



A new selection strategy for multi objective genetic algorithm: MultiMoora Rank selection

Alparslan Serhat Demir^{1*}, Mine Büşra Gelen Mert²

¹Sakarya University, Engineering Faculty, Industrial Engineering Department, 54050, Sakarya, Turkey

²Sakarya University, Institute of Natural Sciences, Industrial Engineering Program, 54050, Sakarya, Turkey

Highlights:

- A new selection strategy for use in multi objective genetic algorithm was developed
- Proposed and classical selection strategies were compared on flow shop scheduling problems
- The proposed selection strategy yielded better results than classical strategies

Keywords:

- Multi objective optimization
- flow shop scheduling
- genetic algorithm
- MultiMoora
- selection methods

Article Info:

Research Article
Received: 08.04.2020
Accepted: 27.11.2021

DOI:

10.17341/gazimmfd.716852

Acknowledgement:

The study was supported by the Scientific Research Project Commission of SAU (Project no: 2017-50-01-073)

Correspondence:

Author: Alparslan Serhat Demir
e-mail: alparslanserhat@sakarya.edu.tr
phone: +90 264 295 5675

Graphical/Tabular Abstract

In the study, MultiMoora Rank Selection (MMRS) strategy is proposed in order to increase the multi objective evaluation performance in the selection step of the genetic algorithm by using the MultiMoora method. Roulette Wheel Selection, Linear Rank Selection, Tournament Selection strategies of genetic algorithm and the proposed method have been applied on multi objective flow shop scheduling problems. The minimum fitness function $f(x)_{min}$ values obtained with applications over 30 were statistically analyzed with the Paired-T test. As a result of the analysis, the superiority of the developed selection strategy to the other selection strategies within the framework of the averages of the $f(x)_{min}$ values μ and test possibilities p is shown in Table A.

Table A. The comparison of the results obtained by the multiple applications of MultiMoora Rank Selection with the selection methods of genetic algorithms with respect to their p values

Problem Size		μ		Roulette Wheel Selection		Linear Rank Selection		Tournament Selection	
		μ	p	μ	p	μ	p	μ	p
15	MultiMoora Rank Selection	143.596	0	144.251	0	144.419	0.02	143.956	
25		229.243	0	235.698	0	236.410	0.004	233.043	
35		326.218	0	330.490	0	332.503	0.036	328.187	
50		457.889	0	464.366	0	465.288	0.001	460.446	

Purpose: In the study, it is aimed to develop a selection method that increases the algorithm performance by providing multi-criteria analysis opportunity in the selection step of the genetic algorithm.

Theory and Methods:

The MultiMoora Rank Selection (MMRS) selection strategy has been developed to be used in the selection step where the chromosome pair to be applied crossover in the genetic algorithm is determined by using the MultiMoora method, which is one of the multi criteria decision making methods.

Results:

The success of the proposed approach; multi objective flow shop scheduling problems, consisting of 15, 25, 35 and 50 jobs, aimed at minimizing the criteria of the maximum completion time, average flowtime, maximum tardiness, average tardiness and number of late jobs, were compared by comparing the genetic algorithm and the classical three selection strategy. The statistical analysis performed after multiple replications has demonstrated the superiority of the proposed approach over classical methods.

Conclusion:

It is seen that MMRS selection strategy developed by using MultiMoora method provides more decrease in minimum fitness function $f(x)_{min}$ values in multi-repeat applications on multi objective flow shop scheduling problems. Statistical analysis with Paired-T test showed that there is a significant difference between MMRS and genetic algorithm Roulette Wheel Selection, Linear Rank Selection, Tournament Selection strategies and MMRS reached lower $f(x)_{min}$ values.



Çok amaçlı genetik algoritma için yeni bir seçim stratejisi önerisi: MultiMoora Rank seçimi

Alparslan Serhat Demir^{1*}, Mine Büşra Gelen Mert²

¹Sakarya Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, 54050, Sakarya, Türkiye

²Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Programı, 54050, Sakarya, Türkiye

Ö N E Ç İ K A N L A R

- Çok amaçlı genetik algoritma için MultiMoora metodunun entegre edilmesi ile yeni bir seçim stratejisi önerilmiştir
- Önerilen yaklaşım ile klasik seçim stratejileri akış tipi çizelgeleme problemleri üzerinde karşılaştırılmıştır
- Önerilen seçim stratejisinin klasik stratejilerden daha başarılı olduğu istatistiksel analiz ile ispatlanmıştır

Makale Bilgileri

Araştırma Makalesi
Geliş: 08.04.2020
Kabul: 27.11.2021

DOI:

10.17341/gazimmfd.716852

Anahtar Kelimeler:

Çok amaçlı optimizasyon,
akış tipi çizelgeleme,
genetik algoritma,
MultiMoora,
seçim metotları

ÖZ

Genetik algoritmalar çözümü zor problemler için kabul edilebilir süre ve kalitede çözüm bulan metasezgisel bir tekniktir. Genetik algoritma uygulamalarında tercih edilen seçim stratejileri, çözüm kalitesini önemli ölçüde etkilemektedir. Bu çalışmada, Çok Amaçlı Genetik Algoritma (ÇAGA)'nın performansını arttırmak amacıyla yeni bir seçim stratejisi olarak, çok kriterli karar verme yöntemlerinden biri olan MultiMoora metoduna dayalı MultiMoora Rank Selection (MMRS) geliştirilmiştir. Geliştirilen metodun performansı çok amaçlı akış tipi çizelgeleme problemlerinde test edilmiştir. MultiMoora Rank Selection ile elde edilen sonuçlar, genetik algoritmada yaygın olarak kullanılan Rulet Tekerleği Seçimi, Lineer Rank Seçimi ve Turnuva Seçimi metotlarının aynı problem üzerindeki sonuçları ile karşılaştırılarak değerlendirilmiştir. Elde edilen sonuçlar, önerilen MultiMoora Rank Selection metodunun karşılaştırılan diğer metotlara üstünlük sağladığını göstermektedir.

A new selection strategy for multi objective genetic algorithm: MultiMoora Rank selection

H I G H L I G H T S

- A new selection strategy has been proposed for the multi objective genetic algorithm by integrating the MultiMoora method
- The classical approach strategies were compared with the proposed approach on flow shop scheduling problems.
- It has been proved by statistical analysis that the proposed selection strategy is more successful than classical strategies

Article Info

Research Article
Received: 08.04.2020
Accepted: 27.11.2021

DOI:

10.17341/gazimmfd.716852

Keywords:

Multi objective optimization,
flow shop scheduling,
genetic algorithm,
MultiMoora,
selection methods

ABSTRACT

Genetic algorithms are metaheuristic methods that provide satisfactory solutions for complex problems within acceptable time periods. In genetic algorithms, the selection strategy considerably affects the quality of the solution. In this study, MultiMoora Rank Selection (MMRS) based on MultiMoora method, which is one of the multi criteria decision making methods, has been developed as a new selection strategy to increase the performance of Multi Objective Genetic Algorithm (MOGA). The performance of the method was tested using flow shop scheduling problems. The results obtained with the MultiMoora Rank Selection were evaluated by comparing with the results obtained using the same problem with the selection methods that are widely used for genetic algorithms, such as the Roulette Wheel Selection, Linear Rank Selection and Tournament Selection methods. The results showed that the proposed MultiMoora Rank Selection method outperformed the compared methods.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *alparslanserhat@sakarya.edu.tr, minebusra92@gmail.com /

