık dağılımına sahip getirileriyle algırlarlar.

c) Yatırımcıların risk tahminleri beklenen getirideki deęiřmeyle orantılıdır.

d) Yatırımcılar, yatırım kararlarını yalnızca beklenen getiri ve riske göre alırlar.

e) Sermaye piyasası oldukça etkindir. Menkul kıymet fiyatlarını etkileyen bütün bilgiler süratle, tamamen ve doęru olarak menkul kıymet fiyatlarına yansıyacak ve herhangi bir anda piyasa dengede olacaktır.

¹¹ Karařın, A. Gültekin, Sermaye Piyasası Analizleri, SPK, Yayın No: 4, Ankara, 1986, s. 121

1.2.1. Markowitz (Ortalama - Varyans) Modeli

Yatırımın tarihçesini 1952'den öncesi ve sonrası olmak üzere iki bölüme ayırmak mümkündür. Bu tarihte Chicago Üniversitesi Ekonomi bölümünde doktora öğrencisi olan Harry Markowitz doktora tezi ile Modern Portföy Teorisinin temelini atmıştı. Markowitz'in o tarihte yayınlamış olduğu makale¹² o kadar önemli idi ki, Markowitz 1990 yılında araştırmaları ve günümüz yatırımcılarının yaklaşımlarına uzun soluklu etkileri nedeniyle Ekonomi dalında Nobel Ödülüne layık görüldü.

Modern Portföy Teorisi öncesinde de yatırımcılar riski tartışmışlardı, ancak onu ölçmek için herhangi bir araçları olmamıştı. MPT, ekonomistlerin ve yatırımcıların piyasayı bir bütün olarak anlamalarına ve yatırım fırsatlarını analiz etmelerine imkan sağlamıştır. Daha önce, portföy yönetiminde esas ağırlık bireysel varlık seçimi üzerindeyken, Markowitz'le beraber risk-getiri değişimi temelinde varlıkların birbirleriyle ilişkileri ortaya konarak portföyün tümünün değerlendirilmesine imkan sağlanmıştır.

Markowitz, portföydeki menkul kıymetler arasındaki korelasyonlar nedeniyle rasgele yapılacak bir çeşitlendirmeye riskten kaçınmanın mümkün olamayacağını belirtmiştir. Ancak, portföy riskinin, portföyü oluşturan varlıkların riskinden daha az olabileceğini ve sistematik olmayan riskin sınırlanabileceğini göstermiştir.

Markowitz modeline göre portföyün beklenen getirisi ve riski aşağıdaki şekilde hesaplanmaktadır.

$$B(G_p) = \sum_{i=1}^N B(G_i).a_i \quad (1.2.1)$$

$$\sigma_p^2 = \sum_{i=1}^N \sum_{j=1}^N Cov(i, j).a_i.a_j \quad (1.2.2)$$

¹² Markowitz, Harry M., Portfolio Selection, Journal of Finance, 7 (1), 1952, s. 77-91

N: Portföydeki menkul kıymet sayısı

$B(G_p)$: Portföyün beklenen getirisi

$B(G_i)$: i menkul kıymetinin beklenen getirisi

a_i : i menkul kıymetinin portföydeki ağırlığı

a_j : j menkul kıymetinin portföydeki ağırlığı

σ_p^2 : Portföyün varyansı

$Cov(i,j)$: i ve j menkul kıymetlerinin beklenen getirilerinin kovaryansı

Kovaryans, herhangi bir tesadüfi değişkenler grubunun birlikte hareket etme eğilimini, yani, iki tesadüfi değişken arasındaki sezgisel bağlantıyı ölçer. Herhangi iki menkul kıymetin kovaryansı menkul kıymetlerin tek tek standart sapmaları ile iki menkul kıymet arasındaki korelasyon katsayısı ile çarpılmasıyla elde edilebilir:


$$Cov(i, j) = \sigma_i \cdot \sigma_j \cdot \rho_{ij} \quad (1.3)$$

σ_i : i menkul kıymetinin standart sapması

ρ_{ij} : i ve j menkul kıymetlerinin getirileri arasındaki korelasyon

Korelasyon, iki değişkenin birlikte hareket etme eğilimini gösterir ve -1 ile $+1$ arasında ($-1 \leq \rho_{ij} \leq +1$) değer alır. Eğer korelasyon 0 'ı aşarsa iki değişken aynı yönde hareket etme eğilimindedir. Korelasyon katsayısının negatif olması ise iki değişkenin ters yönde hareket etme eğilimini gösterir. İki değişken arasındaki korelasyonun 0 olması ise bu değişkenlerin arasında herhangi bir ilişki olmadığını gösterir.

Buna göre, birden fazla menkul kıymetten oluşan bir portföyde menkul kıymetler arasındaki korelasyon katsayısı $+1$ 'den küçük olması durumunda, portföyün riski, portföydeki menkul kıymetlerin risklerinin ağırlıklı toplamından küçük olacaktır. Negatif korelasyon katsayılarının olmasının durumunda ise sıfır riske sahip bir portföy elde edebilmek mümkündür. İki menkul kıymetli bir portföyde korelasyon katsayısına göre riskin değişimi aşağıdaki şekilde verilmiştir: (Şekil 1.4)



Şekil 1.4 – İki Menkul Kıymetli Portföyün Korelasyon Katsayısına Göre Riski

1.2.2. Markowitz Modeline Göre Optimal Portföyler ve Etkin Sınır

Markowitz modelinde yatırımcının belli bir beklenen getiriyi elde edebilmek için kabul edeceği riski minimize etmeye çalıştığı kabul edilir. Beklenen getirinin $B(G_p)$ olarak kabul edildiği bir durumda, bu problem matematiksel olarak aşağıdaki gibi formüle edilebilir:

$$\min \sum_{i=1}^N \sum_{j=1}^N Cov(i, j) \cdot a_i \cdot a_j \quad (1.4.1)$$

$$(i) \quad B(G_p) = \sum_{i=1}^N B(G_i) \cdot a_i \quad (1.4.2)$$

$$(ii) \quad \sum_{i=1}^N a_i = 1 \quad (1.4.3)$$

$$(iii) \quad a_i \geq 0 \quad i=1, \dots, N \quad (1.4.4)$$

Yukarıdaki birinci kısıt elde edilecek getrinin beklenen getiriye eşit olmasını ifade eder. İkinci kısıt ise bütçe kısıtı olarak bilinir ve bütün menkul kıymetlerin


ağırlıklarının toplamının %100'e eşit olmasını gerektirir. Ağırlıkların 0'dan büyük olmasını belirten üçüncü kısıt ise açığa satış işlemlerinin olmadığını gösterir.

Bu modele göre, eğer bir portföye girmesi muhtemel bütün menkul kıymetlerin beklenen getirilerini, risklerini ve korelasyonlarını biliyor isek, bu bilgileri kullanarak herhangi bir portföyün beklenen getirisini ve riskini hesaplayabiliriz.

Hesaplanan bu portföyler içerisinde optimal olanlar ise iki şekilde tanımlanabilir:

1. Belli bir risk seviyesi için en yüksek getiriye sahip olan portföyler
2. Belli bir beklenen getiri için en düşük riske sahip portföyler

Bu iki tanım da birbirine eşittir ve aynı optimal portföy kümesini oluştururlar. Birinci tanım olası her risk seviyesi için, ikinci tanım ise olası her beklenen getiri oranı için optimal portföyleri oluşturur. Optimal portföyler risk getiri uzayında etkin sınırı oluşturur (Şekil 1.5).



Şekil 1.5 – Etkin Sınır Grafiği

Grafikte D-Y eğrisinin altında kalan taralı alan geçerli yatırım ortamında oluşturulabilecek portföylerin oluşturduğu risk-getiri uzayını göstermektedir. Bunun dışında kalan bölgede portföy oluşturmak olanaksızdır. Taralı alandaki her noktada ise, o noktaya karşılık gelen risk ve beklenen getiriye sahip en az bir portföy oluşturulabilir. Ulaşılabilir alanın üstünü çevreleyen D-Y eğrisi ise etkin sınırı oluşturur. Etkin sınır üzerindeki portföyler hem belli bir beklenen getiri için en düşük riske sahip olmaları, hem de belli bir risk için en yüksek beklenen getiriye sahip olmaları nedeniyle optimaldirler ve en iyi çeşitlendirilmiş portföylerdir.

Etkin sınır yatırımcılar için çok önemlidir. Bütün yatırımcılar en yüksek getiriyi elde ederken en az riski üstlenmek istedikleri için etkin sınır üzerinde yer alan bir portföye yatırım yapacaklardır. Çünkü etkin sınır üzerindeki bir portföy diğer tüm portföylere üstün olacaktır.

1.2.3. Markowitz Modeline Kısıtların Eklenmesi

Teorik olarak çok fazla ilgi çekmesine rağmen, standart Markowitz modeli gerçek dünyadaki portföy optimizasyon probleminin karmaşıklığını yeterince temsil etmez. Standart Markowitz modelinde sadece beklenen getiri ve bütçe kısıtları ile açığa satış imkanı olmaması kısıtları mevcuttur. Modeli zenginleştirmek ve daha gerçekçi uygulamalarda kullanabilmek için bazı kısıtların eklenmesi gereklidir. Modele eklenebilecek kısıtların bazıları aşağıda verilmiştir:

- En az ağırlık kısıtı (buy-in threshold): Oluşturulacak portföye dahil edilecek bir menkul kıymetin ağırlığının çok küçük olmamasını sağlamak için belirtilen portföye dahil edilen tüm menkul kıymetlerin ağırlıklarının en az değerini belirtir.
- Portföydeki maksimum farklı menkul kıymet adedi (cardinality constraint): Portföy yönetimini kolaylaştırmak amacıyla portföye en fazla belli bir adet menkul kıymetin dahil olabilmesi istenebilir.
- Portföydeki menkul kıymetler için en az ve en çok ağırlık kısıtları: Bu kısıta göre portföyde yer alacak menkul kıymetlerin ağırlıkları için alt ve üst sınır belirtilebilir.

Yukarıdaki kısıtların eklenmesiyle oluşturulan modelin matematiksel ifadesi aşağıda gösterilmiştir:

$$\min \sum_{i=1}^N \sum_{j=1}^N Cov(i, j) \cdot a_i \cdot a_j \quad (1.5.1)$$

$$(i) B(G_p) = \sum_{i=1}^N B(G_i) \cdot a_i \quad (1.5.2)$$

$$(ii) \sum_{i=1}^N a_i = 1 \quad (1.5.3)$$

$$(iii) a_i \geq 0 \quad i=1, \dots, N \quad (1.5.4)$$

$$(iv) z_i \in [0,1] \quad i=1, \dots, N \quad (1.5.5)$$

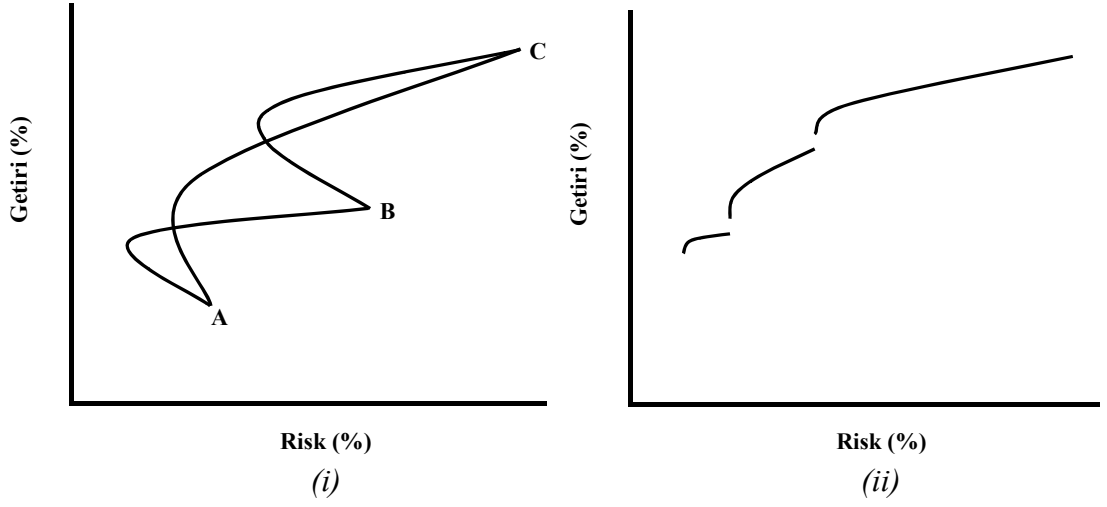
$$(v) \sum_{i=1}^N z_i = K \quad 1 \leq K \leq N \quad (1.5.6)$$

$$(vi) d_i \leq a_i \leq y_i \quad i=1, \dots, N \quad (1.5.7)$$

$$(vii) a_i \geq z_i \cdot m \quad i=1, \dots, N \quad (1.5.8)$$

Modeldeki ilk üç kısıt standart modeldekiyle aynıdır. Dördüncü kısıt ilgili menkul kıymetin portföye dahil olup olmadığını belirtmektedir. ($z_i = 0$ ise menkul kıymet portföye dahil değil, $z_i = 1$ ise menkul kıymet portföye dahildir). Beşinci kısıt portföye dahil olabilecek maksimum menkul kıymet adedini (K) belirtmektedir. Altıncı kısıt herhangi bir menkul kıymet için belirtilmiş olan en düşük (d_i) ve en yüksek (y_i) portföy ağırlıklarını göstermektedir. (Farklı değerler belirtilmediği durumlarda $d_i = 0$ ve $y_i = 1$ 'dir). Yedinci kısıt ise portföye dahil edilecek bir menkul kıymetin minimum ağırlığını (m) göstermektedir. Eğer söz konusu menkul kıymet portföye dahil ise en az ağırlığı m , dahil değilse ağırlığı 0 olacaktır.

Optimizasyon modeline bu kısıtların eklenmesi etkin sınırı doğal olarak değiştirecek ve oluşturulan etkin sınır kesikli yapıda olabilecektir. Kısıtların etkin sınırı nasıl etkilediğini açıklamak için üç menkul kıymet arasından iki tanesini seçerek oluşturulabilecek portföylerin etkin sınırları ve böyle bir kısıtla oluşabilecek tüm portföylerin etkin sınır grafiği aşağıdaki şekilde gösterilmiştir (Şekil 1.6):



Şekil 1.6 – (i) 3 Menkul Kıymetten İkisi ile Oluşturulabilecek Portföylerin Etkin Sınırları (ii) Tüm Portföyler için Etkin Sınır

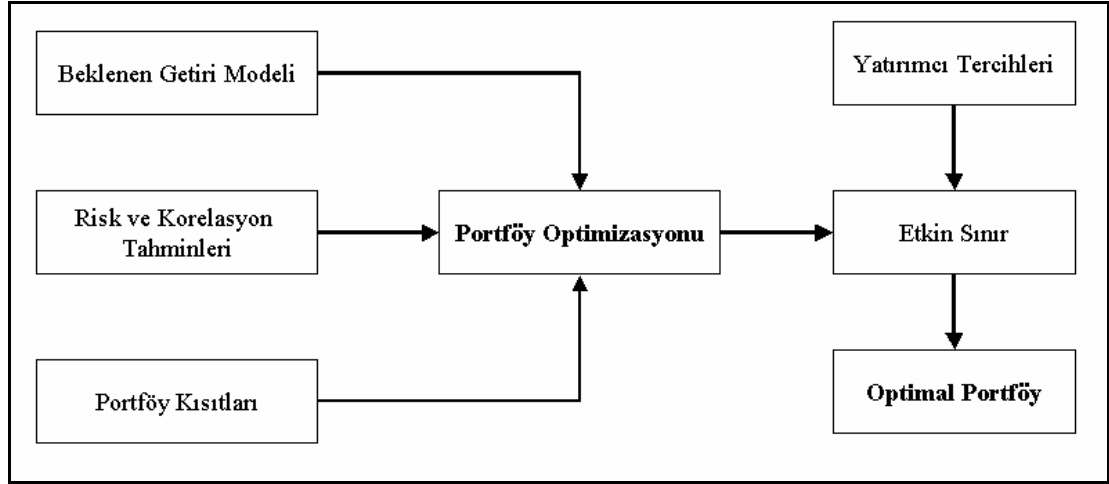
Sonuçta oluşan etkin sınır grafiğine bakıldığında, etkin sınır eğrisinin kesikli olduğu ve en yüksek ve en düşük beklenen getiri değerleri arasında yer alan bazı beklenen getiri değerleri için tanımlı olmadığı görülmektedir. Tanımsız olan bu beklenen getiri seviyelerinde aynı riske sahip daha yüksek beklenen getiri elde etmek mümkünken aynı getiriye sahip daha az riskli bir portföye ulaşmak mümkün değildir, dolayısıyla da bu noktalar doğal olarak etkin sınır üzerinde değildirler.

1.3. MPT'ye göre Portföy Optimizasyon Süreci

Modern Portföy Teorisi normatif bir teoridir.¹³ Pozitif teoriler gerçek yatırımcı davranışlarını ele alırken, normatif teoriler yatırımcıların nasıl davranması gerektiğini belirtir. Bu yönüyle, normatif bir teori olarak MPT optimum portföy oluşturmak amacıyla yatırımcının takip etmesi gereken standart veya normal davranışı açıklamaktadır.

¹³ Fabozzi, Frank J., Gupta, Francis, Markowitz, Harry M., The Legacy of Modern Portfolio Theory, The Journal of Investing, Volume 11, Number 3, Fall 2002, s. 7

MPT'ye göre yatırım süreci aşağıdaki şekilde gösterilmiştir (Şekil 1.7). Yatırımcı belirlediği beklenen getiri ve risk tahminleri ile portföy kısıtlarını kullanarak optimal portföylerden oluşan etkin sınırı oluşturduktan sonra yatırım tercihleri doğrultusunda yatırım yapacağı optimal portföyü seçer.