Tel: +90 264 295 5675

1. GİRİŞ (INTRODUCTION)

Günümüzde çözüm uzayı geniş NP-Hard sınıfında yer alan problemlerin çözümünde dal-sınır algoritması gibi yaklaşık olmayan çözüm yöntemlerinin çok fazla çözüm süresi gerektirmesi sebebiyle, kabul edilebilir sürelerde yaklaşık çözümler sağlayan metasezgisel yöntemler tercih edilmektedir [1]. Genetik algoritma (GA); NP-Hard sınıfı, çözüm uzayı geniş, klasik çözüm yöntemleri ile çözülmesi zor olan bu problemlere çözüm elde etmek amacıyla kullanılan metasezgisel yöntemlerden biridir [2]. Genetik algoritma iyi olan çözümlere ait bilgilerin sonraki nesillere aktararak, çözüm kalitesini arttırmaya çalışan bir yapıya sahiptir. Genetik algoritmada çözüm alternatifleri genlerden oluşan kromozomlar halinde kodlanır ve başlangıç popülasyonu oluşturulur. Başlangıç popülasyonundaki bireylerden başlanarak genetik algoritma işlem basamakları uygulanır ve yaklaşık en iyi çözümün elde edilmesi hedeflenir. Genetik algoritmanın temel işlem basamakları seçim, çaprazlama, mutasyon ve eleme adımlarından oluşmaktadır. Seçim, çaprazlama, mutasyon ve eleme işlemlerinde çeşitli metotlar kullanılmaktadır. Rulet Tekerleği Seçimi, Lineer Rank Seçimi ve Turnuva Seçimi genetik algoritmalarda yaygın olarak kullanılan seçim stratejilerindedir. Uygulamada hangi seçim stratejisinin tercih edildiği genetik algoritmanın problem üzerindeki çalışma performansını büyük ölçüde etkilemektedir.

Literatürde evrimsel bir yöntem olan genetik algoritmanın seçim stratejilerinin ele alındığı birçok çalışma bulunmaktadır. Bu çalışmaların başlıcalarından biri olan Goldberg ve Deb tarafından yapılan çalışmada diferansiyel denklem yaklaşımları ile Orantılı Seçim, Lineer Rank Seçimi, Turnuva Seçimi ve Genitor seçim stratejileri karşılaştırılmıştır [3]. Chakraborty vd. tarafından yapılan başka bir çalışmada Lineer Rank Seçimi, İkili Turnuva Seçimi, Genitor, CHC Algoritmasında Seçim ve Orantılı Seçim yöntemleri geliştirilen bir Markov Zinciri çerçevesi ile kıyaslanmıştır [4]. Chakraborty M. ve Chakraborty U. K. tarafından Lineer Rank Seçimi ve İkili Turnuva Seçimi analiz edilmiş, yapılan simülasyonlar ile metotlar değerlendirilmiştir [5]. Alfonso vd. tarafından Orantılı Seçim, Sıralamaya Dayalı Seçim ve Turnuva Seçimi metotları çoklu test fonksiyonları üzerinde test edilmiştir [6]. Wiese ve Goodwin, iyi genetik özelliklerin korunmasını sağlayan yeni bir ara seçim stratejisi olan En İyi Üreme (Keep-best reproduction) (KBR) seçim stratejisini geliştirmiştir [7]. Wiese vd. Gezgin Satıcı Problemleri üzerinde yapılan uygulamalar ile klasik seçim yapan GA ve KBR kullanan GA yöntemlerini kıyaslamıştır [8]. Andrade vd. tarafından Ortogonal seçim yöntemi, Rulet Tekerleği Seçimi, Turnuva Seçimi, Determinist Örneklem, Stokastik Kalan Örneklem seçim metotları ve çeşitli çaprazlama metotlarının kombinasyonları Çok Protokollü Etiket Değiştirme problemi üzerinde uygulanmış ve kombinasyonların başarıları değerlendirilmiştir [9]. Xie ve Zhang, evrimsel algoritma uygulamalarında Turnuva Seçimi'nin evrim sürecindeki dinamikleri algılayabilmesi

için seçim basıncının otomatik bir şekilde ayarlanabilmesini hedefleyerek Turnuva Seçimi'ne Uygunluk Sıralaması Dağılımı'nın entegre edilmesi ile yeni bir yaklaşım önermiştir [10]. Chudasama vd. Rulet Tekerleği Seçimi, Turnuva Seçimi ve Elitizm seçim stratejilerini Gezgin Satıcı Problemi üzerinde uygulayarak karşılaştırmıştır [11]. Razali ve Geraghty Turnuva Seçimi, Orantılı Rulet Tekerleği Seçimi, Sıralı Rulet Tekerleği Seçimi ile Gezgin Satıcı Problemi üzerindeki farklı uygulamalar ile genetik algoritmanın performansını değerlendirmiştir [12]. Kumar tarafından yeni bir seçim stratejisi olarak Önerilen Tavlama Seçimi yöntemi geliştirilmiş, geliştirilen yöntemin Rulet Tekerleği Seçimi ve Rank Seçimi ile kıyaslanarak performansı değerlendirilmiştir [13].


Alabsi ve Naoum tarafından Rulet Tekerleği Seçimi, Sıralama, Stokastik, Elitizm, Turnuva Seçimi yöntemleri ile birçok çaprazlama operatörünün farklı kombinasyonlarından yararlanılarak genetik algoritmanın performansı, saldırı destek sistemleri üzerinde yapılan uygulamalar ile değerlendirilmiştir [14]. Jebari ve Madiafi birden fazla seçim metodu arasında tercih şansı sağlayan yeni bir kombine seçim prosedürü önermiş ve önerilen bu seçim prosedürünü genetik algoritmaların yaygın olarak kullanılan altı seçim metodu ile karşılaştırmıştır [15]. Oladele ve Sadiku tarafından Rulet Tekerleği Seçimi, Turnuva Seçimi, Sıralama ve Ölçeklendirme Seçimi yöntemlerinin genetik algoritmanın performansı üzerindeki etkisi Çok Amaçlı Ağ Tasarımı Problemi üzerinde uygulama yapılarak değerlendirilmiştir [16]. Nazmul ve Chetty deterministik ve stokastik seçim metotlarının avantajlarını bir arada sağlayan, kromozomlar arasında rassal olmayan eşleşmeye yönlendiren yeni bir seçim metodu önermiş, yeni yaklaşımın uygulandığı algoritmanın performansını İkili Turnuva Seçimi ve Rulet Tekerleği Seçimi'nin kullandığı algoritmalar ile kıyaslayarak değerlendirmiştir [17]. Mayilvaganan ve Geethamani, yeni bir seçim metodu önermiş, yeni yaklaşımı Rulet Tekerleği Seçimi ve Kararlı Durum Seçim Metodu ile kanserli hücrelerin DNA nükleotid sırası kullanılarak çeşitli boyutlardaki problemler üzerinde karşılaştırmıştır [18]. Long vd. tarafından çok amaçlı genetik algoritma için kesikli bir seçim prosedürü geliştirilmiş, önerilen yaklaşımın kullanıldığı çok amaçlı genetik algoritma, literatürde yer alan çeşitli çok amaçlı algoritmalarla kıyaslanarak değerlendirilmiştir [19]. Anand vd. tarafından Alternis seçim metodu önerilmiş ve önerilen metot genetik algoritmanın Rulet Tekerleği Seçimi, Turnuva Seçimi, Rank Seçimi yöntemleri ile performans yönünden karşılaştırılmıştır [20]. Shukla vd. tarafından genetik algoritmanın seçim metotlarının değerlendirildiği çalışmalar incelenmiş ve incelenen çalışmalar ışığında Turnuva Seçimi'nin, Sıralama Seçimi ve Orantılı Rulet Tekerleği Seçimi'nden daha yüksek performansla sahip olduğu tespit edilmiştir [21]. Pandey, genetik algoritmanın Rulet Tekerleği Seçimi, Sıralama Seçimi, Turnuva Seçimi stratejilerini Gezgin Satıcı Problemi üzerinde uygulamış ve bu problemde hangi seçim metodunun daha iyi sonuç sağladığını araştırmıştır [22]. Irfianti vd. tarafından Rulet