Şekil 1.7 – Modern Portföy Teorisine Göre Yatırım Süreci

MPT'de portföy optimizasyonu için gerekli girdileri oluşturan parametrelerin (beklenen getiri, risk) doğru tahmin edilmesinin önemi çok büyüktür. Bu parametrelerdeki - özellikle de beklenen getirideki - küçük değişimlerin optimal portföydeki menkul kıymet ağırlıkları üzerinde önemli etkileri olabilir.¹⁴ Portföy kısıtları ise oluşturulacak portföy ile ilgili yatırımcının özel tercihlerini yansıtmaktadır.

Optimizasyon işlemi için çeşitli araçlar ve yöntemler kullanılabilir. Yatırım için belirlenen amaç fonksiyonu, kullanılan optimizasyon modeline göre uygun şekilde kodlanır ve yukarıdaki girdiler kullanılarak etkin sınır elde edilir. Son olarak, yatırımcının risk ve getiri konusundaki tutumunu gösteren farksızlık eğrisinin etkin sınıra teğet olduğu noktadaki portföy, optimal portföy olarak seçilecektir.

¹⁴ Chopra V K, Ziemba WT, The effect of errors in means, variances and covariances on optimal portfolio choice, Journal of Portfolio Management, Vo.19, No. 2, Winter 1993, s. 6-11

İKİNCİ BÖLÜM

GENETİK ALGORİTMALAR VE KULLANIM ALANLARI

Bilişim teknolojilerindeki önemli gelişmelerle birlikte yapay zeka ve makine tabanlı öğrenme teknikleri son yıllarda yaygın olarak kullanılmaya başlamıştır. İnsanoğlunun idrak kapasitesinin sınırlı ve karar vermede tutarsız olması nedeniyle, artık bilgisayarlar, yatırım strateji ve tercihlerinin belirlenmesinde, portföy oluşturulması ve optimizasyonunda önemli bir yere sahiptirler. Bilgisayarlar kullanılarak, pek çok yatırım alternatifi, finansal senaryo veya portföy hızlı bir şekilde oluşturularak değerlendirilebilmekte ve optimize edilmektedir.

Finansal ortamın çarklarının hızlı döndüğü ve piyasaların dinamik bir şekilde değiştiği ve dönüştüğü günümüzde, finansal yatırım olanaklarının gerçek zamanlı olarak belirlenebilmesi ve alternatiflerin hızlı bir şekilde değerlendirilebilmesi için genetik algoritmalar önemli bir çözüm alternatifi sunmaktadır. Böyle durumlarda en iyiye yakın bir çözüme hızlı bir şekilde ulaşmak, en iyi sonuca çok uzun bir sürede ulaşabilmekten çok daha önemlidir.

Genetik algoritmalar, insanın karar alma yeteneğinin bilgisayarlar kullanılarak benzetilmesine dayanan bir tür yapay zeka tekniğidir. Genetik algoritmalar zor problemleri, bir başlangıç aday çözüm kümesinin tekrarlanan bir süreç kullanılarak evrilmesi yoluyla, çözüm uzayındaki daha iyi çözümlere ulaşmaya çalışarak çözmeye çalışırlar.

2.1. Genetik Algoritmalar

Bilim adamlarının evrimsel yaklaşımı bilgisayar teknolojilerinde kullanmaya çalışması oldukça eskiye dayanmaktadır. Bilgisayar teknolojileri ve evrim yaklaşımının birleştirilmesi için ilk denemeler 1950'lerin sonunda ve 1960'ların başında yapılmıştır. Ancak, ilk denemeler o günlerdeki biyolojik evrim yaklaşımına uygun olarak mutasyon işlemine çok fazla bağımlı olmaları nedeniyle çok fazla başarılı olmamıştır.¹⁵

1960'lı yılların ortalarında John Holland mutasyon işlemine eşleşme ve çaprazlama işlemlerini ekleyerek zor problemlerin doğal seçim prensibi doğrultusunda çözülebilmesine imkan sağlayacağına inandığı bir programlama yöntemi geliştirmiştir. Bu çalışmasıyla Holland genetik algoritmalar alanının kurucusu sayılmıştır. Daha sonra dünyada bu alanda çalışan pek çok araştırmacı Holland'ın orijinal yöntemine dayanan pek çok değişik yöntem geliştirmişler ve pek çok farklı alana uygulamışlardır.¹⁶

Günümüzde, evrimsel yaklaşımı temel alan bilgisayar tabanlı problem çözme ve optimizasyon tekniklerinin tümü evrimsel algoritmalar adı altında ele alınmaktadır. Evrim tabanlı yöntemler olarak, bireylerden oluşan bir popülasyonun belli bir dönüşümden geçirilmesi ve en iyi olan bireylerin varlıklarını devam ettirmesine dayanan başlıca evrimsel algoritma teknikleri, genetik algoritmalar, genetik programlama, evrim stratejileri, sınıflandırma sistemleri ve evrimsel programlama olarak sıralanabilir.¹⁷

¹⁵ Holland, J. H., *Genetic Algorithms*, Scientific American, 1992, s.44

¹⁶ Drake, a.g.e, s. 30

¹⁷ Beasley, David, AI FAQ/genetic, <http://www.faqs.org/faqs/ai-faq/genetic/part2/section-1.html>, (15.08.2003)

Yukarıda sıralanan evrimsel algoritma teknikleri içerisinde en yaygın ve kullanışlı olanı genetik algoritmalarıdır. Genetik algoritmalar karmaşık bir çözüm uzayı olan problemleri çözmek için evrimsel yaklaşımı kullanan rasgele aramaya dayalı buluşsal (heuristic) bir çözüm tekniğidir.

2.2. Genetik Algoritmaların Çalışması

Tipik bir genetik algoritma, genetik algoritmalara özel süreçleri içeren bazı adımlardan oluşur. Örnek bir genetik algoritmanın çalışma adımları aşağıdaki tabloda verilmiştir (Tablo 2.1).

Tablo 2.1 – Genetik Algoritmaların Çalışma Adımları

Adım	Yapılan İşlem
1	Gösterim (kodlama) yönteminin belirlenmesi
2	Başlangıç populasyonunun (ilk nesil) oluşturulması
3	Başlangıç populasyonundaki her bireyin performansının amaç fonksiyonuna göre hesaplanması
4	Yeni neslin oluşturulmasında kullanılacak bireylerin seçilmesi
5	Seçilmiş bireylere genetik işlemlerin uygulanarak yeni neslin elde edilmesi
6	Yeni neslin bireylerinin performanslarının uygunluk fonksiyonuna göre hesaplanması
7	Bitiş koşulu sağlanmamışsa 4. adıma dönülmesi
8	Bitiş koşulu sağlanmışsa en iyi bireyin sonuç olarak dönülmesi

Tabloda gösterilen genetik algoritma adımları genel olarak verilmiştir. Bu adımlar değişik problemler için değişik şekilde uygulanabilir. Ancak her durumda, bu adımlar genetik algoritmaların temel bileşenlerine dayanmaktadır.¹⁸ Bu temel

¹⁸ Michalewicz, Z., *Heuristic Methods for Evolutionary Computation Techniques*, Journal of Heuristics, Vol.1, No.2, 1995, s. 177

bileşenler yukarıdaki adımlar doğrultusunda aşağıdaki bölümlerde detaylı olarak ele alınacaktır.

2.2.1. Gösterim (Kodlama)

Genetik algoritmalar çözüme ulaşmak için problemlerin olası çözümlerinin gösterimlerini kullanırlar. Bu nedenle, herhangi bir (optimizasyon) problemin genetik algoritmalar ile çözülebilmesi için, öncelikle, aday çözümlerin uygun şekilde kodlanması gerekmektedir. Kodlanmış aday çözümler, sınırlı bir değer kümesinden veya alfabeden değer alabilen gen dizilerinden oluşmaktadır. Aday çözümleri temsil eden bu gen dizileri kromozomları oluşturmaktadır. Bu durumda, genler aday çözümlerin özelliklerini, genlerden oluşan her bir kromozom da problemin aday bir çözümünü (birey) göstermektedir.

Tüm problemler için uygun tek bir gösterim şekli yoktur. Çoğu zaman aday çözümler, Holland tarafından ilk olarak kullanıldığı gibi, çözümün her bir elemanının 1 veya 0 değeri alabildiği ikil değerlerin kullanıldığı sabit uzunluklu diziler olarak kodlanır.

Ancak, kullanılan gösterim için uygun genetik işlemler tanımlandığı sürece çözüm adaylarının gösterimi için bir çözümün sınırlı bir dizi olarak kodlanmasına imkan veren herhangi bir gösterim de kullanılabilir. Örneğin, uygulamaya bağlı olarak, bazı problemler için çözüm parametrelerinin daha uygun ifade edilebilmesi nedeniyle tam sayı veya gerçel sayıların kullanılması da mümkündür. Genel olarak ise, gösterim ve çözümlerin kodlanması için diziler, ağaç yapıları, listeler veya herhangi bir nesne kullanılabilir.

2.2.2. Başlangıç Populasyonunun Oluşturulması

Genetik algoritmalar, çözüm adımlarına belirlenen gösterim şekline uygun kodlanmış bireylerden oluşan bir başlangıç populasyonu oluşturarak başlarlar. Başlangıç populasyonunu oluşturan bireyler (kromozomlar) rasgele veya çözülecek probleme özgü özel bilgiler kullanılarak kodlanırlar. Çözümü aranan problem ile

ilgili özel bilgi veya durumlar mevcut ise, bu durum çözüm uzay kümesini sınırlandıracak şekilde başlangıç popülasyonunu oluşturmada kullanılabilir.¹⁹

Genetik algoritmada kullanılacak popülasyon büyüklüğünün belirlenmesi için net kurallar yoktur. Popülasyon büyüklüğü problemin yapısına göre belirlenmelidir. Genetik algoritmanın çalışmasında sonraki adımların daha verimli olabilmesi için, başlangıç popülasyonunun olası çözümlerin önemli bir bölümünü kapsayacak şekilde farklı çözümler barındıracak kadar geniş olması gereklidir. Ancak, popülasyonun büyük olması daha çok çeşitlilik sağlayarak daha sağlam sonuçlar verirken, genetik algoritmanın çalışması için ihtiyaç duyulan kaynak gereksinimini artıracaktır.²⁰

2.2.3. Uygunluk Fonksiyonu

Genetik algoritmaların kullanmanın nihai amacı karmaşık bir optimizasyonuna probleminde en iyi veya en iyiye yakın bir çözümü en kısa sürede ve en kolay şekilde bulabilmektir.²¹ Bunu gerçekleştirmek için genetik algoritmalar varolan çözüm alternatiflerinin performansını bir uygunluk (amaç) fonksiyonu kullanarak ölçerler ve daha iyi çözüm alternatiflerine ulaşmaya çalışırlar.

Uygunluk fonksiyonu (fitness function), çözüm adayı bireylerin kromozomlarını (kodlanmış dizileri) uygunluk değerini gösteren rakamsal bir değere eşleştirir. Hesaplanan uygunluk değeri, bireyin amaç fonksiyonuna göre değerini, dolayısıyla da çözüme yakınlığını göstermektedir.

Finansal problemlerde amaç fonksiyonu kâr veya beklenen getirinin maksimizasyonu ya da zarar veya riskin minimizasyonu şeklinde formüle edilebilir. Örneğin, amaç (fonksiyonu) borsada yapılan yatırımın kârını maksimize etmek için

¹⁹ Feldman, Konrad and Treleaven, Philip, a.g.e, s. 201

²⁰ Drake, a.g.e, s. 36

²¹ Pereira, Robert, *Genetic Algorithm Optimisation for Finance and Investment*, Latrobe University School of Business Discussion Papers, 2000, s. 4

varolan örnek piyasa verilerini kullanarak en uygun alım satım kurallarını belirlemek olabilir. Veya optimal portföy seçimi problemi ele alındığında, amaç, portföydeki varlıkların ağırlıklarının belirli bir beklenen getiri düzeyindeki riski minimize edecek şekilde belirlenmesi olacaktır.

2.2.4. Genetik İşlemler

Genetik algoritmaların, çözüm uzayında en iyi sonucu veren çözümü arama süreci üç önemli genetik işlem kullanılarak gerçekleştirilmektedir:

1. Seçim
2. Çaprazlama
3. Mutasyon

Bu genetik işlemler kullanılarak başlangıçta rasgele oluşturulmuş bir problem çözüm adayları popülasyonu ardışık işlemlerle en iyi veya en iyiye yakın çözümleri içeren popülasyona evrilmeye çalışılmaktadır. Genetik algoritmanın çalışması sırasında bir sonraki nesil, varolan neslin bu işlemler kullanılarak değiştirilmesi ile elde edilmektedir. Genetik algoritmaların gücü bu işlemlerden gelmektedir.

2.2.4.1. Seçim

Seçim, mevcut popülasyondaki hangi bireylerin genetik işlemlere tabi tutularak yeni nesillerin oluşturulmasında kullanılacağını belirler. Mevcut popülasyon içerisinde seçilen bu bireyler yeni neslin ataları olmaktadır.

Seçim sırasında, çözüme daha yakın bireylerin daha yüksek olasılıkla seçilmesi hedeflenir. Ancak, seçim algoritması sadece en iyi bireyleri seçerse, popülasyon kısa bir sürede bu bireye yakınsayacaktır. Bu nedenle, seçim algoritması en iyileri seçmeye yönlendirilmeli, ancak, en iyi olmayıp da genetik açıdan faydalı olabilecek bilgi taşıyan bireyleri de seçebilmelidir.²²

²² Pareira, a.g.e, s. 16

Holland tarafından kullanılan rulet tekerleđi (rulet-wheel) yöntemi olarak adlandırılan ilk seçim yöntemi adayların olasılık dağılımına göre seçilmesine dayanıyordu. Buna göre herhangi bir adayın seçilme şansı, onun bütün popülasyon içindeki performansına göre rasgele belirlenmektedir. Böylelikle performansı yüksek olan adayların şansı daha yüksek olmaktadır. Ancak bu yöntem küçük popülasyonlarda, rasgele seçim nedeniyle oransal olarak çok sayıda kötü performansa sahip çözüm adayının seçilebilmesine sebep olabilmektedir.²³

Rulet-tekerlek yöntemindeki bu sorunu gidermek üzere bir çok alternatif yöntemler önerilmiştir. Bu alternatiflerden en yaygın bilinen ve kullanılanı turnuva seçimi yöntemidir. Turnuva seçiminde mevcut popülasyondan, önce iki veya daha fazla aday seçilir ve seçilen adayların oluşturduğu grup içerisinde de performansı en iyi olan aday seçilir. Bu yöntemin temeli en iyi olan yaşar ilkesine (survival of the fittest) dayanmaktadır. Böylece mevcut popülasyonun en kötü bireyinin bir sonraki neslin atası olması önlenmiş olur.²⁴

2.2.4.2. Çaprazlama

Seçim algoritması sonucunda belirlenen, mevcut popülasyon içerisinde göreceli olarak daha iyi performansa sahip olup en iyi çözüme daha yakın olması muhtemel adaylar, çaprazlama işlemi ile birleştirilerek yeni bireyler oluşturulur. Bu şekilde, çözüm uzayının araştırılması süreci rasgele olmayıp, mevcut genetik bilgi doğrultusunda en iyi sonuca götürecektir şekilde yönlendirilmiş olur.²⁵

Seçim işleminde olduğu gibi çaprazlama işleminde de alternatif yöntemler mevcuttur. En çok kullanılan yöntem tek noktadan çaprazlama (single-point

²³ Mitchell M., *An Introduction to Genetic Algorithms*, The MIT Press, Cambridge, MA, 1996, s. 167

²⁴ Goldberg, David E., Genetic and Evolutionary Algorithms come of age, *Communications of the ACM*, Vol. 37, No. 3, March, 1994, s. 113

²⁵ Pareira, a.g.e, s. 6

crossover) olsa da, iki noktadan çaprazlama, çok noktadan çaprazlama ve homojen çaprazlama (uniform crossover) yöntemleri de kullanılabilir.²⁶

Noktalı çaprazlama işleminde çaprazlama için seçilen iki çözüm adayının karşılıklı değerlerinin (genlerinin) çaprazlama noktası/noktalarına göre değiş tokuşu yapılır. Homojen çaprazlamada ise yeni bireyin genleri rasgele olarak çaprazlamaya katılan bireylerin (anne ve baba) genlerinden gelir.

Çaprazlama işlemi sonucunda her iki atanın (anne ve baba) kısmi özelliklerine sahip yeni bir birey (child) elde edilmiş olur. Çaprazlama işlemi her zaman yapılmayabilir. Çaprazlama önceden belirlenmiş bir olasılık yüzdesine bağlı olarak rasgele (stokastik) olarak yapılır.

2.2.4.3. Mutasyon

Mutasyon işleminde seçilen bir bireyin genetik bilgisi, kullanılan kodlama sistemine uygun şekilde rasgele olarak değiştirilir. Örnek olarak, ikili kodlama sistemi ile kodlanmış bir bireyin 1 olan bir geninin 0'a veya 0 olan bir geninin 1'e dönüştürülmesi verilebilir.