Tekerleği Seçimi, Turnuva Seçimi ve Stokastik Evrensel Örnekleme metotlarının performansları arazi uygunluğu problemi için değerlendirilmiştir [23]. Abd Rahman vd. yeni bir seçim metodu olarak Rulet-Turnuva Seçimi'ni önermiş, önerilen seçim stratejisini bir karides diyet formülasyonu problemi üzerinde gerçek bir kodlama kullanılarak Rulet Tekerleği Seçimi ve Kraliçe Arı Seçimi yöntemleri ile karşılaştırmıştır [24]. Beg ve Islam genetik algoritmanın seçim ve çaprazlama gibi çeşitli adımları için metotlar geliştirerek Yeni Çaprazlama, Seçim ve Kümeleme için Sağlık Kontrollü Genetik Algoritma (Genetic Algorithm with Novel Crossover, Selection and Health Check for Clustering) (GCS) metodunu önermiştir [25]. Algoritmanın performansı beş farklı teknikle karşılaştırılarak değerlendirilmiştir. Alkhayri vd. tarafından Kümeleme Seçim Metodu adı verilen yeni bir seçim metodu önerilmiş, metodun performansı Gezgin Satıcı Problemi üzerinde genetik algoritmanın klasik seçim metotları ile karşılaştırılarak değerlendirilmiştir [26]. Saini tarafından Genetik algoritmanın Boltzmann Seçimi, Rank Seçimi, Rulet Tekerleği Seçimi, Turnuva Seçimi stratejileri incelenmiştir [27]. Yadav ve Sohal genetik algoritmanın Rulet Tekerleği Seçimi, Rank Seçimi, Turnuva Seçimi, Kararlı Durum Seçimi, Boltzmann Seçimi ve Elitizm seçim stratejilerini incelemiştir [28]. Chehouri vd. tarafından dört aşamadan oluşan ve iki farklı versiyonu olan K-Means Genetik Algoritma Seçim Prosesi önerilmiş, önerilen seçim stratejisinin kullanıldığı algoritmanın performansı test problemleri üzerinde yapılan uygulamalar ile farklı algoritmalarla karşılaştırılmıştır [29].

Literatürde seçim stratejilerinin analizi ve geliştirilmesine yönelik yer alan çalışmalarda, seçim stratejilerinin kullanım sıklığını belirten grafik Şekil 1'de gösterilmiştir. Şekil 1'deki grafik incelendiğinde, çalışmalarda Rulet Tekerleği Seçimi, Turnuva Seçimi ve Rank Seçimi'nin öne çıktığı görülmektedir. Ayrıca birçok çalışmada genetik algoritmanın seçim adımında performansın artırılmasına

yönelik olarak yeni seçim stratejilerinin önerildiği görülmektedir. Bu çalışmaların yanı sıra Kalınlı ve Aksu tarafından farklı bireylerin hesaplanan kalite değerleri ve bireylerin aynı pozisyonlarında bulunan gen değerlerinin diğer bireylerde ne kadar tekrarlandığı temel alınarak, yüksek kalitede olan genlerin belirleyici özellikte olmasının hedeflendiği baskın gen seçimi operatörü önerilmiştir [30]. Bu operatörün genetik algoritma adımı olarak uygulanması ile algoritmanın performansında artış sağlanması ve yerel optimum noktalara takılma durumunun önüne geçilmesi hedeflenmiştir.

Bu çalışmada çok amaçlı genetik algoritmalar uygulanırken çaprazlanacak kromozom çiftlerinin seçimi aşamasında, birden fazla kriterin bir arada değerlendirildiği hibrit bir seçim metodu olan MultiMoora Rank Selection (MMRS) seçim stratejisi önerilmiştir. Önerilen metotta MOORA metodu (Oran Metodu ve Referans Noktası Yaklaşımı) ve Tam Çarpım Formu metotları ile elde edilen sonuçlar Sıra Baskınlık Teorisi ile karşılaştırılmakta, böylece seçim aşamasında birden fazla kriterin birlikte değerlendirilmesi sağlanmaktadır. Önerilen metotta MultiMoora kullanmanın başlıca sebebi; diğer çok kriterli karar verme teknikleri çoğunlukla tek bir sıralama elde ederken, MultiMoora'nın üç alt metot ile üç sıralama elde etmesi ve bundan sıra baskınlık teorisi ile tek bir sonuç çıkarmasıdır. Ayrıca tekniğin ana bileşeni olan MOORA metodu AHP, TOPSİS, VİKOR, vb. diğer bir kısım çok amaçlı karar verme teknikleri ile karşılaştırılmış ve hesaplama süresi, sadelik, matematiksel hesaplamalar, kararlılık ve bilgi türü açısından yapılan karşılaştırmada metodun üstünlüğü vurgulanmıştır [31]. Çalışmada önerilen metodun çok amaçlı genetik algoritmanın çözüm kalitesi üzerindeki etkisi, yaygın olarak kullanılan Rulet Tekerleği, Lineer Rank ve Turnuva seçim stratejileri ile 10 makinenin kullanıldığı 15, 25, 35 ve 50 iş sayılarından oluşan akış tipi çizelgeleme problemleri üzerinde karşılaştırılarak test edilmiştir. Önerilen yaklaşım ile mevcut seçim stratejilerinin kıyaslanmasında, performans



Şekil 1. Literatürde yer alan çalışmalarda seçim stratejilerinin ele alınma sıklığı
(Frequency of selection strategies in studies in the literature)

kriterleri olarak elde edilen jenerasyonların kalitesini gösteren ortalama uygunluk ve minimum uygunluk fonksiyonu değerleri kullanılmıştır. Yine aynı yazarlar tarafından yapılan başka bir çalışmada turnuva seçim stratejisine sahip çok amaçlı genetik algoritmaya MultiMoora metodu entegre edilerek (MBGA- Genetik Algoritma Tabanlı MultiMoora) amaç fonksiyonu en iyi olan belirli sayıda bireyin değerlendirilmesi fikri temel alınmıştır [32]. Bu çalışmada ise MultiMoora metodunun, genetik algoritmanın seçim adımı olarak uygulanması ve lineer rank seçimine benzer kromozom sıralama prensibinin temel alınması ile daha etkin bir seçim operatörü oluşturulması hedeflenmiştir.

Çalışmanın ilk bölümünde problemin konusu ve literatürde bu alanda yapılan çalışmalar incelenmiştir. Çalışmanın ikinci bölümünde genetik algoritmanın klasik seçim stratejileri, MultiMoora metodu ve önerilen MultiMoora Rank Selection seçim stratejisi tanıtılmıştır. Çalışmanın üçüncü bölümünde akış tipi çizelgeleme problemleri üzerinde yapılan uygulamalar, elde edilen sonuçlar ve seçim stratejilerinin istatistiksel olarak analizi yer almaktadır. Çalışmanın son bölümünde yapılan uygulama değerlendirilmiş ve ileride yapılacak çalışmalara yönelik önerilerde bulunulmuştur.