Mutasyon ile var olan popülasyona yeni genetik bilgi eklenmiş olur. Bu popülasyonun çeşitliliğini artırarak, çaprazlamanın tersine, algoritmanın çalışma sürecini rasgele bir şekilde çözüm uzayının yeni alanlarına yönlendirir. Mutasyon işlemi, genetik algoritmalara yerel alt optimumlarda takılıp kalmama ve yeni ve daha önceden fark edilmemiş çözümlere ulaşabilme özelliği kazandırmaktadır.²⁷

²⁶ Beasley, D., Bull, D.R., & Martin, R.R., An Overview of Genetic Algorithms: Part 2, Research Topics, University Computing, Volume 15, Issue 4, 1993, s. 170

²⁷ Pareria, a.g.e., s. 7

Mutasyon, seçim ve çaprazlama ile beraber uygulandığından yalnızca çözüm uzayının verimli bir şekilde araştırılmasını sağlamakla kalmaz, aynı zamanda çözüm aday kümesinin çeşitliliğinin kaybolmaması için güvence sağlamış olur.²⁸

Mutasyon da çaprazlama gibi önceden belirlenmiş bir olasılık yüzdesine göre rasgele olarak yapılır. Mutasyonlar optimal çözüme ulaşma açısından faydalı da olabilirler faydasız da olabilirler. Bu nedenle, popülasyonun genetik bilgisinin bir anda çok fazla değişmemesi için mutasyon olasılığı düşük tutulur.

2.2.5. Yeni Bireylerin Değerlendirilerek Yeni Neslin Oluşturulması

Genetik işlemlerin mevcut nesle uygulanmasıyla oluşturulan yeni bireylerden hangilerinin yeni nesle aktarılacağı, bu yeni bireylerin uygunluk fonksiyonuna göre elde edilen değerleri kullanılarak belirlenirler. Yeni bireyler kullanılarak mevcut nesilden, yeni neslin oluşturulmasında iki temel yaklaşım mevcuttur.²⁹ Basit (generational) yöntemde, her yeni nesilde, mevcut neslin tamamı, yeni oluşturulan bireylerden en iyi uygunluk değerlerine sahip bireylerle yenilenir. Dengeli (steady state) yöntemde ise yeni bireylerden, iyi uygunluk değerine sahip olanlar, baştaki neslin zayıf bireyleri ile değiştirilerek yeni nesil oluşturulur.

Basit yöntemde, yeni nesil oluşturulurken, mevcut nesildeki yüksek performansa sahip bireylerin çaprazlama ve mutasyon işlemleri sırasında değiştirilerek kaybolması ve yeni neslin performansı daha düşük bireylerden oluşması riski söz konusudur. Bu problemi gidermek için elitizm kullanılabilir.³⁰ Elitizm, performansı en iyi bireyle (bireyler) temsil edilen o ana kadarki en iyi çözümün korunarak, değiştirilmeksizin bir sonraki nesle aktarılmasını sağlar.

²⁸ Goldberg, David E., a.g.e, s. 114

²⁹ Beasley, D., Bull, D.R., Martin, R.R., *An Overview of Genetic Algorithms: Part 1, Fundamentals*, University Computing, Volume 15, Issue 2, 1993, s. 64

³⁰ Beasley, David, AI FAQ/genetic, <http://www.faqs.org/faqs/ai-faq/genetic/part6/section-6.html>, (15.08.2003)

Böylece her yeni nesil, en azından bir önceki nesildeki en iyi bireyi içermiş olur ve olası çözümün performansının sonraki nesillerde azalması mümkün olmaz.

2.2.6. Bitiş

Genetik algoritmanın çalışma döngüsünün sona erip, çözüme ulaşılabilmesi için önceden belirlenmiş bir çıkış koşulunun sağlanmış olması gerekir. Çıkış koşulunun sağlanması (termination) üç durumdan birinin gerçekleşmesi ile olabilir.³¹

- 1) Tatmin edici bir sonuca ulaşılmış olması
- 2) Genetik algoritmanın belli bir çözüme yakınsaması
- 3) Önceden belirlenmiş en fazla nesil sayısına ulaşılması

Genetik algoritma belli bir çözüme yakınsadığında nesli oluşturan tüm bireyler benzerdir ve genetik algoritmanın adımlarının tekrarlanması sonucu değiştirmez. En fazla nesil sayısı ise genetik algoritmanın yakınsamadığı bazı problemlerde süresiz olarak çalışmasını engellemek amacıyla belirlenir.

Genetik algoritma, sonuca ulaşmadığı, yakınsamadığı veya en fazla nesil sayısına ulaşmadığı durumlarda seçim, çaprazlama ve mutasyon işlemlerini kullanarak yeni nesillerin oluşturulmasına devam eder.

2.3. Genetik Algoritmaların Özellikleri

Genetik algoritmalar basit ama oldukça güçlü bir çözüm aracı sunmaları ve kolayca bir bilgisayar programına dönüştürülebilmeleri nedeniyle gerçek problemlerin çözümünde oldukça yaygın olarak kullanılmaktadırlar. Aşağıdaki bölümlerde genetik algoritmaların avantajları ve dezavantajları sırasıyla ele alınacaktır.

³¹ Lankhorst, Marc M., *Genetic algorithms in data analysis*, Online Resource : <http://www.ub.rug.nl/eldoc/dis/science/m.m.lankhorst/>, (15.08.2003), s.13

2.3.1. Genetik Algoritmaların Avantajları

Genetik algoritmalar, klasik yöntemlerle çözümü elde edilemeyen karmaşık problemlere, en iyi ya da en iyiye yakın sonuçların, hızlı bir şekilde elde edilmesi için kullanılabilen kolay uygulanabilir, güçlü bir optimizasyon tekniğidir. Genetik algoritmaların bu avantajları aşağıda anlatılmıştır.³²

Genetik algoritmalar, gerçek hayatta karşımıza çıkan pek çok problemde olduğu gibi, aşağıdaki özelliklerden bir veya daha fazlasına sahip olup klasik yöntemlerle çözülmesi güç olan problemlerin çözümünde kullanılabilir:

- Çok geniş bir çözüm uzayı
- Birden fazla optimum noktası
- Amaç fonksiyonunun türevinin alınamıyor olması
- Amaç fonksiyonundaki süreksizlikler
- Verilerin doğrusal (lineer) olmaması
- Verilerde önemli oranda hata payı (noise) olması
- Verilerin istikrarsız (nonstationary) olması

Genetik algoritmaların optimal ya da optimale yakın sonuçlara ulaşabilme özelliği ve gücü yukarıda da bahsedildiği gibi genetik işlemlerin (seçim, çaprazlama ve mutasyon) kullanılmasından gelmektedir.

Seçim işleminde performansı daha iyi olan bireylerin seçilme şansı yüksek olsa da bütün bireylerin seçilme şansı mevcuttur. Bu da çözüm uzayının araştırılması sürecinin daha geniş bir alanda sürdürülmesiyle ilk bakışta çözüm için uygun görülmeyen çözüm alanlarının daha detaylı araştırılması sonucunda çok daha iyi sonuçlara ulaşılabilmesine imkan sağlamaktadır.

Seçilen bireylerin çaprazlanması ile aday çözüm kümesinde olmayan yeni bireylerin elde edilmesi mümkün olmaktadır. Bu şekilde mevcut genetik bilginin

³² Pereira, a.g.e., s. 15

kombinasyonlarıyla daha iyi çözümlere ulaşılmaya çalışılmakta, çözüm uzayını araştırma süreci dahi iyi sonuçlar elde edilmesi olası alanlara doğru yönlendirilmektedir.

Mutasyon ise arama sürecini rasgele olarak farklı yönlerde geliştirerek çözüm uzayının farklı bölgelerinin keşfedilmesine olanak sağlamaktadır. Ancak, çözüm uzayındaki arama sürecinin genel gidişini çok fazla bozmamak amacıyla mutasyon olasılığı ve oranı genelde düşük tutulur. Böylece çözüm uzayında sürdürülen genel arama süreci devam ederken, mutasyon ile çözüm uzayının hiç keşfedilmemiş bölümleri de arama sürecine katılmış olur.

Genetik algoritmalarının diğer optimizasyon tekniklerinin aksine yerel minimumlarda takılıp kalma ihtimali çok daha azdır. Bunun sebebi seçim, çaprazlama ve mutasyon işlemlerinin rasgele olarak gerçekleştiriliyor olmasıdır.

Genetik algoritmaların çözüme oldukça hızlı ulaşabilmesi çalışmalarının doğrudan (explicit) ve dolaylı (implicit) paralellik içermesi sayesinde. Doğrudan paralellik genetik işlemlerin aynı anda bütün bir popülasyona uygulanması nedeniyle çözüm uzayının paralel bir şekilde araştırılması demektir. Dolaylı paralellik ise bir bireyin performansının değerlendirilmesinde amaç fonksiyonu kullanılırken bireyin tüm özelliklerinin (genlerinin) aynı anda değerlendiriliyor olması demektir. Bu paralellikler çözüm uzayının farklı bölgelerinin aynı anda araştırılmasını sağlayarak büyük bir verimlilik sağlamış olurlar. Bu verimliliği sayesinde genetik algoritmalar optimal sonuca diğer tekniklere göre çok daha hızlı yakınsarlar.

Ancak burada hız ve ulaşılan sonucun doğruluğu (accuracy) arasında bir tercihin söz konusu olduğunu belirtmek gereklidir. Genetik işlemler anlatılırken değinildiği gibi çaprazlama için farklı yöntemler kullanılabilir. Ayrıca çaprazlama ve mutasyon önceden belirlenmiş olasılıklara göre rasgele olarak gerçekleştirilmektedir. Kullanılan çaprazlama yöntemi ve çaprazlama ile mutasyon olasılık yüzdelerinin seçimi hız ve doğruluk arasındaki tercihi etkilemektedir.

Son olarak, küçük değişikliklerle farklı problemlere kolaylıkla uygulanabilen esnek bir yöntem olması genetik algoritmaların cazibesini arttırmaktadır.

Hazırlanmış olan bir genetik algoritma programının yeni bir probleme uyarlanabilmesi için çoğu zaman problemin uygun şekilde kodlanması ve uygunluk fonksiyonunun doğru bir şekilde formüle edilmesi yeterlidir. Ayrıca, çözülecek problemle ilgili özel bilgiler genetik algoritma tarafından kolaylıkla kullanılabilir ve genetik algoritmalar başka yöntemlerle beraber kullanılabilirler.

2.3.2. Genetik Algoritmaların Dezavantajları

Genetik algoritmaların bir önceki bölümde anlatılan avantajları yanında, genetik algoritmaların belli bir probleme uygulanmasında karşılaşılan tasarım zorlukları ile çözüme ulaşmada yaşanabilecek güçlükler nedeniyle bazı dezavantajları da söz konusudur.³³

Kullanılan kodlama sistemi, seçim, çaprazlama ve mutasyon yöntemleri, çaprazlama ve mutasyon olasılıkları, uygunluk fonksiyonunun formülasyonu ve bitiş koşulunun belirlenmesi gibi parametrelerin, genetik algoritmaların hızı ve sonuca ulaşma yeteneği üzerinde çok önemli bir etkisi vardır. Ancak, bu parametrelerin belirlenmesinde her probleme uygulanabilecek genel kurallar mevcut değildir ve bu parametrelerin doğru olarak belirlenmesi imkansız olmasa da oldukça zor bir konudur.

Bu nedenle, bu seçimlerin problem özelliklerine en uygun olacak şekilde yapılmasına çalışılmalı ve daha iyi çözümlere ulaşabilmek için bu tercihler de optimize edilmelidir. Bu amaçla, çoğu kez parametrelerin çeşitli değerler kullanılarak denenmesi gerekmektedir. Ayrıca, genetik algoritmaların daha önce uygulanmış olduğu problemlerden yararlanmak yol gösterici olacaktır.

Genetik algoritmaların en önemli kısıtı optimal sonuca ulaşma garantisinin olmamasıdır. Özellikle, klasik yöntemlerle çözümü elde edilemeyen problemler söz konusu olduğunda elde edilen sonucun optimal olup olmadığını belirlemek güçtür. Genetik algoritmalar en iyi çözüme ulaşmadan genelde yerel en iyi olan bir çözüme

³³ Pereira, a.g.e., s. 17

yakınsayabilir. Buna erken (prematüre) yakınsama denilmektedir. Ayrıca çok kısıtlı ve yüksek düzeyde doğrusal olmayan (highly non-linear) problemlerde ise hiç yakınsamayabilir. Genetik algoritmaların yakınsamaması yukarıda bahsedilen parametreler için uygun değerlerin seçilmemesine bağlı olabileceğinden, problem için uygun değerlerin seçilmesiyle bu sorun ortadan kaldırılabilir. Ancak, problemin özelliklerinden kaynaklanan yakınsamama durumlarında yapılacak pek bir şey olmayabilir.

2.4. Genetik Algoritmaların Finans Uygulamaları

Dinamik olarak sürekli değişim içerisinde olan günümüz finansal piyasalarında başarılı olabilmek için güçlü araçlar kullanılması gereği açıktır. İnsanın sınırlı kavrama kapasitesine sahip olması ve karar vermede tutarsız olabilmesi bilgisayar teknolojilerinin kullanımını zorunlu kılmaktadır. Genetik algoritmalar bilgisayar teknolojisinin gücüyle birleştiğinde, kararların ve stratejilerin çok daha hızlı bir şekilde doğru olarak belirlenebilmesi için oldukça önemli avantajlar sunmaktadır.

Genetik algoritmalar finans alanında pek çok problemin çözümünde kullanılacak uygun bir tercihtir. Genetik algoritmalar amaç fonksiyonu odaklıdır. Finans problemlerinde genel olarak, amaç fonksiyonları tahmin etme gücüne veya bir kıyaslama sonucuna bağlı getirilerdeki gelişmeleri içerir. Dolayısıyla, kullanılan araç ve problemler arasında mükemmel bir eşleşme mevcuttur.

Bu yönüyle, genetik algoritmalar; finansal tahminlerin yapılması, alım satım stratejilerinin belirlenmesi, nakit akışı yönetimi, opsiyon fiyatlaması, portföy yönetimi, müşteri kredi değerliliğinin belirlenmesi gibi pek çok finans probleminde başarılı bir şekilde kullanılmıştır.

ÜÇÜNCÜ BÖLÜM

GENETİK ALGORİTMALAR İLE PORTFÖY OPTİMİZASYONU: İMKB'DE BİR UYGULAMA

3.1. Genetik Algoritmalarla Portföy Optimizasyonu

3.1.1. Optimizasyon Yöntemleri

Optimizasyon yöntemleri eldeki bir probleme en iyi çözümü bulmaya çalışırlar. Optimizasyon problemlerinde problemin özelliğine bağlı olarak pek çok alternatif yöntem vardır. Günümüzde kullanılan optimizasyon yöntemleri genel olarak üç sınıfta ele alınabilir:³⁴ hesap tabanlı (calculus based), sıralama (numaralandırma) tabanlı (enumeration based) ve rasgele arama (random search) yöntemleri.

Hesap tabanlı yöntemler optimizasyon problemlerinde oldukça fazla çalışılmış ve kullanılmıştır. Hesap tabanlı yöntemler dolaylı ve doğrudan yöntemlerden oluşur. Bu yöntemler fonksiyonun türevinin köklerinin fonksiyonun en küçük ve en büyük değer veren noktaları olmasından yararlanır. Dolaylı yöntemlerde amaç fonksiyonunun türevi sıfıra eşitlenerek sonuca ulaşılmaya çalışılır. Doğrudan yöntemlerde (tepe tırmanma vs.) yerel eğim (gradient) doğrultusunda hareket

³⁴ Lankhorst, Marc M., a.g.e., s. 7

edilerek yerel optimuma ulařılmaya alıřılır. Bu tr yntemlerin kullanılmasında iki temel sorun vardır. İlk olarak bu yntemler zm uzayının arařtırılmaya bařlandığı noktaya yakın en iyi zm oluřturan yerel optimumlarda takılabilir. İkinci olarak hesap tabanlı yntemlerde optimize edilen fonksiyonunun trevinin alınabilmesi gereklidir. Ancak gerek hayattaki problemlerin zm uzayı genelde sreksiz ve dzensizdir, bu nedenle de ama fonksiyonlarının trevi alınamaz.

Sıralama tabanlı yntemler (dinamik programlama, dal ve sınır yntemi vs.) ama fonksiyonunun en iyi deęerini zm uzayındaki noktaların her birini sırasıyla deęerlendirerek bulmaya alıřır. Bunun iin zm uzayının belli aralıklarla ayrılarak (discretization) zm uzayında olası zm noktalarının belirlenmesi gereklidir. zm algoritması ama fonksiyonunun deęerini zm uzayındaki her bir nokta iin sırayla hesaplar. Bu yntemin kolaylığı cazip olsa da, oldukça verimsizdir. oęu gerek problem iin zm uzayı tmnn arařtırılmasının mantıklı olmayacağı kadar byktr.

Rasgele arama yntemleri ise zm uzayının arařtırılacağı ynn rasgele seilmesine dayalıdır. Rasgele arařtırma sonucunda elde edilen en iyi sonular kaydedilerek seilen arama ama doęrultusunda arama sreci yeni bir doęrultuda ynlendirilir. Bu tr yntemler, hesap tabanlı yntemlerin aksine, trev bilgisi gerektirmemeleri, ama fonksiyonu ile ilgili bir kısıtlamalarının olmaması ve hatalı bilgiler ierebilen (noisy) ayrık (disjoint) bir zm uzayını arařtırabilmeleri nedeniyle gerek problemlerin zm iin oldukça kullanışlıdırlar. Ancak, bu tr rasgele yntemlerin uygun bir zaman dilimi ierisinde en iyi zm bulma konusunda garantisi yoktur. Dolayısıyla arařtırma srecinin verimli bir şekilde ynlendirilmesi zerinde durulması gereken nemli bir konudur. Bu nedenle, Genetik Algoritmalar, Benzetimli Tavlama (Simulated Annealing) ve Yasaklı Arama (Tabu Search) gibi rasgele aramaya dayalı teknikler buluşsal yntemler (heuristics) kullanarak rasgele arama srecini daha akıllı hale getirmeyi amalarlar. Bylece bu yntemler dięer yntemlerle zlemeyen problemlere tutarlı ve en veya en iyiye yakın kabul edilebilir sonuların kısa bir srede elde edilmesini saęlarlar.

Rasgele aramaya dayalı buluşsal bir yöntem olarak genetik algoritmaları klasik optimizasyon yöntemlerinden ayıran 4 özelliği vardır:³⁵

- Genetik algoritmalar parametreleri değil parametrelerin kodlanmış gösterimlerini kullanırlar. Herhangi bir fonksiyonu optimize etmek için parametrelerin sonlu elemanlı bir alfabeden oluşturulan sonlu diziler kullanılarak kodlanması yeterlidir.
- Genetik algoritmalar çözüm uzayını bir tek noktadan değil, bir grup noktadan araştırır. Böylece yerel en iyi sonuçlara takılmadan en iyi sonuca hızlı bir şekilde ulaşma şansı artmış olur.
- Genetik algoritmalar çözüme ulaşmak için sadece amaç fonksiyonunu kullanırlar, türev veya başka ek bilgi gerektirmezler. Dolayısıyla da pek çok problemde kolaylıkla kullanılabilirler.
- Genetik algoritmalar önceden belirlenmiş (deterministic) kurallara göre değil, olasılığa bağlı (probabilistic) kurallara göre çalışırlar. Bu özellik genetik algoritmalara başka yöntemlerle ulaşılamayan çözümlere ulaşabilme imkanı vermektedir.

3.1.2. Portföy Optimizasyon Problemi

Portföy optimizasyon probleminin zorluğu modele dahil edilen kısıtlara ve portföyün büyüklüğüne bağlıdır.³⁶ Klasik Markowitz modelinde olduğu gibi açığa satış işlemine izin verilmeyen portföy optimizasyon problemi geleneksel olarak karesel (quadratic) programlama problemi olarak gösterilmektedir.

³⁵ Goldberg, David E., *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley, USA, 1989, s.7

³⁶ Schyns, M., Crama, Y., *Simulated Annealing for Complex Portfolio Selection Problems*, European Journal of Operational Research, Volume 150, Issue 3, November 2003, s. 549

Portföy optimizasyonu probleminin en basit formu olan bu durumda doğrusal programlama veya türev-arama (gradient-search) gibi geleneksel optimizasyon yöntemlerine dayanan özel algoritmalar kullanılarak kolayca çözüm elde edilebilir.³⁷

Kısıtlı portföy optimizasyon modeli ise karmaşık tamsayı (tam sayı ve gerçel sayılı) doğrusal olmayan programlama (mixed integer non-linear programming) problemidir ve klasik algoritmalar ile çözülemez.³⁸

Bölüm 1.2.3'de de gösterildiği gibi kısıtların eklenmesi etkin sınırı süreksiz ve bazı noktalarda tanımsız hale getirebilmektedir. Bu kısıtların dahil edildiği bir kısıtlı portföy modelinde amaç fonksiyonunun türevi alınamayacağından hesap tabanlı yöntemlerle sonuçlara ulaşmak mümkün değildir.

Sıralama tabanlı yöntemler ise portföyün büyüklüğüne bağlı olarak çok uzun zaman alabilir. Olası portföy alternatiflerin çokluğunu görebilmek için H tane hisse senedi içeren bir piyasada P hisse senedi içeren bir portföy oluşturulduğunu varsayalım. Bu durumda oluşturulabilecek farklı portföy kombinasyonlarının adedi aşağıdaki gibi hesaplanır:

$$C(H, P) = \frac{H!}{P!(H - P)!} \quad (3.1)$$

Şimdi de portföydeki hisse senedinin ağırlıklarının çözünürlüğünün de A olduğunu kabul edelim. (A=100 için hisse senetlerinin ağırlıklarının %1'in katı olması gerekir). Portföyü oluşturan hisse senetlerinin ağırlıklarının toplamı %100 olmalıdır. Bu durum, toplam ağırlığın (%100) portföydeki hisse senetlerine dağıtıldığı kombinasyonel bileşim (combinatorial composition) problemi olarak ele

³⁷ Freedman R, DiGiorgio R, A Comparison of Stochastic Search Heuristics for Portfolio Optimization, Proceedings of Second International Conference On Artificial Intelligence Applications on Wall Street, Software Engineering Press, April, 1993, s. 149

³⁸ Chang T. J., Meade N., Beasley J.E., Sharaiha Y. M., *Heuristics for Cardinality Constrained Portfolio Optimisation*, *Computers & Operations Research*, Vol. 27, Issue 13, 2000, s. 1271

alınabilir.³⁹ Buna göre, ağırlık çözünürlüğünün A ve portföydeki hisse senedi adedinin P olduğu bir durumda portföydeki hisse senetlerinin alabilecekleri farklı ağırlık değerlerinin sayısı,

$$C(A + P - 1, P - 1) = \frac{(A + P - 1)!}{A! \cdot (P - 1)!} \quad (3.2)$$

olarak hesaplanır.

Yukarıdaki formüller göz önünde bulundurulduğunda H hisse senedinden oluşan bir yatırım ortamında, ağırlık çözünürlüğü A olacak şekilde, P hisse senedi içeren farklı portföy adedi T:

$$T = C(H, P) \cdot C(A + P - 1, P - 1) = \frac{H!}{P! \cdot (H - P)!} \cdot \frac{(A + P - 1)!}{(P - 1)! \cdot A!} \quad (3.3)$$

dir.

Bu durumda, 30 hisse senedi için ağırlıkları %1'in katları olacak şekilde 10 hisse senedi içeren toplam portföy sayısı aşağıdaki kadardır:

$$T = C(30, 10) \cdot C(109, 9) = \frac{30!}{20! \cdot 10!} \cdot \frac{109!}{9! \cdot 100!} \cong 1,28 \times 10^{20}$$

Varsayılan yatırım ortamının oldukça küçük olmasına rağmen olası portföy adedi oldukça fazladır. Bu kadar çok alternatifi teker teker değerlendirmek günümüz bilgisayar teknolojileri düşünüldüğünde yıllar sürebilir.

Hesap tabanlı ve sıralama tabanlı klasik optimizasyon yöntemleri portföy için belirlenen kısıtları sağlayabilen çözümlere ulaşmakta zorlanırken, rasgele aramaya dayalı buluşsal yöntemler karmaşık kısıtlar veya amaç fonksiyonları belirlendiği

³⁹ Buseti, Franco, Metaheuristic Approaches To Realistic Portfolio Optimisation, M.S. Thesis, June 2000, s.2

durumlarda bile en iyi ya da en iyiye yakın kabul edilebilir sonuçlara hızlı bir şekilde ulaşabilirler.⁴⁰

3.1.3. Genetik Algoritmaların Kullanılma Sebepleri

Genetik algoritmaların finansal modelleme uygulamaları için uygun olması ve kısıtlı portföy optimizasyonu probleminin çözümünde güçlü bir tercih olarak öne çıkması ve bu çalışmada kullanılmasının 3 temel sebebi vardır:⁴¹

- Genetik algoritmalar amaç odaklıdır. Finansal problemler de bir amaç fonksiyonu ile ifade edilebilirler. Bu açıdan problem çözüm aracı ile hedef problemler arasında tam bir uyum söz konusudur
- Genetik algoritmalar nitelikleri gereği niceldirler, dolayısıyla da parametre optimizasyonu için çok uygundur. Genetik algoritmaların en yaygın kullanım alanı çok parametrelili fonksiyon optimizasyonudur.⁴² Pek çok problem gibi kısıtlı portföy optimizasyonu da, girdi parametrelerinin karmaşık bir fonksiyonunun optimizasyonu olarak formüle edilebilir.
- Genetik algoritmalar klasik yöntemlerde sağlanması mümkün olmayan pek çok kısıtın eklenmesine ve esnekliğe imkan verir.

Bu özellikleri sayesinde hızlı bir şekilde uygun çözümlere ulaşabilmesi, ulaşılan çözümlerin kalitesi, yeni kısıtların kolayca eklenebilmesi ve amaç fonksiyonunun kolaylıkla değiştirilebiliyor olması nedeniyle genetik algoritmalar kısıtlı portföy optimizasyonu probleminin çözümünde önemli ve oldukça uygun bir çözüm alternatifi olarak değerlendirilmiş ve çalışmada kullanılmıştır.

⁴⁰ Freedman R, DiGiorgio R, A Comparison of Stochastic Search Heuristics for Portfolio Optimization, Proceedings of Second International Conference On Artificial Intelligence Applications on Wall Street, Software Engineering Press, April, 1993, s. 149

⁴¹ Leinweber, David J. and Arnott, Robert D., Quantitative and computational innovation in investment management, The Journal of Portfolio Management, Vol.21, No. 2, Winter, 1995, s. 12

⁴² Forrest, Stephanie, Genetic Algorithms, Computing Surveys Vol. 28:1, 1996, s. 79

3.2. Geliştirilen Uygulama: Yöntemler ve Varsayımlar

3.2.1. Uygulama Geliştirme Ortamı

Bu çalışmada uygulama geliştirme ortamı olarak, her türlü hesaplamanın kolayca yapılabilmesi, kolay kullanılabilir ve adapte edilebilir olması ve grafik desteği nedeniyle MS Excel ® kullanılmıştır. Genetik algoritma programı MS Excel ® makrosu olarak kodlanmıştır.⁴³

Uygulamanın çalıştırıldığı test ortamı olarak ise Intel ® Pentium IV işlemcili, 256 MB belleğe sahip standart bir masaüstü bilgisayar kullanılmıştır.

3.2.2. Veri Seçimi

Günümüz koşulları içerisinde mevcut özellikleri nedeniyle İMKB’de yapılan yatırımlar çoğu kimse tarafından kumar olarak algılanmaktadır. Bu nedenle yapılan çalışmaların sonuçlarının tutarlı olabilmesi ve bilimsel bir değeri olması için İMKB-30 hisse senetleri kullanılmıştır.

03.06.2002 ile 31.12.2002 tarihleri arasında gerçekleşen İMKB-30 hisse senetlerinin birinci 6 aylık günlük 2. seans kapanış fiyatları geliştirilen modelde girdi olarak kullanılmış, elde edilen sonuçların değerlendirilmesinde ise 02.01.2003 ile 30.06.2003 tarihleri arasındaki ikinci 6 aylık dönem için gerçekleşmiş olan hisse senedi getirileri kullanılmıştır.⁴⁴

⁴³ <http://ffusco.altervista.org/software/genetic/> (15.08.2003)

⁴⁴ <http://www.imkb.gov.tr/> (15.08.2003)

3.2.3. Uygulama Adımları

3.2.3.1. Veri Analizi

Yapılan çalışmada geliştirilen modelde beklenen getiri ve risk değerlerinin hesaplanması için 03.06.2002 ile 31.12.2002 tarihleri arasında gerçekleşen İMKB-30 hisse senetlerinin 6 aylık günlük 2. seans kapanış fiyatları kullanılmıştır.

Tablo 3.1 – İMKB-30 Hisse Senetlerinin 03.06.2002 - 31.12.2002 Tarihleri Arasındaki 6 Aylık Getirileri

İMKB-30	Getiri	Risk	İMKB-30	Getiri	Risk
AKBNK	44,68%	46,41%	ISCTR	-23,37%	49,67%
AKENR	-8,28%	40,83%	KCHOL	24,18%	41,57%
AKGRT	8,43%	43,94%	MIGRS	28,88%	40,79%
AKSA	31,70%	43,08%	NETAS	7,11%	42,91%
ALARK	5,78%	37,35%	PETKM	16,41%	47,43%
ARCLK	51,27%	46,65%	PTOFS	8,63%	45,22%
DOHOL	7,70%	63,37%	SAHOL	15,16%	37,14%
DYHOL	27,24%	68,80%	SISE	22,31%	46,04%
ENKAI	17,93%	32,16%	TCELL	48,38%	51,91%
EREGL	19,77%	42,21%	TRKCM	29,50%	38,06%
FINBN	46,90%	53,20%	TNSAS	-16,56%	46,76%
FROTO	6,89%	42,01%	TOASO	-18,89%	44,14%
GARAN	4,57%	54,06%	TUPRS	24,53%	42,80%
HURGZ	22,20%	53,63%	VESTL	20,19%	45,64%
IHLAS	40,36%	74,84%	YKBNK	-44,00%	72,90%

Hisse senetlerinin beklenen getirilerinin hesaplanması için belirtilen dönem için 6 aylık günlük getiriler hesaplanmış, günlük getirilerin toplamı da 6 aylık dönem için beklenen getiri olarak bulunmuştur. Hisse senetlerinin riski için ise yine bu 6 aylık dönemdeki günlük getirilerin standart sapması kullanılmıştır. (Tablo 3.1)

Hisse senetlerinin katıldıkları portföyün riskine olan katkılarını hesaplayabilmek için de belirtilen 6 aylık dilim için hazırlanmış olan günlük kapanış değerlerinin kovaryansı hesaplanmıştır.

Bu hesaplamaların tümü MS Excel'e aktarılmış olan veriler ve MS Excel'de mevcut olan fonksiyonlar kullanılarak yapılmıştır.⁴⁵

3.2.3.2. Optimal Portföyün Oluşturulması

Yukarıda elde edilen beklenen getiri, risk ve kovaryans değerleri genetik algoritma programında girdi olarak kullanılmış ve portföy optimizasyonu bu değerler doğrultusunda genetik algoritma programı ile yapılmıştır.

Genetik algoritma programında, her biri bir portföyü temsil eden bireylerden oluşan bir başlangıç popülasyonu ile başlanıp, genetik işlemlerin uygulanmasıyla her yeni nesilde daha iyi çözümleri seçerek optimal çözüme ulaşılmaya çalışılmıştır. Bu çalışmada popülasyonları oluşturan bireyler olası portföyleri temsil ettiği için birey veya portföy değişmeli olarak kullanılabilse de aynı anlamı ifade etmektedir.

Genetik algoritmanın yakınsaması, dolayısıyla çalışmasının durdurulması kararı kullanıcıya bırakılmıştır. Ancak yapılan testlerde genetik algoritma 100 ila 200üncü nesil arasında yakınsamıştır.

Genetik algoritma ile elde edilen portföylerin beklenen getirilerinin hesaplanması için portföydeki hisse senedi ağırlıkları ile hisse senetlerinin beklenen getirileri kullanılmıştır. Oluşturulan portföylerin risklerinin hesaplanması için ise kovaryans matris yöntemi⁴⁶ kullanılmıştır. Bu yöntemle göre oluşturulan bir portföyün riskini hesaplamak için kovaryans matrisini satır ve sütun ağırlıklarıyla çarpıp, oluşan ağırlıklı kovaryans değerlerini toplamak yeterlidir.

⁴⁵ Küçükkocaoğlu, Güray, *Optimal Portföyün Seçimi ve İMKB Ulusal-30 Endeksi Üzerinde Bir Uygulama*, <http://www.baskent.edu.tr/~gurayk/kisiseoptimization.pdf> (15.18.2003)

⁴⁶ Kolb Robert W, Rodriguez Ricardo J, Finansal Yönetim, SPK , Yayın No: 35, Temmuz 1996, s. 226

3.2.3.3. Elde Edilen Sonuçların Değerlendirilmesi

Yapılan çalışmada birinci öncelik genetik algoritmaların kullanılan girdi bilgileri doğrultusunda kısıtları karşılayan optimal bir portföye ulaşabilirliğinin gösterilmesidir. Bu amaçla kullanılan veri seti ve kısıtlar için etkin sınır grafiği çizilerek optimal portföyler kümesi elde edilmiş ve elde edilen sonuçlar yorumlanmıştır.

Genetik algoritmanın belirtilen parametrelerle çalıştırılmasından sonra oluşturulan herhangi bir portföyün performansının ölçülebilmesi amacıyla ise, oluşturulan portföyün 02.01.2003 ile 30.06.2003 tarihleri arasındaki ikinci 6 aylık dönem için gerçekleşmiş olan hisse senedi getirileri kullanılmıştır (Tablo 3.2).

Oluşturulan portföydeki hisse senedi ağırlıkları ile hisse senetlerinin getirilerinin çarpılmasıyla, bu zaman diliminde oluşturulmuş portföye yatırım yapılmış olunsaydı ne kadar getiri elde edileceği hesaplanmıştır.

Tablo 3.2 – İMKB-30 Hisse Senetlerinin 02.01.2003 - 30.06.2003 Tarihleri Arasındaki 6 Aylık Getirileri

İMKB-30	Getiri	İMKB-30	Getiri
AKBNK	20,50%	ISCTR	13,06%
AKENR	-7,17%	KCHOL	-9,21%
AKGRT	9,81%	MIGRS	2,24%
AKSA	-0,32%	NETAS	18,97%
ALARK	16,58%	PETKM	35,06%
ARCLK	17,19%	PTOFS	-29,02%
DOHOL	-4,37%	SAHOL	4,42%
DYHOL	-0,41%	SISE	15,65%
ENKAI	22,45%	TCELL	6,24%
EREGL	20,75%	TRKCM	9,26%
FINBN	33,51%	TNSAS	8,32%
FROTO	28,00%	TOASO	34,20%
GARAN	-3,96%	TUPRS	30,97%
HURGZ	2,48%	VESTL	18,25%
IHLAS	24,49%	YKBNK	23,92%
Endeks			2,99%

3.3 Standart Markowitz Modeline Göre Portföy Optimizasyonu

Standart Markowitz modeline göre portföy optimizasyonunda geçerli olan tek kısıt hisse senedi ağırlıklarının 0 veya daha büyük olması, yani açığa satış işleminin olmadığı durumdur.