2. METODOLOJİ (METHODOLOGY)

2.1. Genetik Algoritmalar ve Seçim Metotları (Genetic Algorithms and Selection Methods)

Genetik algoritmalar Charles Darwin'in en iyi olanın varlığını sürdürmesini temel alan evrim teorisinden esinlenilerek oluşturulmuş evrimsel bir algoritmadır [33]. Ortaya çıkışı 1975 yılına dayanan metot, ilk kez John Holland tarafından "Adaption in Natural and Artificial

Systems" isimli çalışma ile önerilmiştir [34], [35]. Genetik algoritmalar, Goldberg tarafından yapılan çalışmalar ile bilinen meta sezgisel metotlardan biri haline gelmiştir [36]. Metot, genel yapısı gereği kromozom adı verilen başlangıç çözümlerine seçim, çaprazlama, mutasyon ve replacement işlemlerinin uygulanması ile her jenerasyonda daha iyi bireyler elde etmeye ve kötü bireyleri elemeye çalışır.

Zamanla birden fazla ölçütün bir arada değerlendirilmesi ihtiyacı ile çok amaçlı genetik algoritmalar ortaya çıkmıştır. İlk kez Schaffer tarafından önerilmiş ve Vektör Değerlendirilmiş Genetik Algoritmalar olarak adlandırılmıştır [37]. Genetik algoritmaların çok amaçlı olarak uygulanması sırasında, probleme ait amaç fonksiyonu birden fazla amacın optimizasyonuna yönelik ortak bir fonksiyon şeklinde oluşturulabilmektedir. Bu fonksiyon, uygulamada ele alınan problemin yapısına göre her bir amaca ağırlık katsayıları verilerek minimize veya maksimize edilebilmektedir. Çalışmada kullanılan bazı sembollere ait açıklamalar Tablo 1'de yer almaktadır.

2.1.1. Rulet tekerleği seçimi (Roulette wheel selection)

Genetik algoritmaların ilk seçim metodu Holland tarafından 1975 yılında önerilen Rulet Tekerleği Seçimi'dir [24]. Rulet Tekerleği Seçimi ile kromozomların uygunluk fonksiyonu değerlerine göre işlem yapılmaktadır. Uygunluk değeri hesaplanan kromozomlara, uygunluk değerleri oranınca rulet çemberi üzerinde alan sağlanır. Uygunluk değeri büyük olan kromozom, çember üzerinde daha fazla alana sahip olur ve böylelikle seçilme şansı artar. Rassal sayı üretilerek, üretilen rassal sayının çember üzerinde karşılık geldiği alanda yer alan kromozom, çaprazlama işlemine gönderilmek üzere seçilir. Rulet Tekerleği Seçimi'ne ait algoritma yapısı, Şekil 2'de yer alan sözde kodlar ile belirtilmiştir.

Tablo 1. Çalışmada kullanılan semboller (Symbols used in the study)

Sembol	Sembolün Tanımı	Sembol	Sembolün Tanımı
chromosome[]	Kromozom dizisi	ffpercent[]	Kromozomların amaç fonksiyonu değerlerine göre yüzdelik dilim değerleri dizisi
fit[]	Amaç fonksiyonu dizisi	tourcount	Turnuva sayısı
crank	Kromozom sıraları dizisi	rnd[]	Rastgele üretilmiş birbirinden farklı, 1 ile belirtilen sayısı arasında rakamlardan oluşan dizi
Rankpercent[]	Kromozomların sıralamasına göre yüzdelik dilim değerleri dizisi	tchromosome[]	Turnuva sayısı kadar seçilmiş kromozomlardan oluşan dizi
cc	Havuzdaki kromozom sayısı	ffmin_x	ff dizisindeki en küçük fonksiyon değerine sahip elemanın sıra numarası
fitness_function(x)	x. Kromozomun amaç fonksiyonu değerini hesaplayan yapı	findsmallest_x	İçerisine gönderilen dizinin içindeki en küçük elemanın sıra numarasını veren yapı
uptodownff	Amaç fonksiyonu değerine göre kromozomları büyükten küçüğe sıralama	MM[]	chromosome[] dizisindeki kromozomların MultiMoora sıralamasının tutulduğu dizi
ranksum	Sıra numaralarının toplamı	MultiMoora()	İçine gönderilen dizinin değerlerinin MultiMoora sıralamasını dizi olarak döndüren fonksiyon
ffmax	En büyük amaç fonksiyonu değeri	tcn[]	Turnuva için seçilmiş kromozomların sıra numaralarının tutulduğu dizi
findbiggest()	Dizideki en büyük değeri bulan yapı	RevMM[]	MultiMoora sıralaması dizisinin ters sıralaması dizisi
ffrevsum	En büyük amaç fonksiyonu değerinden(ffmax) çıkarılmış amaç fonksiyonu değerleri toplamı	Reverse()	İçerisine gönderilen dizinin elemanlarının dizi elemanlarına göre tersini dizi olarak döndüren fonksiyon
ffreverse[]	En büyük amaç fonksiyonu değerinden(ffmax) çıkarılmış amaç fonksiyonu değerleri dizisi		

```

For i=1 To cc
    Hesapla ff[i]= fitness_function(chromosome[i])
Next
Hesapla fmax=findbiggest(ff[])
Set fsum=0
For i=1 To cc
    freverse[i]= fmax-ff[i]
    fsum=fsum+ffreverse[i]
Next
(0,100) aralığında rastgele sayı r üret
For i=1 To cc
    fpercent[i]=fpercent[i-1]+(100*ffreverse[i]/fsum)
    If r between fpercent[i] and fpercent[i-1] Then
        select chromosome[i]
    End
Next

```

Şekil 2. Rulet Tekerleği Seçimi sözde kodu
(Roulette wheel selection pseudocode)

2.1.2. Linear rank seçimi (Linear rank selection)

Rank seçimi ilk kez Baker tarafından orantılı seçimin olumsuz yönlerini ortadan kaldırmak amacıyla önerilmiştir [38]. Bu metod, Rulet Tekerleği Seçimi'nde olduğu gibi kromozomların uygunluk fonksiyonu değerlerini kullanmaktadır. Uygunluk değeri hesaplanan kromozomlar, en kötü uygunluk değerine sahip olan kromozom en başta olacak şekilde en iyi uygunluk değerine sahip olan kromozoma kadar sıralanır. Sıralanan kromozomlara, en kötü uygunluk değerine sahip kromozomdan en iyi uygunluk değerine sahip kromozoma doğru 1'den popülasyondaki kromozom sayısına kadar birer artış ile sıra numarası verilir. Verilen sıra numaralarının toplamı hesaplanır. Hesaplanan toplama her kromozomun sıra numarası değeri teker teker oranlanarak her kromozom için bir oran elde edilir. Rassal sayı üretilerek, bu sayının kromozomların sahip olduğu oranlar doğrultusunda belirlenen aralıkların hangisinde bulunduğu tespit edilir. Rassal sayının bulunduğu aralığa sahip kromozom çaprazlama işlemine gönderilmek üzere tercih edilir. Linear Rank Seçimi'ne ait algoritma yapısı Şekil 3'te gösterilmiştir.