Bu şekilde formüle edilmiş bir portföy optimizasyonu problemi, daha önce de bahsedildiği gibi, geliştirilmiş klasik yöntemler kullanılarak çözülebilir. Genetik algoritmaların elde ettiği sonuçların optimal olduğunu garanti etmek mümkün olmadığından, bu tür yöntemlerle elde edilen optimal sonuçlar genetik algoritma ile edilen optimizasyon sonuçlarının doğruluğunun ölçülebilmesi için kullanılabilir. Bu amaçla Markowitz modelinin standart formunda portföy optimizasyonu için MS Excel Çözücü⁴⁷ kullanılmış ve elde edilen sonuçlar genetik algoritma ile elde edilen sonuçla karşılaştırılmıştır. Buradaki temel amaç genetik algoritmaların böyle bir problemin çözümünde kullanılabilirliğini göstermektir.

Microsoft Excel Çözücü, Austin'deki Texas Üniversitesi'nden Leon Lasdon'ın ve Cleveland State Üniversitesi'nden Allan Waren'ın geliştirdiği (Generalized Reduced Gradient - GRG2) doğrusal olmayan en iyi hale getirme kodunu kullanır. Doğrusal ve tamsayı problemleri, değişkenlerdeki sınırlarla simpleks yöntemini ve dal ve sınır yöntemini (branch-and-bound) kullanır.

3.4. Standart Markowitz Modeline Göre Genetik Algoritma Portföy Optimizasyonu

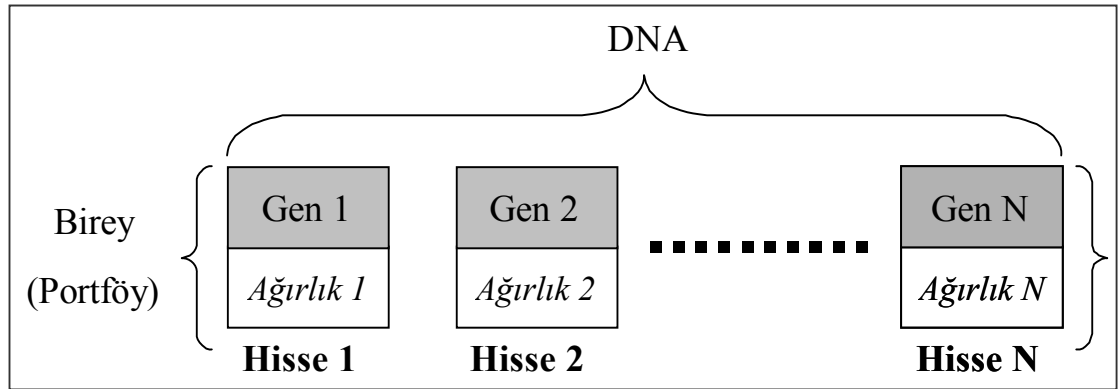
3.4.1. Çözümlerin Kodlanması

Genetik algoritmalarla ilgili bölümde bahsedildiği üzere, bir problemin genetik algoritmaların çözümünde kullanılabilmesi için ilk önemli adım, oluşturulacak çözümlerin gösterimi ve genetik algoritma tarafından işlenmeye uygun

⁴⁷ <http://www.solver.com> (15.08.2003)

olacak şekilde kodlanmasıdır. Bilindiği gibi genetik algoritmalarda çözümlerin kodlanmasında genel olarak ikili değerler kullanılmakla başka alternatifler de kullanılabilir. Bizim çalışmamızda probleme daha uygun olduğu için aday bireylerin kodlanmasında gerçel sayılar kullanılmıştır.

Buna göre N hisse senedi içeren bir yatırım ortamında portföy oluşturulduğu bir durumda, her bir olası portföy bir birey olarak ele alınmış ve portföydeki hisse senetlerinin ağırlıkları da bu hisse senedinin genetik kodu olarak kabul edilmiştir. Bu durumda her bir bireyin genetik kodu (DNA'sı) içerdiği N hisse senedinin ağırlık değerlerinden (genlerden) oluşmaktadır. Her birey için genlerin toplam değeri (DNA) 1'e eşit, her genin değeri ise 0 ile 1 arası ($0 \leq \text{Ağırlık } N \leq 1$) bir değerdir. Portföylerin bu şekilde kodlanması aşağıdaki şekilde gösterilmiştir.



Şekil 3.1 – Genetik Algoritmada Portföylerin Gösterimi (Genetik Kod)

Genetik algoritmanın çalıştırılması sırasında herhangi bir andaki portföy popülasyonu yukarıda belirtilen şekilde kodlanmış bireylerden oluşmaktadır.

3.4.2. Başlangıç Popülasyonunun Oluşturulması

Başlangıç popülasyonunu oluşturmak için, popülasyondaki her bir portföyün hisse ağırlıkları 0 ile 1 arasında gerçel bir sayı olacak şekilde rasgele oluşturulur, daha sonra bu ağırlıkların toplamı 1'e eşit olacak şekilde ölçeklendirilerek ilk nesil oluşturulmuş olur.

3.4.3. Yeni Nesil İçin Aday Bireylerin Oluşturulması (Genetik İşlemler)

Yeni bir neslin oluşturulması için aday bireyler o anki mevcut populasyon bireylerinin çaprazlanması ve mutasyonu ile elde edilir. Bu şekilde elde edilen aday portföylerden oluşan popülasyondaki her bir portföyün performansı değerlendirilerek (uygunluk fonksiyonuna göre) en iyi performansa sahip bireyler bir sonraki nesli oluşturmak için seçilirler.

3.4.3.1. Seçim ve Çaprazlama

Genetik algoritma optimizasyonu için popülasyon büyüklüğü, hızlı yakınsaması ve iyi sonuçlar almak için yeterli olması nedeniyle 10 bireylik (portföy) bir popülasyon yeterli olmuştur. Bu nedenle bir sonraki neslin oluşturulmasında çaprazlamaya katılacak bireyler için herhangi bir seçim algoritması uygulanmamış ve dolayısıyla aday popülasyonun bireyleri mevcut popülasyonun tüm bireylerinin ikili çaprazlanmasıyla elde edilmiştir.

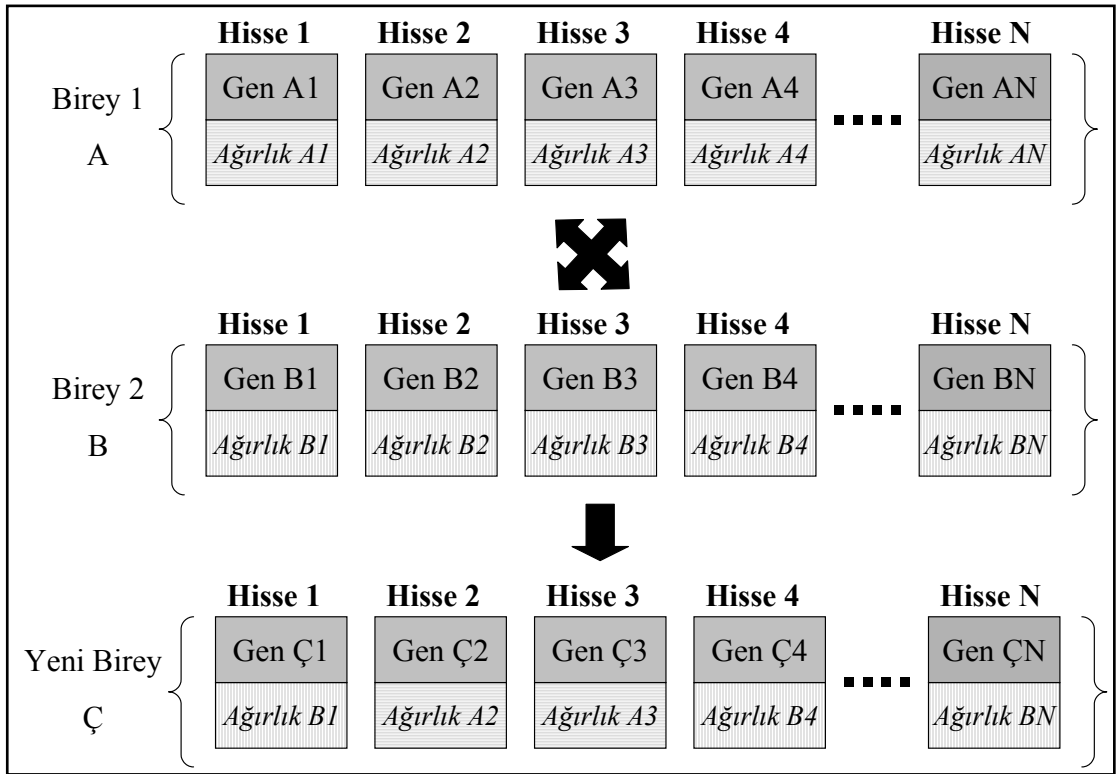
Ancak yeni nesil oluşturulurken, bir önceki neslin en iyi bireyi de herhangi bir değişikliğe uğramadan bir sonraki neslin seçileceği, bir önceki neslin bireylerinin seçme, çaprazlama ve mutasyon işlemlerinden geçirilmesi ile oluşturulmuş aday bireyler popülasyonuna dahil edilmektedir. Bu durumda bir önceki neslin en iyi bireyi, aday bireyler popülasyonunun en iyi N bireyi içerisinde yer alabilirse bir sonraki nesle de aktarılmış olur. Yapılan bu elitizm uygulamasıyla, her neslin en iyi bireyi korunarak, bir sonraki neslin en iyi portföyünün performansının en az bir önceki neslin en iyi portföyü kadar olması garanti edilmiş olur. Böylece her nesilde bir önceki neslin en iyi çözümü korunmuş ya da geliştirilmiş olur, dolayısıyla da genetik algoritmanın en iyi ya da en iyiye yakın sonuca ulaşması ve hızlı bir şekilde yakınsaması sağlanmış olur.

Bu durumda, çaprazlama işleminden sonra bir sonraki neslin oluşturulacağı aday bireyler popülasyonu, bir önceki neslin en iyi çözümünü temsil eden birey de dahil olmak üzere toplam

$$C(N,2)+1 = \frac{N(N-1)}{2} + 1 \quad (3.4)$$

bireyden oluşur. (N=10 için toplam 46 birey)

Çaprazlama işlemi için homojen çaprazlama yöntemi kullanılmıştır. Buna göre iki portföyün (Genetik açıdan anne ve babanın DNAlarının) çaprazlanmasıyla yeni bir portföyün oluşturulmasında, yeni portföyün genleri rasgele seçilmiş olarak anne ya da babadan gelmektedir. Bu durumda yeni portföydeki her bir hisse senedinin ağırlığı anne ya da baba portföyündeki hisse senedinin ağırlığıdır. Böylece her yeni portföy mevcut portföy populasyonunda var olan hisse senetlerinin (ağırlığı sıfırdan büyük olan hisse senetleri) kombinasyonlarından biri olacaktır. Çaprazlama işleminin yapılışı aşağıdaki şekilde gösterilmiştir. (Şekil 3.2)



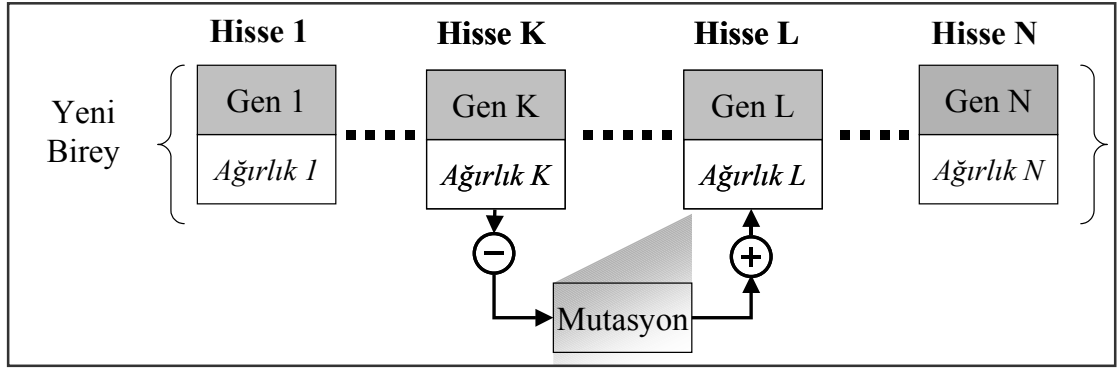
Şekil 3.2 – Genetik Algoritma Çaprazlama İşlemi

Çaprazlama işlemi sonucunda elde edilen yeni portföydeki hisse senetlerinin ağırlıkları anne veya baba portföyden rasgele gelmiş olduğundan, genelde yeni portföydeki hisse senetlerinin ağırlıkları oransal olarak değişmiş olur ve sonuç olarak

yeni portföydeki ağırlıklar anne veya baba portföydeki ağırlıklardan farklı değerler olabilir.

3.4.3.2. Mutasyon

Çaprazlama ile elde edilen bireyler daha sonra mutasyon işlemine tabi tutulurlar. Bu çalışmada kullanılan mutasyon işleminde her bir portföyde bir adet kaynak hisse senedi ve bir adet hedef hisse senedi seçilir ve kaynak hisse senedinin portföy ağırlığının en fazla belirlenmiş olan mutasyon oranı kadar kısmı hedef hisse senedine aktarılır (Şekil 3.3).



Şekil 3.3 – Genetik Algoritma Mutasyon İşlemi

Mutasyon miktarı sıfırdan en fazla mutasyon oranı kadar bir aralıkta değişen değerler alabilen bir gerçel sayı olabilir. Mutasyon miktarı sıfır olduğunda ağırlıklar değişmemiş yani mutasyon yapılmamış, mutasyon miktarı sıfırdan büyük olduğunda ise mutasyona katılan iki hisse senedinin ağırlıkları mutasyon miktarı kadar değiştirilmiş olur.

Çaprazlama işlemi sonucunda elde edilen portföylerde hisse senetlerinin ağırlıkları değişebilse de yeni portföyler sadece mevcut populasyondaki portföye dahil hisse senetlerinin kombinasyonundan oluşmaktadır. Mutasyon işleminde ise portföydeki hisse senetlerinin ağırlıkları değişebildiği gibi, ağırlığı sıfır olup portföye dahil olmayan hisse senetlerinin portföye dahil olabilmesine olanak sağlanarak alternatif portföylerin değerlendirilmesi fırsatı da verilmiş olur.

Mutasyon işlemi sonucunda herhangi bir hisse senedinin ağırlığının negatif olması durumunda, açığa satış işlemine izin verilmemesi nedeniyle hisse senedinin ağırlığı sıfıra eşitlenir. Bu şekilde hisse senetlerinin ağırlıklarının sürekli olarak sıfıra eşit olması ya da pozitif olması sağlanmış olur.

Çaprazlama ve mutasyon işlemlerinden sonra portföydeki hisse senedi ağırlıkları değişmiş olabileceğinden, hisse senedi ağırlıklarının toplamları büyük olasılıkla 1'e eşit olmayacaktır. Bu nedenle yeni ağırlıkların oluşturulması için çaprazlama ve mutasyon sonrasında elde edilen ağırlıklar toplamları 1'e eşit olacak şekilde ölçeklendirilir. Sonuçta, genetik algoritmanın yakınsaması durumu dışında, elde edilen portföyler bir önceki nesli oluşturan portföylerden büyük ölçüde farklılık arz edecektir.

3.4.4. Yeni Nesle Aktarılacak Bireylerin Seçilmesi

Yeni neslin oluşturulmasında basit (generational) yöntem kullanılmıştır. Buna göre, her yeni nesilde, mevcut nesli oluşturan N bireyin tamamı, yeni oluşturulan bireylerden en iyi uygunluk değerlerine sahip bireylerle yenilenir. Bu amaçla, başlangıçtaki N bireylik popülasyondan genetik işlemler sonucunda elde edilen $\frac{N(N-1)}{2} + 1$ aday bireyden sadece N tanesi yeni nesle aktarılacaktır. Genetik algoritmanın çalışması açısından aday bireylerden yeni nesle aktarılmak üzere seçilecek N birey, bu bireylerin temsil ettiği portföylerin belli bir risk seviyesi için beklenen getirinin en yüksek olması ya da belli bir beklenen getiri için riskin en düşük olması olarak belirlenmiş olan kritere göre performansı hesaplanan aday portföylerin en iyi N tanesi olarak seçilir.

Portföy performansları seçilen optimizasyon türüne (risk veya beklenen getiri) ve portföyün riski ve beklenen getirisine göre hesaplanır. Daha önce de bahsedildiği gibi herhangi bir portföyün beklenen getirisini hesaplamak için portföy ağırlıkları portföydeki hisse senetlerinin beklenen getirileri ile çarpılarak toplanır. Portföy riskini hesaplamak için ise portföy ağırlıkları kovaryans matrisi ile çarpılarak toplanır.

Portföy optimizasyon kriteri risk olarak seçilmişse, genetik algoritma ilk nesillerde riski belirlenen sınırın altına düşürecek şekilde yeni nesilleri oluşturur, risk hedefine ulaşıldıktan sonraki nesillerde ise her yeni nesilde risk sınırı aşılmadan beklenen getiri arttırılmaya çalışılır. Bunu sağlamak için amaç fonksiyonunda riskin belirlenen seviyeden yüksek olması durumunda portföy performansı riskin negatif değerini alır. Bu şekilde belirlenenden fazla risk için bir tür ceza fonksiyonu kullanılmış olur. Riskin belirlenen seviyenin üstünde olmaması durumunda ise portföy performansı portföyün beklenen getirisine eşit olacaktır. Böylece risk kriteri sağlandığında getiri arttıkça portföyün performansı dolayısıyla da bir sonraki nesle aktarılma olasılığı artmış olacaktır.