2.1.3. Turnuva seçimi (Tournament selection)

Turnuva Seçimi, Brindle'm 1980'lerin başındaki çalışması ile ortaya çıkmış bir seçim stratejisidir [39]. Turnuva Seçimi'nin ilk adımı, popülasyondan belirli sayıda bireyin rassal olarak seçilmesidir. Seçilen bireylerin uygunluk fonksiyonu değerleri hesaplanır. Hesaplama sonucu uygunluk değeri en iyi olan birey, çaprazlama işlemine gönderilmek üzere seçilir. Turnuva Seçimi'ne ait algoritma yapısı Şekil 4'te gösterilmektedir.

```

For i=1 To cc
    Hesapla ff[i]= fitness_function(chromosome[i])
Next
Hesapla crank[]= uptodownff(ff[])
Set ranksum=0
For i=1 To cc
    ranksum=ranksum+i
Next
(0,100) aralığında rastgele sayı r üret
For i=1 To cc
    Rankpercent[i]=Rankpercent[i-1]+(100*crank[i]/ranksum)
    If r between Rankpercent[i] and Rankpercent[i-1] Then
        select chromosome[i]
    End
Next

```

Şekil 3. Linear Rank Seçimi sözde kodu
(Linear Rank Selection pseudocode)

```

(1, cc) aralığında rastgele farklı tur sayısı rnd [] oluştur
For i=1 To tourcount
    tchromosome[i]= chromosome[rnd[i]]
Next
For i=1 To tourcount
    Hesapla ff[i]= fitness_function(tchromosome[i])
Next
Hesapla fmin_x=findsmallest_x(ff[])
Select chromosome[rnd[fmin_x]]

```

Şekil 4. Turnuva Seçimi sözde kodu
(Tournament selection pseudocode)

2.2. MultiMoora Metodu (MultiMoora Method)

Brauers ve Zavadskas tarafından çok kriterli karar verme metodu olan MOORA (the multi-objective optimization on the basis of ratio analysis) metodu önerilmiştir [40]. Oran Metodu ve Referans Noktası Yaklaşımı metodlarını içeren MOORA metoduna, Brauers ve Zavadskas tarafından Tam Çarpım Formu'nun eklenmesiyle MultiMoora (MOORA plus the full multiplicative form) metodu geliştirilmiştir [41]. MultiMoora metodu Oran Metodu ve Referans Noktası Yaklaşımı ve Tam Çarpım Formu ile elde edilen sonuçların Sıra Baskınlık Teorisi kullanılarak karşılaştırılması sonucu alternatiflere ait bir sıralama elde etmektedir.

2.2.1. Oran metodu (Ratio method)

MultiMoora metodunun ilk adımı olan Oran Metodu'nda, çeşitli kriterlere göre alternatiflere ait performans

değerlerinin yer aldığı bir başlangıç matrisi oluşturulur. Bu matriste etkisi olumlu olan kriterler maksimum, olumsuz olan kriterler ise minimum kriter olarak Eş. 1'deki gibi belirlenir. Metot uygulanırken kriterlerin maksimum veya minimum olması durumları göz önünde bulundurularak değerlendirme yapılır.

$$X = \begin{matrix} & K_1 & K_2 & \dots & K_n \\ \text{Maksimum veya Minimum} & & & & \\ A_1 & \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots \\ A_m & x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix} \end{matrix} \quad (1)$$

Başlangıç matrisi değerlerine, 1970'li yıllarda Van Delft ve Nijkamp tarafından önerilen Eş. 2'deki işlemler ile normalizasyon uygulanır [42]. Normalize edilmiş değerler x_{ij}^* ile bir normalize edilmiş başlangıç matrisi oluşturulur.

$$x_{ij}^* = \frac{x_{ij}}{\sqrt{\sum_{j=1}^m x_{ij}^2}} \quad (2)$$

$i = 1, 2, \dots, m; m$ kriter sayısı

$j = 1, 2, \dots, n; n$ alternatif sayısı

x_{ij}

= j . alternatifin i . kriter açısından performans ölçüm değeri

Oluşturulan normalize edilmiş başlangıç matrisi değerleri, kritere ait ağırlıklar w_i kullanılarak Eş. 3'teki gibi ağırlıklandırılır. Matristeki tüm değerlerin ağırlıklandırılması ile ağırlıklandırılmış değerlerden v_{ij} oluşan, ağırlıklı normalize edilmiş bir matris oluşturulur.

$$v_{ij} = w_i * x_{ij}^* \quad (3)$$

$w_i = i$. kriter ağırlığı

Oluşturulan matriste her bir alternatif için, Oran Metodu puanı y_j^* Eş. 4 kullanılarak elde edilir.

$$y_j^* = \sum_{i=1}^g v_{ij} - \sum_{i=g+1}^n v_{ij} \quad (4)$$

$i = 1, \dots, g$ fayda türü kriter sayısı

$i = g + 1, \dots, n$ maliyet türü kriter sayısı

$g =$ maksimize edilecek hedeflerin sayısı

$n - g =$ minimize edilecek hedeflerin sayısı

$y_j^* = j$ alternatifinin tüm kriterlere göre normalize edilmiş değeri

Hesaplanan puanlar kullanılarak, alternatifler büyükten küçüğe doğru sıralanır ve Oran Metodu'na göre alternatiflere ait sıralama elde edilir.

2.2.2. Referans noktası yaklaşımı (Reference point approach)

MultiMoora metodunun sonraki adımı olan Referans Noktası Yaklaşımı'nda, Oran Metodu'nda olduğu gibi

başlangıç matrisine ağırlıklandırma ve normalizasyon işlemlerinin uygulanması sonucu elde edilen matristen yararlanılır. Matriste yer alan maksimum sütunların maksimum değeri, minimum sütunların ise minimum değeri o sütun için referans değeri r_i olarak belirlenir. Ardından ağırlıklı normalize matriste bulunan değerlerin, referans değerleri ile farkı Eş. 5'teki gibi hesaplanır. Hesaplanan değerlerden yeni bir matris oluşturulur.

$$|w_i r_i - v_{ij}| \quad (5)$$

Oluşturulan matriste her bir satırın maksimum değeri tespit edilir. Bu değerlerin küçükten büyüğe doğru sıralanması ile Referans Noktası Yaklaşımı metoduna ait alternatif sıralaması Eş. 6 kullanılarak elde edilir.

$$\min_j \{ \max_i (|w_i r_i - v_{ij}|) \} \quad (6)$$

2.2.3. Tam çarpım formu (Full multiplicative form)

MultiMoora metodunun üçüncü adımı olan Tam Çarpım Formu'nda başlangıç matrisi değerleri, Eş. 7' de yer alan ve Kundakçı tarafından uygulanan ağırlıklandırma formülü ile ağırlıklandırılır [43].

$$x_{ij}^{w_i} \quad (7)$$

Tüm matris değerlerinin ağırlıklandırılması sonucu ağırlıklandırılmış bir başlangıç matrisi elde edilir. Ağırlıklandırılmış başlangıç matrisinde her bir alternatif için maksimum değerler çarpımı A_j ve minimum değerler çarpımı B_j Eş. 8 kullanılarak ayrı ayrı hesaplanır.

$$A_j = \prod_{i=1}^g x_{ij}^{w_i} \quad , \quad B_j = \prod_{i=g+1}^n x_{ij}^{w_i} \quad (8)$$

$A_j =$ her bir alternatif için maksimum sütun değerleri çarpımı

$B_j =$ her bir alternatif için minimum sütun değerleri çarpımı

Hesaplanan A_j ve B_j değerlerinin oranlanması sonucu Eş. 9'dan yararlanılarak U_j değeri hesaplanır. Tüm alternatiflerin U_j değerlerinin büyükten küçüğe doğru sıralanması sonucu, alternatiflere ait Tam Çarpım Formu sıralaması elde edilir.

$$U_j = A_j / B_j \quad (9)$$

$U_j =$ alternatif j 'nin genel faydası

2.2.4. Sıra baskınlık teorisi (The theory of dominance)

Sıra Baskınlık Teorisi, MultiMoora metodu uygulanırken elde edilen üç farklı sıralamanın değerlendirmesi amacıyla geliştirilen bir metottur [44]. Karmaşıklık düzeyi yüksek olmayan problemlerde Oran Metodu, Referans Noktası Yaklaşımı ve Tam Çarpım Formu metodlarının sonuçları görüşler doğrultusunda değerlendirilebilmektedir [45].