Optimizasyon kriteri olarak beklenen getiri olarak seçildiği durumda ise genetik algoritma öncelikle belirlenen beklenen getiriye ulaşmaya çalışır, bu getiri seviyesi elde edildikten sonraki nesillerde ise her yeni nesilde beklenen getirinin altına düşülmeden risk azaltılmaya çalışılır. Bu kritere göre elde edilen getiri belirlenen seviyenin altına düşmediği sürece, düşük risk yüksek performans değeri alır, elde edilen getiri belirlenen getiri kriteri altına düştüğü durumda ise belirlenen seviyenin altına düşüldükçe daha yüksek bir negatif değer veren bir ceza fonksiyonu kullanılır.

Aslında her iki optimizasyon kriterinde yapılan işlemler benzerdir ve daha önce de bahsedildiği gibi aynı sonuçları vermektedirler.

3.5. Kısıtlı (Genişletilmiş) Markowitz Modeline Göre Genetik Algoritma Portföy Optimizasyonu

Portföy optimizasyonunda kullanılabilecek kısıtlar genel kısıtlar ve hisse senedi kısıtları olarak ikiye ayrılabilir. Çalışmada kullanılan modelde genel kısıtlar olarak N tane hisse senedinden K tanesinin seçilmesi ($K \leq N$) ve portföydeki bir hisse senedinin minimum ağırlık değeri; hisse senedi kısıtları olarak da her hisse senedi için minimum ve maksimum ağırlık değerleri kullanılmıştır.

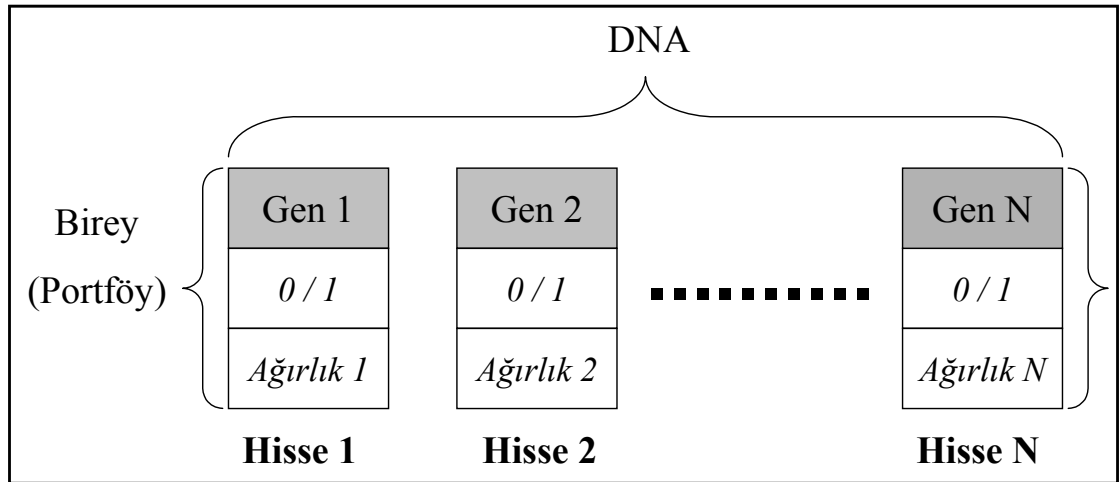
Genel portföy kısıtları portföyün yönetilebilir olmasını ve portföy yönetim maliyetlerinin azaltılmasını hedeflerken, hisse senedi kısıtları da yatırımcının

beklentilerini yansıtmaktadır. Herhangi bir hisse senedi için en az ağırlığın sıfırdan büyük olması bu hisse senedinin oluşturulacak portföye dahil olacağını, en çok ağırlığının sıfıra eşit olması ise oluşturulacak portföye dahil edilmeyeceğini göstermektedir.

Bu tür kısıtlara sahip bir portföy optimizasyon problemi daha önce de değinildiği gibi oldukça karmaşık bir problem olup, klasik yöntemler çözülememekte bu nedenle genetik algoritma çözümleri kullanılmaktadır.

3.5.1. Çözümlerin Kodlanması

Genişletilmiş Markowitz modelinde bireylerin genetik kodunda (DNA) hisse senetlerinin ağırlık değerlerine ek olarak hisse senedinin portföye dahil olup olmadığına da bilinmesi gereklidir. Bu amaçla standart kodlamaya hisse senedinin portföye dahil olup olmadığını gösteren ve 0 veya 1 değeri alabilen ilave bir alan eklenmiştir. Bu alanın 0 olması ilgili hisse senedinin portföye dahil olmadığını, 1 olması ise portföye dahil olduğunu göstermektedir. Eğer bir hisse senedi portföye dahil değilse ağırlığı sıfır olacaktır. Yeni genetik kodlama aşağıdaki şekilde gösterilmiştir. (Şekil 3.4)



Şekil 3.4 – Kısıtlı Portföy Optimizasyonu Modelinde Portföylerin Gösterimi

N hisse sendi içerisinde oluşturulan bir portföydeki maksimum hisse senedi adedi K ($K \leq N$) olması durumunda bu portföydeki bu alanların toplamı K 'dan küçük veya K 'ya eşit olmalıdır.

3.5.2. Başlangıç Populasyonunun Oluşturulması

Genetik algoritmanın çalıştırılmasında ilk populasyon yukarıda standart Markowitz modeli için anlatıldığı şekilde rasgele oluşturulur, ancak bu işlem sırasında portföy kısıtları da dikkate alınır.

İlk olarak, minimum ağırlığı sıfırdan büyük olan hisse senetleri oluşturulacak portföye dahil edilir, maksimumu sıfıra eşit hisse senetleri ise portföyden çıkarılır. Kalan hisse senetleri arasından portföye dahil olacak hisse senedi adedine ulaşılabilecek kadar hisse senedi portföye rasgele olarak dahil edilir. Bu işlem sonucunda N hisse senedi arasından K hisse senedi kümesinden oluşan portföyler elde edilmiş olur.

Hisse senetleri için girilmiş sıfırdan büyük en az ağırlıklar ilgili hisse senetlerine dağıtılmış kabul edilerek en az ağırlıklar toplamı dışında kalan ağırlık portföye dahil olması muhtemel hisse senetleri arasında rasgele dağıtılır. Dolayısıyla hisse senetlerinin gerçek ağırlığı istenen minimum ağırlığı ile o hisse senedine dağıtılmış olan ağırlığın toplamına eşit olacaktır.

Bu işlemler sırasında, oluşturulan ağırlıkların toplamının 1'e eşit olacak şekilde ölçeklendirilmesi nedeniyle, sonuçta her bir hisse senedinin ağırlığı o hisse senedi için girilmiş olan minimum ve maksimum değerler arasında bir değer almış olur.

Portföye dahil olacak en fazla hisse senedi adedi değeri, portföydeki toplam hisse senedi sayısının üst sınırını belirttiği için bir hisse senedinin portföye dahil olması onun ağırlığının sıfırdan büyük olmasını gerektirmez. Buna göre genetik algoritma uygulaması açısından portföydeki toplam hisse senedi adedi her zaman için belirlenmiş en çok hisse senedi adedi değerine eşit olurken, elde edilen portföyde uygulama açısından portföye dahil olsa da ağırlığı sıfır olan hisse senetleri

olabileceğinden, portföyün pratikteki hisse senedi adedi en çok hisse senedi adedi değerinden az olabilir.

3.5.3. Yeni Nesil İçin Aday Bireylerin Oluşturulması (Genetik İşlemler)

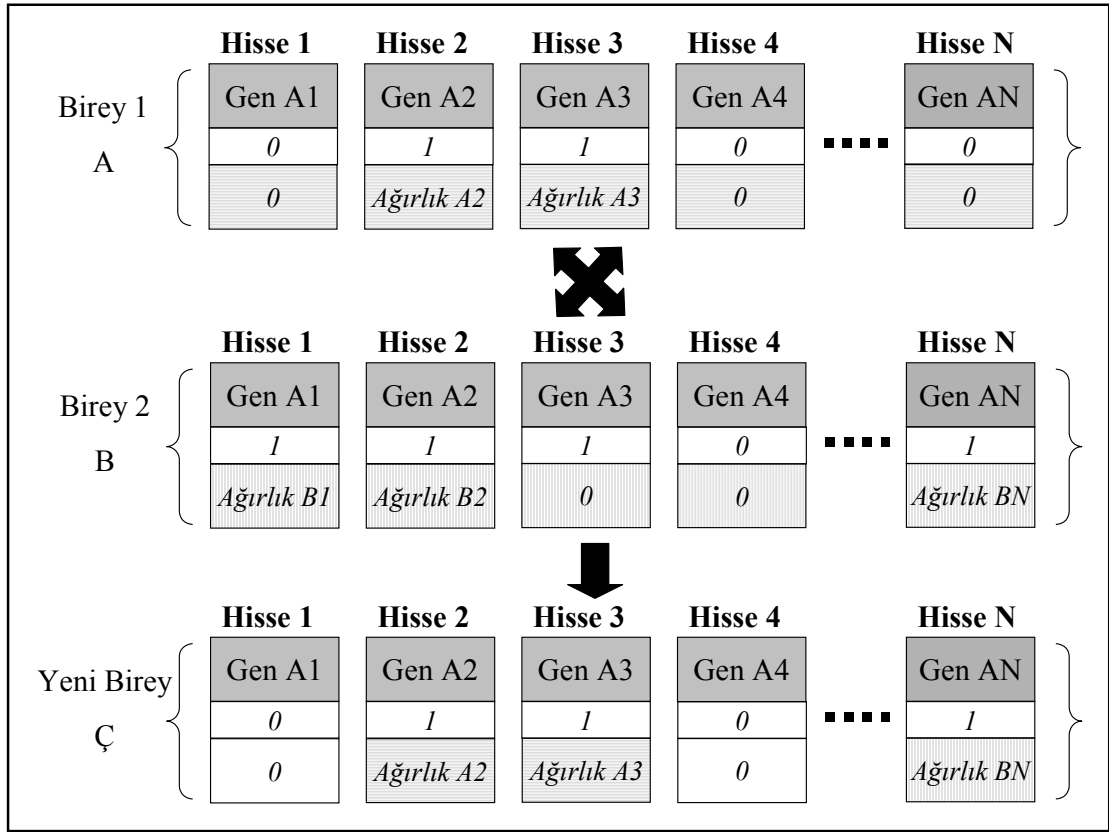
3.5.3.1. Seçim ve Çaprazlama

Çaprazlamaya katılacak bireylerin seçiminde bu modelde de özel bir seçim algoritması kullanılmamış, mevcut popülasyondaki tüm bireyler birbirleriyle çaprazlanmışlardır.

Çaprazlama işlemi anne ve baba portföyelerine dahil hisse senetlerine göre standart modelde olduğu gibi homojen çaprazlama yöntemi kullanılarak yapılmaktadır. Öncelikle eğer bir hisse senedi hem anne hem de baba tarafından temsil edilen portföylere dahil ise çaprazlama ile elde edilen yeni bireyle temsil edilen portföye de dahil edilmektedir. Böyle bir hisse senedinin ağırlığı rasgele olarak anne ya da babasının ağırlığına eşit olacaktır.

Çaprazlamaya katılan her iki portföyde de ortak olarak mevcut olan hisse senetlerinin yeni portföye de eklenmesinden sonra, anne ve baba portföyelerinde geriye kalan ve ikisinden birinde portföye dahil hisse senetleri kümesinden yeni portföye dahil olacak hisse senedi sayısını belirlenmiş olan en fazla hisse senedi adedine (K) tamamlayacak kadarı yeni portföye ağırlıklarıyla rasgele olarak aktarılır. (Şekil 3.5)

Sonuçta, her iki portföyde de (anne ve baba) dahil olan hisse senetleri yeni oluşturan portföye dahil olurken, her ikisinde de dahil olmayan hisse senetleri ise yeni oluşturulan portföyde yer almayacaktır. Ancak, diğer hisse senetleri anne ve babadan rasgele olarak ekleneceği için yeni portföyün içeriği değişmiş olacaktır.



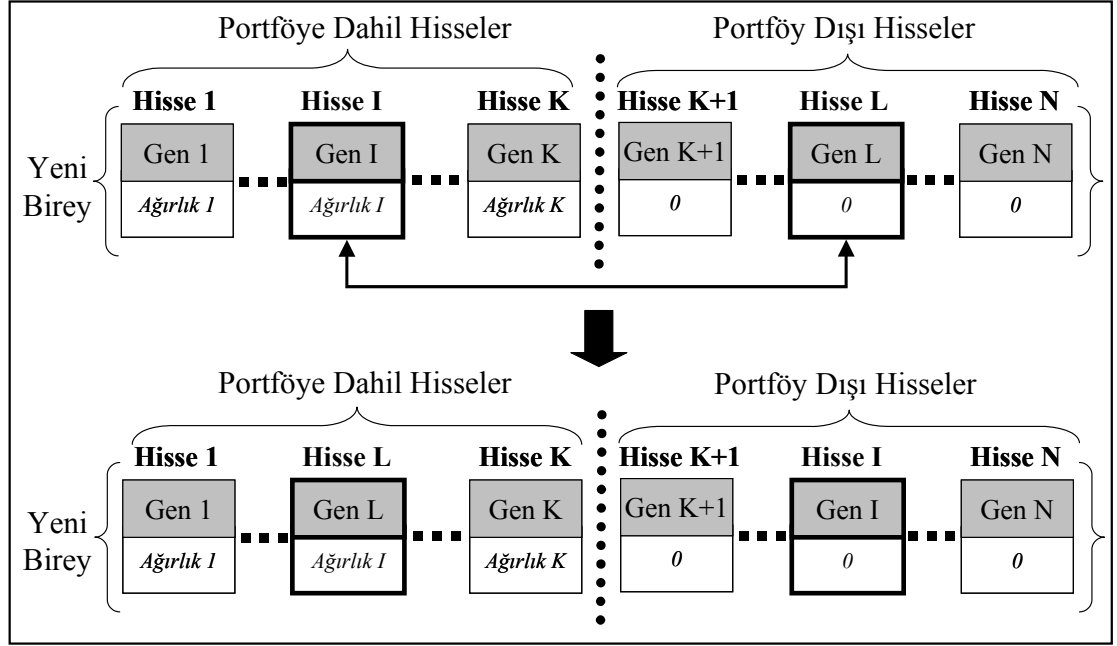
Şekil 3.5 – Kısıtlı Portföy Optimizasyonu Modelinde Çaprazlama İşlemi

Çaprazlama işlemi sonucunda elde edilen yeni portföy anne ve baba portföyü oluşturan hisse senetlerinin birleşim kümesinin K elemanlı bir alt kümesi olarak oluşturulmuş olur.

3.5.3.2. Mutasyon

Standart modelde kullanılan mutasyon işleminin sonucunda portföye dahil hisse senetlerinin ağırlıkları değişebilmesinin yanında portföye yeni hisse senetlerinin eklenebilmesi imkanı da sağlanmış oluyordu. Kısıtlı modelde de mutasyon işlemi sonucunda aynı sonuçları elde edebilmek için iki aşamalı bir mutasyon işlemi kullanılmıştır.

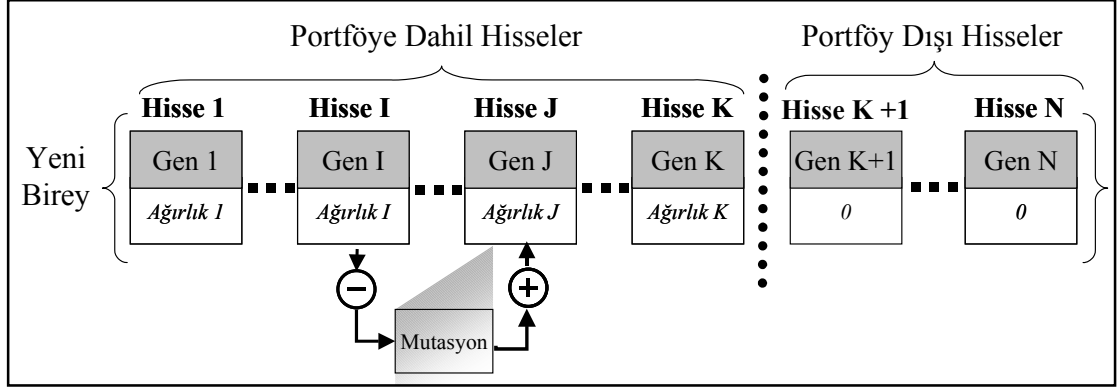
İlk aşamada portföye dahil hisse senetleri kümesinden en düşük ağırlığa sahip bir hisse senedi portföyden çıkarılarak yerine portföy dışından bir hisse senedi rasgele seçilerek portföye eklenir (Şekil 3.6). Böylece, performansı düşük bir hisse senedi portföyden çıkartılmış, yerine daha iyi performans göstermesi olası bir hisse senedi eklenmiş olur.



Şekil 3.6 - Kısıtlı Portföy Optimizasyon Modelinde Portföydeki En Düşük Ağırlığa Sahip Hisse Senedinin Portföy Dışı Bir Hisse Senedi ile Yer Değiştirmesi

Mutasyon işleminin ilk aşaması sırasında portföy kısıtları da dikkate alınmalıdır. Portföy kısıtlarının ihlal edilmemesi için portföyden çıkarılacak hisse senedinin en az ağırlığının sıfıra eşit olması ve portföye dahil edilecek hisse senedinin ise en çok ağırlığının sıfıra eşit olmaması gereklidir. Aksi takdirde portföyde olması zorunlu bir hisse senedi portföyden çıkarılmış ve/veya portföyde olmaması gereken bir hisse senedi portföye dahil edilmiş olur.

İkinci aşamada ise portföye dahil hisse senetleri kümesinden iki adet hisse senedi rasgele seçilerek, bu iki hisse senedi standart modeldeki mutasyon işlemine tabi tutulurlar. Yani en fazla mutasyon oranı kadar bir ağırlık kaynak hisse senedinden hedef hisse senedine aktarılır (Şekil 3.7). Bu aşamada portföye dahil hisse senetlerinin ağırlıkları değiştirilmiş olur.