Karmaşıklıkla fazla olan ve büyük matrisli problemlerin çözümünde Oran Metodu, Referans Noktası Yaklaşımı ve Tam Çarpım Formu ile elde edilen alternatif sıralamaları Sıra Baskınlık Teorisi kullanılarak değerlendirilir ve MultiMoora sıralaması olarak tek sıralama haline getirilir [46]. Sıra Baskınlık Teorisi aşağıda yer alan kurallar çerçevesinde uygulanmaktadır.

Mutlak Baskınlık: Alternatife ait sıralamalar üç yöntemde sırasıyla (1-1-1) olduğu durumda, bu alternatif diğer alternatiflere kesinlikle baskındır.

Genel Baskınlık: Baskınlıkların sırasıyla ($p < r < s < t$) olduğu durumda genellikle;
 $(t - p - p)$, $(s - r - r)$ 'ye ve $(p - t - p)$, $(r - s - r)$ 'ye ve $(p - p - t)$, $(r - r - s)$ 'ye baskındır.
Geçişkenlik: p , r 'ye ve r , s 'ye baskın olduğunda, p , s 'ye baskın olmaktadır.

Dengelilik: İki alternatife ait sıralamalar ($u - u - u$) gibi aynı olduğu durumda, mutlak dengelilik vardır.

Alternatiflere ait sıralamalarda ($4 - u - 11$) and ($6 - u - 7$) gibi yalnızca üç tanesinden ikisinde dengelilik varsa, burada kısmi dengelilik durumu bulunmaktadır.

Döngüsel Akıl Yürütme: A (10-18-12), B (12-14-13) ve C (13-17-11) alternatifleri için;
A (10-18-12), genellikle B (12-14-13)'ye,
B (12-14-13), genellikle C (13-17-11)'ye baskın olduğunda,
C (13-17-11), genellikle A (10-18-12)'ya baskın ise bu üç alternatif genellikle aynı sıraya sahip olmaktadır.

2.3. Geliştirilen MultiMoora Rank Selection Stratejisi (Proposed MultiMoora Rank Selection Strategy)

Genetik algoritmaların birden fazla performans kriterinin birlikte optimizasyonunun hedeflendiği problemler üzerinde uygulama performansını arttırmak amacıyla bir, çok amaçlı genetik algoritma seçim stratejisi önerilmiştir. Önerilen seçim stratejisi ile başlangıç popülasyonundaki bireyler çaprazlama için seçilirken sırasıyla Oran Metodu, Referans Noktası Yaklaşımı ve Tam Çarpım Formu ile elde edilen sıralama sonuçları Sıra Baskınlık Teorisi ile değerlendirilerek, kromozomlar için bir MultiMoora sıralaması elde edilir. Bu sıralamada iyi olandan kötü olana doğru sıra değerleri verilir. Bu sıra değerleri ile hesaplanan uygunluk değerleri değerlendirilerek çaprazlamaya girecek bireyler belirlenmiş olur. Önerilen seçim stratejisine ait ayrıntılı uygulama adımları aşağıda verilmiştir:

1. Adım : Başlangıç popülasyonunu oluşturan N adet kromozomun tamamına MultiMoora metodu uygulanır. Metot uygulanırken aralarından seçim yapılacak kromozomlar alternatifler, problemin amaçları ise kriterler olarak değerlendirilir.

2. Adım : MultiMoora işlemleri sonucu değerlendirilen kromozomlar için bir sıralama elde edilir. Elde edilen bu sıralamada başarılı bulunan ve ilk sırada yer alan

kromozoma N sıra numarası verilir. Sıralamada azalan performansa göre sıra numarası bir azaltılarak son sırada bulunan ve en düşük performanslı olarak değerlendirilen kromozoma 1 sıra numarası denk gelecek şekilde numaralandırılır.

3. Adım : Tüm sıra numaralarının toplamı hesaplanır ve kromozomların her birinin sıra numaraları, bu değere oranlanır.

4. Adım : Elde edilen oranlar miktarınca, rassal sayılar için aralıklar belirlenir.

5. Adım : Rassal sayılar üretilerek bu sayıların yer aldığı aralıktaki m adet kromozom seçilir.

6. Adım : Oluşturulan kromozom topluluğunda yer alan m adet kromozom için uygunluk fonksiyonu $f(x)$ ile uygunluk değerleri hesaplanır.

7. Adım : Topluluktaki en iyi $f(x)$ değerine sahip kromozom, çaprazlamaya gönderilecek ilk kromozom olarak seçilir.

Önerilen MultiMoora Rank Selection metoduna ait algoritma yapısı sözde kodlar ile Şekil 5'te gösterilmiştir.

3. UYGULAMA, DENEYLER VE KARSILAŞTIRMALAR

(IMPLEMENTATION, EXPERIMENTS AND COMPARISONS)

3.1. Test Problemleri (Testing Problems)

Geliştirilen MultiMoora Rank Selection seçim stratejisinin performansını görmek amacıyla, Microsoft Excel'de mevcut ve önerilen stratejiler kodlanarak çok amaçlı akış tipi çizelgeleme problemleri üzerinde uygulama yapılmıştır. Uygulamada on tezgahlı 15, 25, 35 ve 50 iş sayılarından oluşan dört farklı akış tipi çizelgeleme probleminden yararlanılmıştır. Tamamlanma zamanı, ortalama akış zamanı, maksimum gecikme ve ortalama gecikme kriterlerinin minimizasyonu ve zamanında tamamlanan iş sayısı kriterinin maksimizasyonu birlikte sağlanmaya çalışılmıştır. Uygunluk fonksiyonu olarak Veeraiah vd. tarafından önerilen fonksiyon Eş. 10'daki gibi kullanılmıştır [47].

$$\text{Min}f(x) = [w_1 C_{mak} + w_2 \bar{F} + w_3 T_{mak} + w_4 \bar{T} + w_5 NLJ] \quad (10)$$

C_{mak} = Maksimum tamamlanma zamanı

\bar{F} = Ortalama akış süresi

T_{mak} = Maksimum Gecikme

\bar{T} = Ortalama Gecikme

NLJ = Geciken iş sayısı

w_1, w_2, w_3, w_4 ve w_5 ifadeleri sırasıyla $C_{mak}, \bar{F}, T_{mak}, \bar{T}$ ve NLJ kriterlerine ait ağırlıklar olmak üzere,

$w_1, \geq 0, w_2 \geq 0, w_3 \geq 0, w_4 \geq 0, w_5 \geq 0$

$w_1 + w_2 + w_3 + w_4 + w_5 = 1$

Seçim metotları uygulanırken çaprazlama stratejisi olarak doğrusal sıralı çaprazlama, mutasyon stratejisi olarak keyfi üç işi değiştirme kullanılmıştır. Eleme aşaması için ise popülasyondaki en kötü bireyin popülasyondan çıkarılmasına dayanan, en kötüyü eleme stratejisi kullanılmıştır. Popülasyon büyüklüğü $N= 40$ olarak belirlenmiştir. Turnuva Seçimi stratejisi ile önerilen


```

Hesapla MM[]= MultiMoora(chromosome[])
Hesapla revMM[]= reverse(MM[])
Set ranksum=0
For i=1 To cc
    ranksum=ranksum+i
Next
For i=1 To cc
    Rankpercent[i]= Rankpercent[i-1]+(100* revMM[i]/ ranksum)
Next
(1, 100) aralığında rastgele farklı tur sayısı rnd [] oluştur
For j=1 To tourcount
    For i=1 To cc
        If rnd[j] between Rankpercent[i] and Rankpercent[i-1] Then
            tcn[j]= i
        End
    Next
Next
For i=1 To tourcount
    Hesapla ff[i]= fitness_function(chromosome[tcn[i]])
Next
Hesapla ffmín_x=findsmallest_x(ff[])
Select chromosome[tcn[ffmín_x]]

```

Şekil 5. MultiMoora Rank Selection sözde kodu (MultiMoora Rank Selection pseudocode)

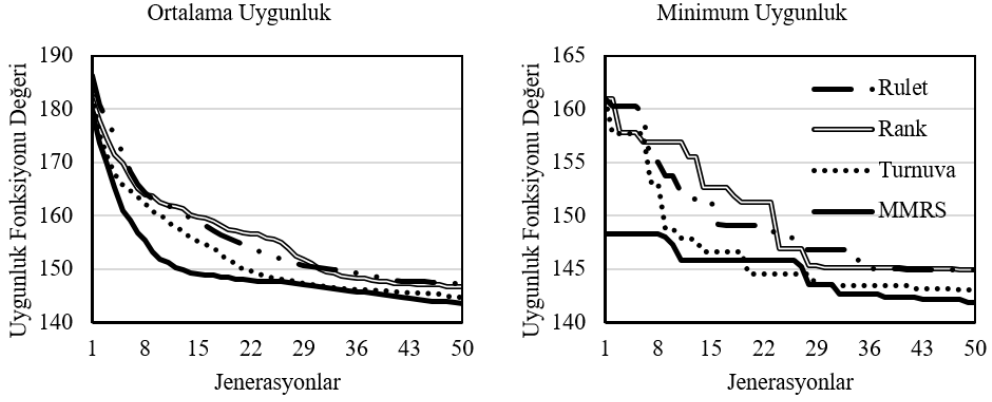
MultiMoora Rank Selection stratejileri uygulanırken ihtiyaç duyulan turnuva genişliği değeri m , 5 alınmıştır. Stratejilerin performanslarını daha iyi analiz edebilmek için jenerasyon sayısı dört problemde de 50 jenerasyon alınmış ve bu süreçte elde edilen minimum uygunluk fonksiyonu $f(x)_{min}$ ve her jenerasyondaki ortalama uygunluk fonksiyonu $f(x)_{ort}$ değerleri gözlemlenmiştir. Bu değerlerin 15, 25, 35 ve 50 işten oluşan problemler bazında jenerasyonlar boyunca değişimi Şekil 6 -9'de gösterilmektedir. Ortalama uygunluk fonksiyonu $f(x)_{ort}$ ve minimum uygunluk fonksiyonu $f(x)_{min}$ performans kriterleri açısından, dört problem büyüklüğünde de önerilen MultiMoora Rank Selection'ın daha iyi sonuçlar verdiği görülmektedir. Özellikle problem büyüklüğü arttırıldıkça MultiMoora Rank Selection'ın performansındaki artış belirginleşmektedir. Ayrıca önerilen stratejinin 15, 35 ve 50 işteki problemlerde, diğer seçim stratejilerine göre ilk jenerasyonlardan itibaren daha küçük $f(x)_{min}$ değerlerine ulaşabildiği ve sonraki jenerasyonlar boyunca da bunu geliştirerek devam ettirdiği görülmektedir.

3.2. Önerilen Seçim Stratejisinin Performansını Test Etme (Testing The Performance Of The Proposed Selection Strategy)


MultiMoora Rank Selection metodunun performansının tesadüfi olup olmadığının değerlendirilmesi amacıyla 15, 25,

35 ve 50 iş problemlerinin her birinde 40 bireyden oluşan başlangıç popülasyonundaki bireylerin değiştirilmesi ile tekrar sayısı 30'un üzerinde olacak şekilde uygulamalar gerçekleştirilmiştir. Uygulamalarda her bir tekrarda 50 jenerasyon boyunca elde edilen $f(x)_{min}$ değerleri için seçim stratejilerinin performansları değerlendirilmiştir. Yapılan normalizasyon testi sonucu verilerin normal dağılıma uygun olduğu tespit edilmiştir. Bu nedenle değerlendirmede normal dağılıma uygun verileri test etmekte kullanılan Eşlenik T-Testi'nden yararlanılmıştır. MultiMoora Rank Selection ile genetik algoritmanın Rulet Tekerleği Seçimi, Lineer Rank Seçimi ve Turnuva Seçimi stratejilerine ikili eşleştirme ile Eşlenik T-Testi uygulanmıştır. Minitab programına aktarılan verilere uygulanan Eşlenik T-Testi sonucu tüm iş sayıları için her bir denemede elde edilen $f(x)_{min}$ değerlerinin ortalamaları μ ve test olasılıkları p Tablo 2'de yer almaktadır.


Tablo 2'de, yapılan Eşlenik T-Testi sonucunda dört farklı problem büyüklüğünde $p \leq 0.05$ sonucunun sağlanmasıyla geliştirilen MultiMoora Rank Selection stratejisinin elde ettiği sonuçların tesadüfi olmadığı ve mevcut stratejilere nazaran anlamlı bir azalış sağladığı tespit edilmiştir.



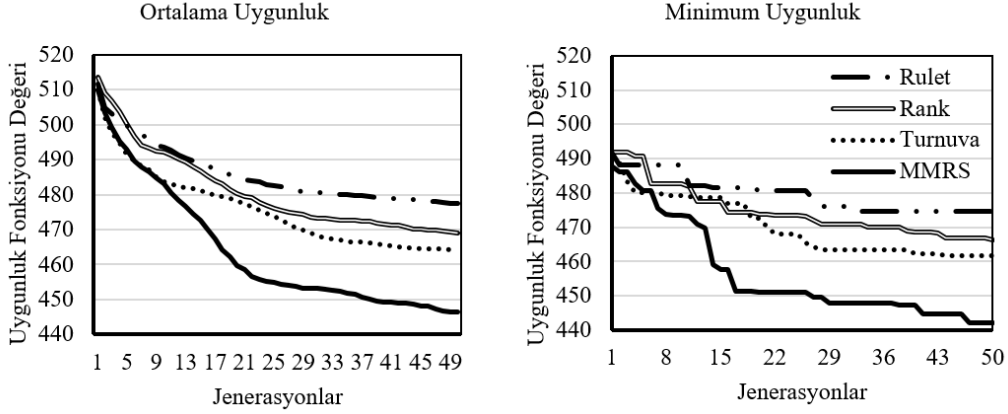
Şekil 6. 15 iş için Rulet Tekerleği Seçimi, Linear Rank Seçimi, Turnuva Seçimi ve MMRS ye ait, (a) $f(x)_{ort}$ karşılaştırılması (b) $f(x)_{min}$ karşılaştırılması
(The comparisons of Roulette Wheel Selection, Linear Rank Selection, Tournament Selection and MMRS for 15 jobs (a) $f(x)_{avg}$ (b) $f(x)_{min}$)



Şekil 7. 25 iş için Rulet Tekerleği Seçimi, Linear Rank Seçimi, Turnuva Seçimi ve MMRS ye ait, (a) $f(x)_{ort}$ karşılaştırılması (b) $f(x)_{min}$ karşılaştırılması
(The comparisons of Roulette Wheel Selection, Linear Rank Selection, Tournament Selection and MMRS for 25 jobs (a) $f(x)_{avg}$ (b) $f(x)_{min}$)



Şekil 8. 35 iş için Rulet Tekerleği Seçimi, Linear Rank Seçimi, Turnuva Seçimi ve MMRS ye ait, (a) $f(x)_{ort}$ karşılaştırılması (b) $f(x)_{min}$ karşılaştırılması
(The comparisons of Roulette Wheel Selection, Linear Rank Selection, Tournament Selection and MMRS for 35 jobs (a) $f(x)_{avg}$ (b) $f(x)_{min}$)