Şekil 3.7 – Kısıtlı Portföy Optimizasyon Modelinde Portföye Dahil Hisseler Arası Mutasyon İşlemi

Mutasyon işleminde ikinci aşama her halükarda yapılmakla birlikte birinci aşama rasgele bir değişkene bağlı olarak belli bir olasılıkla yapılır. Bu rasgele değişkene bağlı olarak portföye dahil hisse senetleri değişmiş ya da değişmemiş olur. Böylece, mutasyonun birinci aşaması portföydeki hisse senetlerinin değiştirilmesine olanak sağlarken ikinci aşama da portföydeki hisse senetlerinin ağırlıklarının değiştirilebilmesini sağlar.

Standart modelde olduğu gibi çaprazlama ve mutasyon işlemlerinden sonra portföy ağırlıkları değişmiş oldukları için yeni ağırlıkların kısıtları karşılayacak şekilde düzeltilmesi ve toplamalarının 1'e eşit olacak şekilde ağırlıklarının belirlenmesi gereklidir. Ancak yeni belirlenen ağırlıkların kısıtları karşılayıp karşılamadığı da kontrol edilmelidir.

Öncelikle her hisse için belirlenen en az ağırlıklar ilk baştan itibaren bu hisse senetlerine ayrılmış olduğundan, genetik algoritmanın çalışması sırasında hisse senetlerinin ağırlıklarının o hisse senedi için belirlenmiş olan en az değer altına düşmesi mümkün değildir.

Portföye dahil hisse senetleri sadece mutasyon işlemiyle değiştiği ve bir değişim gerçekleştiğinde portföyden çıkarılan hisse senedinin yerine yeni bir hisse senedi portföye dahil edildiği için en fazla hisse senedi kısıtı da genetik algoritmanın çalışması boyunca sağlanmış olacaktır.

Portföye dahil hisse senetlerinin ağırlıklarının portföy için belirtilmiş olan en az genel hisse senedi ağırlık oranının üstünde olmasını garantilemek için bu değerin altındaki hisse senetlerinin ağırlıkları (dolayısıyla da negatif değere sahip ağırlıklar da) sıfıra eşitlenmektedir.

Portföydeki bir hisse senedinin ağırlığının o hisse senedi için belirlenmiş olan ağırlıktan çok olması durumunda ise önce bu hisse senedinin ağırlığı en çok değere eşitlenir ve ağırlıkların ölçeklendirildiği portföye dahil hisse senedi kümesinden çıkartılır ve geride kalan hisse senetlerinin ağırlıkları dağıtım için kalan ağırlık üzerinden yeniden hesaplanır. Bu işlem geride kalan hiçbir hisse senedinin en çok ağırlık değerini aşmaması sağlanıncaya kadar tekrar edilir. Sonuçta portföydeki her hisse senedinin ağırlığının en çok ağırlık değerini aşmaması sağlanmış ve bu değeri geçen ağırlıklar da portföye dahil diğer hisse senetlerine dağıtılmış olur.

Hisse senetlerinin ağırlıklarının bu şekilde hesaplanması ile hem kısıtlar sağlanmış olur, hem de portföydeki hisse senetlerinin toplam ağırlığının 1'e eşit olması garantilenmiş olur.

3.5.4. Yeni Nesle Aktarılacak Bireylerin Seçilmesi

Yeni nesle aktarılacak bireylerin seçilmesi için kullanılan yöntem ve kullanılan uygunluk fonksiyonu, bölüm 3.4.4.'de anlatılan standart modelde kullanılan yöntemle aynıdır. Yani, yeni oluşturulan portföylerden en iyi uygunluk değerine sahip N tanesi yeni nesli oluşturur. Ayrıca, bir önceki bölümde de anlatıldığı gibi genetik algoritma işlemleri sırasında kısıtlar dikkate alındığından, elde edilen aday bireyler ve dolayısıyla da her nesildeki popülasyonu oluşturan bireyler belirlenmiş olan kısıtları karşılarlar.

3.6. Portföy Optimizasyon Sonuçları

Yukarıda anlatılan yöntemlere göre elde edilen portföy optimizasyonları için sonuçlar iki şekilde değerlendirilmiştir. Öncelikle optimizasyon yapılan dönem için (1. 6 aylık dönem) elde edilen risk ve getiriler hesaplanarak etkin sınır bulunmuştur. Daha sonra belirlenmiş bu portföyün bir sonraki dönemde (2. 6 aylık dönem) yatırım

için kullanıldığı varsayılarak, bir sonraki dönemde elde edilen getiri hesaplanarak, endeksin getirisi ile karşılaştırılmıştır.

3.6.1. Standart Markowitz Modeline Göre Portföy Optimizasyonu

3.6.1.1. Genetik Algoritma İçin Kullanılan Parametreler

Standart Markowitz modeline göre optimizasyon için genetik algoritma parametreleri olarak populasyon büyüklüğü 10, en fazla mutasyon oranı da %5 olarak kullanılmıştır.


3.6.1.2. Genetik Algoritmanın Çalışmasının Test Edilmesi

Standart Markowitz modeline göre Genetik Algoritma ile elde edilen optimizasyon sonuçlarını karşılaştırmak için standart modelde çözüm elde edilmesine olanak sağlayan MS Excel Çözücü kullanılmıştır. Kullanılan test verileri ile elde edilen optimal portföyler karşılaştırıldığında Genetik Algoritmanın MS Excel Çözücü ile elde edilen sonuçlara en fazla on binde bir hata payıyla çoğu kez de aynen ulaştığı görülmüştür. Hata payının olduğu durumlarda ise genetik algoritmayı daha fazla nesil için çalıştırarak tam sonuç elde etmek de mümkündür.

Bu alternatif çözüm araçlarının performansları karşılaştırıldığında ise doğrudan çözüme ulaşma yöntemi olması açısından MS Excel Çözücünün çözüme çok daha hızlı ulaşabildiği, ancak Genetik Algoritmanın da çözüme ulaşmak için çok fazla zaman almadığı görülmüştür. Genetik algoritma kullanılan test ortamında 1 dakikalık 1 bir sürede optimal sonuca ulaşmıştır.

3.6.1.3. Etkin Sınır

Genetik Algoritma (ve MS Excel Çözücü) ile edilen optimal portföyler kümesinden elde edilen etkin sınır aşağıdaki şekilde gösterilmiştir.



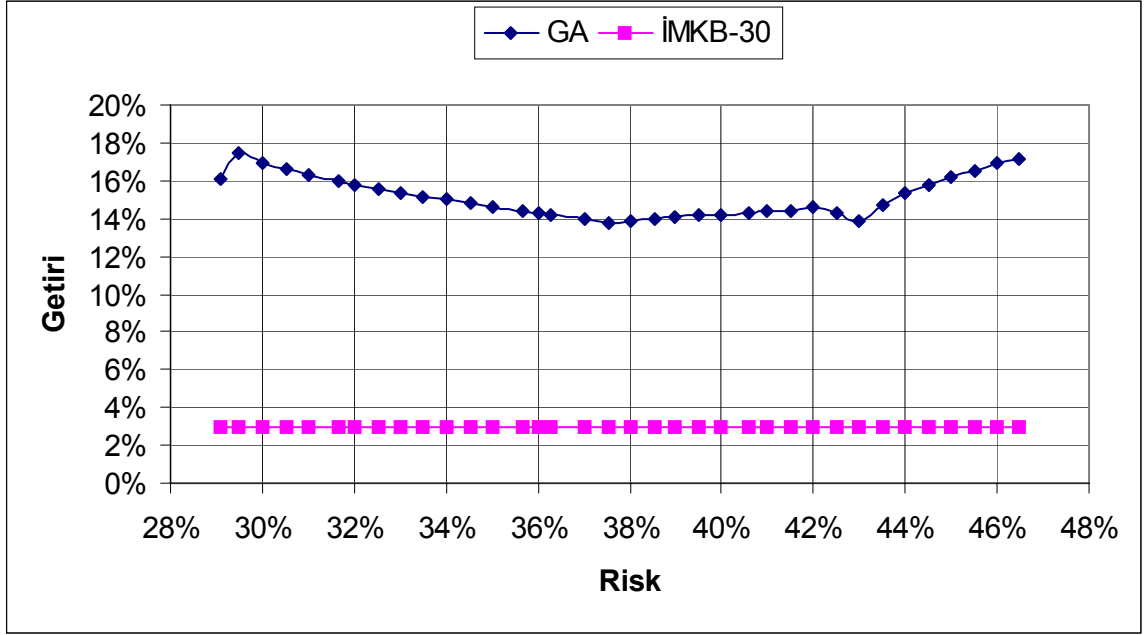
Şekil 3.8 – Standart Modele Göre Elde Edilmiş Etkin Sınır

Elde edilen etkin sınır grafiğine göre söz konusu dönem için (1. 6 aylık dönem) elde edilecek minimum riske sahip portföy %29,10 riske % 20 getiriye sahip portföydür. En yüksek getiriye sahip portföy ise doğal olarak en yüksek getirili tek hisse senedini (Arçelik) içeren %51 getiriye ve % 46 riske sahip portföydür.

Etkin sınır eğrisine baktığımız zaman minimum risk düzeyi göz önünde bulundurulduğunda İMKB’de yatırım yapmanın riskinin, nispeten tutarlı olan İMKB-30 hisse senetleri için bile çok yüksek olduğu ve doğal olarak piyasa riskinin yüksek olduğu açıkça görülmektedir. Bu açıdan Markowitz modeline göre teorik olarak sıfır riskli bir portföy oluşturmak mümkün olsa da pratikte İMKB’de böyle bir portföy oluşturmak mümkün değildir.

3.6.1.4. Elde Edilen Optimal Portföylerin 2. 6 Aylık Dönemdeki Getirisi

Elde edilen optimal portföylerin bir sonraki dönemde (2. 6 aylık dönem) yatırım için kullanılmış olduğunu varsayımıyla elde edilen getiri grafiği ve bu getirilerin İMKB-30 endeksinin getirisiyle karşılaştırılması aşağıdaki şekilde gösterilmiştir.



Şekil 3.9 –Etkin Portföylerin 2. Dönem Getirisi

Şekle bakıldığında her risk seviyesinde oluşturulabilecek portföyler için portföylerin getirisi İMKB-30 endeksinin getirisinden (%2,99) çok daha fazla olduğunu (%14-%17) görebiliriz. Bu durumda Genetik Algoritma portföy optimizasyonu modeline girdi olarak girilen 1. 6 aylık dönem verilerinden hesaplanmış olan beklenen getiri, risk ve kovaryans bilgilerinin 2. dönem verilerini tahmin konusunda başarılı olduğu sonucuna varabiliriz. Genetik algoritma optimizasyonu girdi olarak kullanılan değerlere göre yapıldığı için doğal olarak elde edilen portföylerin getiri performansı bu değerlerin isabetli oluşuna bağlıdır.

3.6.2. Kısıtlı Markowitz Modeline Göre Portföy Optimizasyonu

3.6.2.1. Genetik Algoritma İçin Kullanılan Parametreler

Genetik algoritma parametreleri olarak yine populasyon büyüklüğü 10, en fazla mutasyon oranı %5 olarak kullanılmıştır. Çözümüne ulaşma süresi standart modelde olduğu gibi kullanılan test ortamı için yaklaşık 1 dakika olarak gerçekleşmiştir. Kullanılan sistemin performansının çok yüksek olmadığı ve çözülen problemin karmaşıklığı göz önünde bulundurulduğunda genetik algoritmaların bu tür problemlerde sonuca ulaşmadaki gücü de görülmüş olur.

Geliştirilen genetik algoritma uygulamada herhangi bir kısıtlar kümesi için optimal portföylerin bulunması amacıyla kullanılabilir. Yapılan test çalışmalarında her türlü kısıt kombinasyonu için Genetik Algoritmanın başarılı bir şekilde sonuca ulaşabildiği görülmüştür. Bu sonucun gösterilebilmesi ve sonuçların tartışılabilmesi için rasgele belirlenmiş bir kısıtlar kümesinin kullanıldığı örnek bir çalışma yapılmıştır. Kısıtlı Markowitz modelinde örnek çalışma için kullanılan genel kısıtlar ve hisse senedi kısıtları aşağıdaki tabloda verilmiştir (Tablo 3.3).

Tablo 3.3 – Test İçin Kullanılan Örnek Portföy Kısıtları

Genel Portföy Kısıtları		
En Küçük Hisse Senedi Oranı	1%	
En Çok Hisse Adedi	7	
Hisse Senedi Kısıtları	En Az	En Fazla
AKBANK	0%	10%
ARÇELİK	0%	20%
DOGAN YAYIN	0%	0%
ENKA İNŞAAT	12%	24%
PETKİM	10%	25%
SABANCI	0%	0%
TURKCELL	0%	0%
TUPRAS	8%	25%

Yukarıdaki tabloda yer alan hisse senetlerinden en az değeri sıfırdan büyük olan hisse senetleri oluşturulan portföye mutlaka dahil olması istenen hisse senetlerini, en fazla değeri sıfır olan hisse senetleri de portföye dahil edilmemesi gereken hisse senetlerini göstermektedir.

3.6.2.2. Genetik Algoritmanın Çalışmasının Test Edilmesi

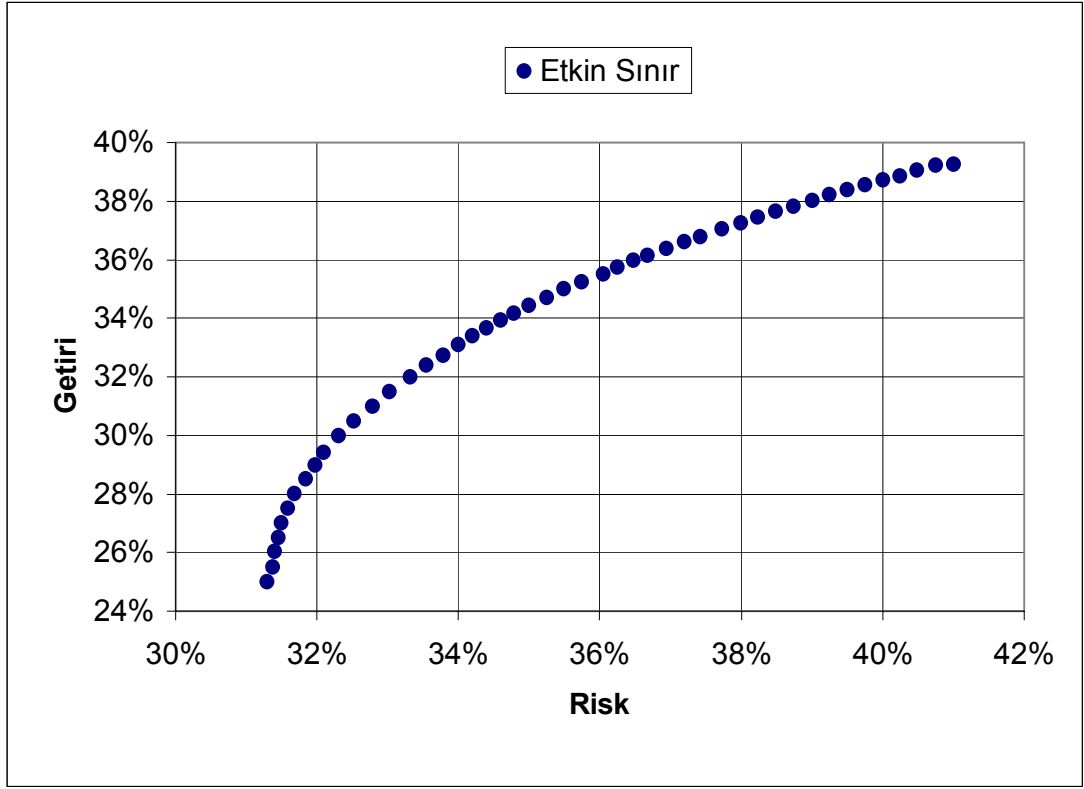
Kısıtlı Markowitz modelinde optimal portföylerin elde edilmesinde MS Excel Çözücü gibi klasik yöntemler sonuca ulaşamamaktadır. Genetik algoritmaların gücü ve etkinliği bu noktada ortaya çıkmaktadır. Her türlü kısıtlı portföy optimizasyon problemi uygun şekilde kodlandığı ve programlandığı takdirde genetik algoritmalar ile kolayca çözülebilmektedir.

Ancak, genetik algoritmalar rasgele aramaya dayalı buluşsal bir yöntem oldukları ve kısıtlı model için optimal sonuçları elde edebileceğimiz başka bir yöntem olmadığı için Genetik Algoritmanın kısıtlı model için elde ettiği sonuçların optimal olduğunu garanti etmek mümkün değildir.

Standart modelde ise Genetik Algoritmanın optimal sonuçlara ulaşabildiği gösterilmişti. Bu nedenle, Genetik Algoritmanın kısıtlı modelde de optimal sonuçlara ulaşabildiğini test edebilmek için, standart modelde elde edilen optimal portföy verileri Genetik Algoritma için kısıt olarak kullanılmış, elde edilen sonuçlar standart model sonuçlarıyla karşılaştırılmıştır. Bu testler sonucunda kısıtlı modele göre çalışan Genetik Algoritmanın da aynı sonuçlara ulaşabildiği, dolayısıyla da Genetik Algoritmanın kısıtlı modelde de optimal sonuca ulaşabilme becerisi görülmüştür.

3.6.2.3. Etkin Sınır

Genetik algoritmanın yukarıdaki tabloda gösterilen kısıtlarla çalıştırılması sonucunda elde edilen optimal portföyleri gösteren etkin sınır grafiği aşağıda gösterilmiştir (Şekil 3.10). Şekilde de görüldüğü gibi Genetik Algoritma kısıtlı modelde etkin sınır kümesi oluşturan getiri ve risk değerlerine sahip etkin portföyleri başarıyla bulabilmiştir.



Şekil 3.10 – Kısıtlı Modele Göre Elde Edilmiş Etkin Sınır

Kısıtlı modele göre elde edilen etkin sınır grafiğini standart modele göre elde edilen grafiklerle karşılaştırdığımızda modele eklenen kısıtların doğal olarak elde edilen portföylerin riskini artırırken beklenen getirilerini düşürdüğünü görmekteyiz.

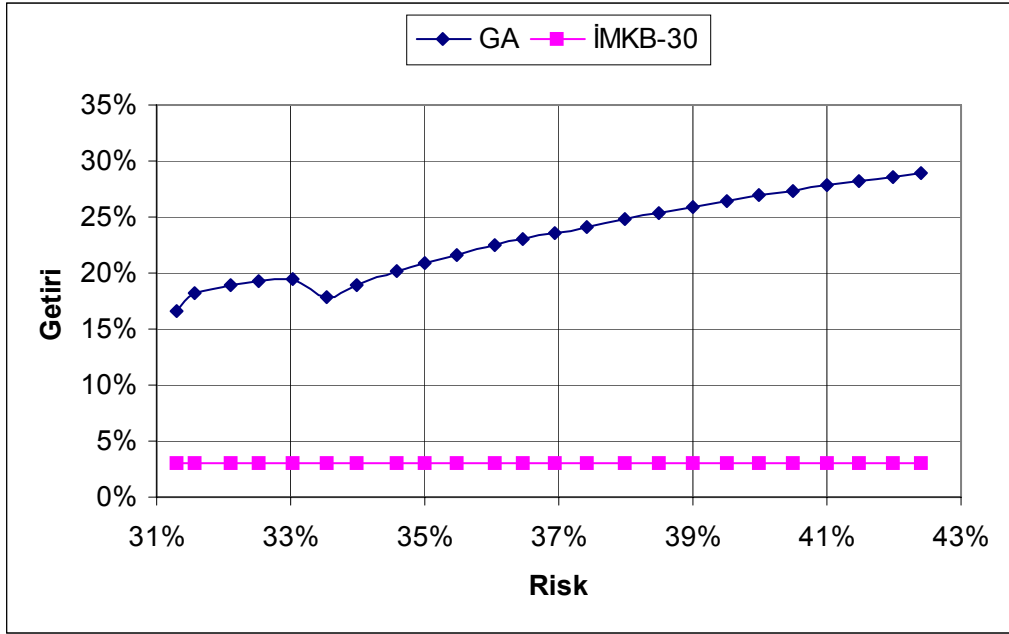
Her ne kadar geliştirilen genetik algoritmanın portföy optimizasyonu probleminin çözümünde ne kadar başarılı olduğu gösterilmiş olsa da, daha önce de bahsedildiği gibi kısıtlı modelde elde edilen portföylerin optimal olduğunu ispatlamak çok zordur. Ancak, elde edilen etkin sınır grafiği incelendiğinde risk arttıkça getirinin artması (veya getiri arttıkça riskin artması) ve etkin sınır üzerindeki tüm portföy kümelerinin değerlerinin birbirleriyle tutarlı olması elde edilen sonuçların optimal ya da optimale yakın olduğunu göstermektedir.

Ayrıca kısıtlı modele göre elde edilen etkin sınır grafiğinin, kısıtların çokluğuna rağmen standart model etkin sınır grafiğinin çok altında olmaması da sonuçların oldukça başarılı, muhtemelen de optimal olduğunu göstermektedir.

3.6.2.4. Elde Edilen Optimal Portföylerin 2. 6 Aylık Dönemdeki Getirisi

Kısıtlı modelde kullanılan genel kısıtlar oluşturulacak portföylerin daha kolay yönetilebilir olmasını hedeflerken, hisse kısıtları, kullanılan beklenen getiri ve risk değerleri dışında yatırımcının bir sonraki dönem için beklentilerini yansıtmaktadır. Bu kısıtların isabetli öngörülerini yansıtmaması durumunda elde edilecek portföylerin performansı da standart model portföylerinin performansından daha iyi olacaktır.

Kısıtlı modele göre elde edilen optimal portföylerin bir sonraki dönemde (2. 6 aylık dönem) yatırım için kullanılmış olduğunu varsayımıyla elde edilen getiri grafiği ve bu getirilerin İMKB-30 endeksinin getirisiyle karşılaştırılması aşağıdaki şekilde gösterilmiştir (Şekil 3.11).



Şekil 3.11 –Etkin Portföylerin 2. Dönem Getirisi

Şekli incelediğimizde kısıtlı modelden elde edilen portföylerin performanslarının, standart model portföylerinin performansından çok daha iyi olduğunu, dolayısıyla da kısıtlı modelde kullanılan kısıtların bir sonraki dönem için başarılı öngörülerini temsil ettiğini söyleyebiliriz.

SONUÇLAR VE DEĞERLENDİRMELER

Bir yatırım portföyü oluşturulurken, portföydeki menkul kıymet ağırlıklarının belirlenebilmesi sadece sezgisel olarak yapılamaz; modern, güçlü ve güvenilir optimizasyon tekniklerinin kullanımı gereklidir.

Bu çalışmada genetik algoritmaların optimal portföyün bulunması problemine uygulanabilirliği incelenmiştir. Bu amaçla, Modern Portföy Teorisi ve Genetik Algoritmaların teorik olarak ele alınmasından sonra, genetik algoritmalar ile İMKB-30 hisse senetlerinin verileri kullanılarak istenen kısıtları sağlayan optimal portföylerin bulunduğu bir örnek çalışma anlatılmıştır.

Bir önceki bölümde sonuçları verilmiş olan testler genetik algoritmaların, klasik yöntemlerle sonuç elde etmenin mümkün olmadığı en karmaşık portföy optimizasyon problemlerinde bile sonuca ulaşmada ne kadar hızlı ve başarılı olduğunu göstermiştir.

Genetik algoritmaların basitliği ve esnekliği çok önemli bir avantajdır. Bu açıdan problemdeki değişiklikler, önceki bölümlerde de gösterildiği gibi, gösterim, genetik işlemler ve uygunluk fonksiyonunda yapılacak küçük değişikliklerle genetik algoritmaya kolaylıkla yansıtılabilir. Örneğin, bu çalışmada geliştirilmiş olan genetik algortmada kullanılmış olan kısıtlı portföy optimizasyon modeli, alım satım maliyetleri gibi yeni kısıtların eklendiği daha gerçekçi bir portföy optimizasyon modeline dönüştürülebilir.

Bu çalışmada elde edilen sonuçlar ışığında, genetik algoritmaların, kullanılan veriler ve kısıtlar doğrultusunda optimal portföyleri bulma konusunda çok başarılı olduğu, hatta, bu konuda benzersiz olduğu söylenebilir. Ancak, doğal olarak elde edilen portföylerin performansı girdi olarak kullanılan veri ve kısıtlara bağlıdır. Kullanılan verilerin ve kısıtların doğru öngörülere dayanması genetik algoritmaların çalışması dışında bir olgu olup tamamen yatırımın yatırım sanatı kısmı olarak değerlendirilebilir.

Bu açıdan, eğer yatırım araçları konusunda doğru olduğuna inandığınız öngörülere ve verilere sahipseniz, genetik algoritmalar, uygun yatırım araçlarından oluşan optimal portföyün oluşturulmasında size yardımcı olarak yatırım hedeflerinize ulaşmanızı sağlayacaktır.

Aslında, bu çalışmada kullanılmış olan genetik algoritma modeline girdi olarak kullanılan verilerin elde edilmesinde de genetik algoritmalar kullanılabilir. Bu çalışmada amaç genetik algoritmaların portföy optimizasyonunda kullanılabilirliğini göstermek olduğundan bu konu ele alınmamıştır. Ancak, finansal verilerin tahmin edilmesi amacıyla genetik algoritmaların kullanılmasına literatürde pek çok başarılı örnek mevcuttur. Bu açıdan yapılan çalışma böyle bir genetik algoritma veri modeli ile entegre edilerek geliştirilebilir.

Sonuç olarak, genetik algoritmalar, pek çok alanda olduğu gibi, finans alanında da oldukça dikkat çekici faydalar sağlama potansiyeline sahip önemli bir hesaplama yöntemidir. Bu alanda yapılan araştırma ve çalışmalar oldukça ümit verici olmakla birlikte, bu çalışmalar henüz gelişme aşamasında olup, daha yapılabilecek pek çok şey mevcuttur.

KAYNAKÇA

Kitaplar

Brigham, Eugene F., Finansal Yönetimin Temelleri, Ankara Üniversitesi Yayınları, No: 212-213, Ankara, 1999

Ertuna, İ. Özer, *Yatırım ve Portföy Analizi (Bilgisayar Uygulama Örnekleriyle)*, Boğaziçi Üniversitesi, 1991

Goldberg, David E., *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley, USA, 1989

Holland, John H., *Adaptation in Natural and Artificial Systems*, MIT Press, Cambridge, 1992

Karan, Mehmet Baha, *Yatırım Analizi ve Portföy Yönetimi*, Gazi Kitabevi, Ankara, 2001

Karaşin, A. Gültekin, *Sermaye Piyasası Analizleri*, SPK, Yayın No: 4, Ankara, 1986

Kolb Robert W, Rodriguez Ricardo J, *Finansal Yönetim*, SPK , Yayın No: 35, İstanbul, Temmuz 1996

Lankhorst, Marc M., “Genetic algorithms in data analysis”, Online Resource : <http://www.ub.rug.nl/eldoc/dis/science/m.m.lankhorst/> (15.08.2003)

Markowitz, Harry M., *Mean-variance Analysis in Portfolio Choice and Capital Markets*, Oxford: Basil Blackwell, 1987

Markowitz, Harry M., *Portfolio Selection: Efficient Diversification of Investments*, Oxford: Basil Blackwell, 1992

Mitchell M., *An Introduction to Genetic Algorithms*, The MIT Press, Cambridge, MA, 1996

Özçam, Mustafa, *Varlık Fiyatlama Modelleri Aracılığıyla Dinamik Portföy Yönetimi*, SPK, Yayın No: 104, Ankara, Ekim1997

Makaleler

Beasley, D., Bull, D.R., Martin, R.R., *An Overview of Genetic Algorithms: Part 1, Fundamentals*, University Computing, Volume 15, Issue 2, February 1993, 58-69
ftp://ralph.cs.cf.ac.uk/pub/papers/GAs/ga_overview1.ps (01.06.2003)

Beasley, D., Bull, D.R., Martin, R.R., *An Overview of Genetic Algorithms: Part 2, Research Topics*, University Computing, Volume 15, Issue 4, 1993, s. 170-181
ftp://ralph.cs.cf.ac.uk/pub/papers/GAs/ga_overview2.ps (01.06.2003)

Busetti, Franco, *Metaheuristic Approaches To Realistic Portfolio Optimisation*, M.S. Thesis, June 2000, <http://www.geocities.com/francorbusetti/Metaheuristic.pdf> (01.06.2003)

Chang T. J., Meade N., Beasley J.E., Sharaiha Y. M., *Heuristics for Cardinality Constrained Portfolio Optimisation*, Computers & Operations Research, Vol. 27, Issue 13, 2000, s. 1271-1302

Chopra V K, Ziemba WT, *The Effect of Errors in Means, Variances and Covariances on Optimal Portfolio Choice*, Journal of Portfolio Management, Vol. 19, No. 2, Winter 1993, s. 6-11

Drake, Adrian E., Marks, Robert E., *Genetic algorithms in economics and finance: Forecasting stock market prices and foreign exchange- A review*, In Shu-Heng Chen (Ed.) *Genetic Algorithms and Genetic Programming in Computational Finance*, 2000, s. 29-54

Farmer J. D., Lo, A. W., *Frontiers of Finance : Evolution and Efficient Markets*, Proc. Natl. Acad. Sci. USA, Vol. 96, August 1999, s. 9991-9992

Feldman, Konrad and Treleven, Philip, *Intelligent systems in finance*, Applied Mathematical Finance, Vol 1, No. 2, December 1994, s. 195-207

Forrest, Stephanie, *Genetic Algorithms*, Computing Surveys Vol. 28:1, 1996, s. 77-80

Freedman R, DiGiorgio R, *A Comparison of Stochastic Search Heuristics for Portfolio Optimization*, Proceedings of Second International Conference On Artificial Intelligence Applications on Wall Street, Software Engineering Press, April, 1993, s. 149-151

Goldberg, David E., *Genetic and Evolutionary Algorithms come of age*, Communications of the ACM, Vol. 37, No. 3, March 1994, s. 113-119

Gupta, Francis; Fabozzi, Frank J.; Markowitz, Harry M., *The Legacy of Modern Portfolio Theory*, The Journal of Investing, Fall 2002, Volume 11, No. 3, s. 7 – 22

Haugh, Martin B., Lo, Andrew W., *Computational Challenges in Portfolio Management*, IEEE Computing in Science & Engineering, Vol. 3, No.3, 2001, s. 54-59

Holland, John H., *Genetic Algorithms*, Scientific American, 1992, s. 44-50

Jobst N. J., Horniman M. D., Lucas C. A., Mitra G., *Computational Aspects of Alternative Portfolio Selection Models in the Presence of Discrete Asset Choice Constraints*, Quantitative Finance, Vol. 1, No. 5, September 2001, s. 489-501

Küçükkocaoğlu, Güray, *Optimal Portföyün Seçimi ve İMKB Ulusal-30 Endeksi Üzerinde Bir Uygulama*, <http://www.baskent.edu.tr/~gurayk/kisiseloptimization.pdf> (01.06.2003)

Leinweber, David J. and Arnott, Robert D., *Quantitative and computational innovation in investment management*, The Journal of Portfolio Management, Vol.21, No. 2, Winter 1995, s. 8-15

Markowitz, Harry M., *Portfolio Selection*, Journal of Finance, 7 (1), 1952, s. 77-91

Michalewicz, Z., Heuristic Methods for Evolutionary Computation Techniques, Journal of Heuristics, Vol.1, No.2, 1995, s.177-206

Pereira Robert, *Genetic Algorithm Optimisation for Finance and Investment*, Latrobe University School of Business Discussion Papers, 2000
<http://www.latrobe.edu.au/business/research/dps/downloads/dps00/a00-02.pdf>
(01.06.2003)

Schyns, M., Crama, Y., *Simulated Annealing for Complex Portfolio Selection Problems*, European Journal of Operational Research, Volume 150, Issue 3, November 2003, s. 546-571

İnternet Adresleri

Beasley, David, AI FAQ/genetic, <http://www.faqs.org/faqs/ai-faq/genetic/>
(15.08.2003)

Heuristics and Artificial Intelligence in Finance and Investment,
<http://www.geocities.com/francorbusetti/> (15.08.2003)

İstanbul Menkul Kıymetler Borsası, <http://www.imkb.gov.tr/> (15.08.2003)

MS Excel Solver, www.solver.com (15.08.2003)

Software: Genetic Algorithms, <http://ffusco.altervista.org/software/genetic/>
(15.08.2003)

The Genetic Algorithms Archive, <http://www.aic.nrl.navy.mil/galist/> (15.08.2003)

ÖZET

Finansal piyasalarda yatırım kararları önemli ölçüde belirsizlik içermekte ve yatırımlardan beklenen getiri açısından önemli bir risk söz konusu olmaktadır. Belirsizlik ortamında sürekli dalgalanmakta olan finansal piyasalarda bireysel ve kurumsal yatırımcıların güvencesi çeşitlendirme ile portföy oluşturulmasıdır.

Geleneksel portföy yönetiminde her bir menkul kıymet tek tek ele alınmış ve riskin birden fazla menkul kıymete dağıtılması amaçlanmıştır. Modern Portföy Teorisi (MPT) ise yatırım bilimine yeni bir bakış açısı getirerek, menkul kıymetleri tek tek ele almak yerine piyasayı bir bütün olarak ele alan sistematik bir yatırım yaklaşımı ortaya koymuştur.

Genetik algoritmalar, insanın karar alma yeteneğinin bilgisayarlar kullanılarak benzetilmesine dayanan bir tür yapay zeka tekniğidir. Genetik algoritmalar zor problemleri, bir başlangıç aday çözüm kümesinin tekrarlanan bir süreç kullanılarak evrimleştirilmesi yoluyla, çözüm uzayındaki daha iyi çözümlere ulaşmaya çalışarak çözmeyi amaçlar.

Bu çalışmada genetik algoritmaların kısıtlı portföy optimizasyon problemine uygulanabilirliği incelenmiştir. Bu amaçla, Modern Portföy Teorisi ve Genetik Algoritmaların teorik olarak ele alınmasından sonra, genetik algoritmalar ile İMKB-30 hisse senetlerinin verileri kullanılarak istenen kısıtları sağlayan optimal portföylerin bulunduğu bir örnek çalışma anlatılmıştır.

ABSTRACT

Due to the inherent uncertainty of the investment decisions in financial markets, there is considerable risk regarding the expected returns. In such volatile, ever changing financial markets the assurance for individual and institutional investors is diversification and portfolio construction.

Traditional portfolio management was focused on analyzing and selecting individual assets with the aim of distributing risk among a number of assets. Modern portfolio theory brought a new systematic approach to investment with a focus on the whole market rather than the individual assets.

Genetic algorithms is an artificial intelligence technique based on the simulation of human decision process by using computers. Genetic algorithms are used to solve hard problems by evolving an initial population through a repeated process with the aim of reaching better solutions in the solution space.

In this thesis, we investigate the applicability of genetic algorithms to the problem of constrained portfolio optimization. After a theoretical overview of Modern Portfolio Theory and Genetic Algorithms, a case study of finding optimal portfolios with satisfying the requested constraints using the İMKB-30 stocks daily return data is presented.