Şekil 9. 50 iş için Rulet Tekerleği Seçimi, Linear Rank Seçimi, Turnuva Seçimi ve MMRS ye ait, (a) $f(x)_{ort}$ karşılaştırılması (b) $f(x)_{min}$ karşılaştırılması

(The comparisons of Roulette Wheel Selection, Linear Rank Selection, Tournament Selection and MMRS for 50 jobs (a) $f(x)_{avg}$ (b) $f(x)_{min}$)

Tablo 2. MultiMoora Rank Selection metodunun çok tekrar ile elde edilen uygulama sonuçlarının genetik algoritmanın seçim metodoları ile p değeri bazında karşılaştırılması (Comparison of MultiMoora Rank Selection method application results obtained with multiple repetitions with the selection methods of genetic algorithm on the basis of p value)

Problem Büyüklüğü		μ	Rulet Tekerleği Seçimi		Lineer Rank Seçimi		Turnuva Seçimi	
			p	μ	p	μ	p	μ
15		143,596	0	144,251	0	144,419	0,02	143,956
25	MultiMoora	229,243	0	235,698	0	236,410	0,004	233,043
35	Rank	326,218	0	330,490	0	332,503	0,036	328,187
50	Seçimi	457,889	0	464,366	0	465,288	0,001	460,446

4. SONUÇLAR (CONCLUSIONS)

Bu çalışmada çok kriterli karar verme yöntemlerinden biri olan MultiMoora metodu, genetik algoritmaya yeni bir seçim stratejisi olarak adapte edilerek kullanılmıştır. Geliştirilen MultiMoora Rank Selection (MMRS) stratejisinin performansı 15, 25, 35 ve 50 iş sayılarından oluşan çok amaçlı akış tipi çizelgeleme problemleri üzerinde test edilmiştir. Aynı problemler üzerinde genetik algortmada sıkça kullanılan seçim stratejilerinden olan Rulet Tekerleği Seçimi, Lineer Rank Seçimi ve Turnuva Seçimi stratejileri ile uygulamalar yapılmış, elde edilen sonuçlar MultiMoora Rank Selection stratejisi ile karşılaştırılmıştır. Karşılaştırmada her jenerasyonda elde edilen $f(x)_{ort}$ ve $f(x)_{min}$ performans kriterleri kullanılmıştır. Ayrıca bu alandaki problemlerin çözümünde tekniklerin başarısında belirleyici olan $f(x)_{min}$ açısından sonuçlar tekrarlanarak % 95 güven düzeyinde istatistiksel analiz gerçekleştirilmiştir. Elde edilen bulgular, önerilen MultiMoora Rank Selection seçim stratejisinin, genetik algortmada yaygın kullanılan seçim stratejilerinden daha iyi sonuçlar verdiğini göstermektedir. Önerilen metot ile daha az jenerasyonda birden çok amaç aynı anda, hızlı bir şekilde optimize edilebilmektedir. Bundan sonraki yapılacak çalışmalarda, geliştirilen seçim stratejisi araç rotalama, tesis düzenleme vb. gibi farklı türlerdeki çok amaçlı ve çözüm uzayı büyük problemlerin çözümünde kullanılabilir. Ayrıca farklı çok

kriterli karar verme tekniklerinin genetik algoritmaya adapte edilmesi ve farklı performans kriterlerinin değerlendirme aşamasına dahil edilmesiyle yeni stratejiler geliştirilebilir. Geliştirilen yeni stratejiler bu çalışmada elde edilen sonuçlar ile karşılaştırılabilir.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışma SAÜ Bilimsel Araştırma Projeleri Komisyonu tarafından desteklenmiştir. (Proje no: 2017-50-01-073)

KAYNAKLAR (REFERENCES)

1. Arık O. A., Genetic Algorithm Application for Permutation Flow Shop Scheduling Problems, Gazi University Journal of Science, 1-1, 2021.
2. Çalışkan F., Yüksel H., Dayık M., Genetik Algoritmaların Tasarım Sürecinde Kullanılması, SDU Teknik Bilimler Dergisi, 6 (2), 21-27, 2016.
3. Goldberg D. E., Deb K., A comparative analysis of selection schemes used in genetic algorithms, Foundations of genetic algorithms, 1, 69-93, 1991.
4. Chakraborty U. K., Deb K., Chakraborty M., Analysis of selection algorithms: A Markov chain approach, Evolutionary Computation, 4 (2), 133-167, 1996.
5. Chakraborty M., Chakraborty U. K., An analysis of linear ranking and binary tournament selection in

- genetic algorithms, *Information Communications and Signal Processing (ICICS)*, 1, 407-411, 1997.
6. Alfonso H., Cesan P., Fernandez N., Minetti G. F., Salto C., Velazco L., Gallard R. H., Contrasting main selection methods in genetic algorithms, *IV Congreso Argentina de Ciencias de la Computación*, 1998.
 7. Wiese K., Goodwin S. D., Keep-best reproduction: a selection strategy for genetic algorithms, *Association for Computing Machinery (ACM) symposium on Applied Computing*, 343-348, 1998.
 8. Wiese K., Goodwin S. D., The effect of genetic operator probabilities and selection strategies on the performance of a genetic algorithm, *Advances in Artificial Intelligence*, Springer, 1418, 139-153, 1998.
 9. Andrade A. V., Errico L., Aquino A. L. L., Assis L. P., Barbosa C. H. N. R., Analysis of selection and crossover methods used by genetic algorithm-based heuristic to solve the lsp allocation problem in mpls networks under capacity constraints, *International Conference on Engineering Optimization*, 1-9, 2008.
 10. Xie H., Zhang M., Tuning Selection Pressure in Tournament Selection, *School of Engineering and Computer Science*, 1-14, 2009.
 11. Chudasama C., Shah S. M., Panchal M., Comparison of parents selection methods of genetic algorithm for TSP, *International Conference on Computer Communication and Networks*, 85-87, 2011.
 12. Razali N. M., Geraghty J., Genetic algorithm performance with different selection strategies in solving TSP, *International Conference of Computational Intelligence and Intelligent Systems*, 2, 1134-1139, 2011.
 13. Kumar R., Blending roulette wheel selection & rank selection in genetic algorithms, *International Journal of Machine Learning and Computing*, 2 (4), 365-370, 2012.
 14. Alabsi F., Naoum R., Comparison of selection methods and crossover operations using steady state genetic based intrusion detection system, *Journal of Emerging Trends in Computing and Information Sciences*, 3 (7), 1053-1058, 2012.
 15. Jebari K., Madiafi M., Selection methods for genetic algorithms, *International Journal of Emerging Sciences*, 3 (4), 333-344, 2013.
 16. Oladele R. O., Sadiku J. S., Genetic algorithm performance with different selection methods in solving multi-objective network design problem, *International Journal of Computer Applications*, 70 (12), 5-9 2013.
 17. Nazmul R., Chetty M., A priority based parental selection method for genetic algorithm, *The Genetic and Evolutionary Computation Conference*, 125-126, 2013.
 18. Mayilvaganan M., Geethamani G. S., Performance Comparison of Roulette Wheel Selection and Steady state Selection in Genetic Nucleotide Sequence, *International Journal of Innovative Research in Computer and Communication Engineering*, 3 (4), 4271-4276 2015.
 19. Long Q., Wu C., Wang X., Jiang L., Li J., A multiobjective genetic algorithm based on a discrete selection procedure, *Mathematical Problems in Engineering*, 1-17, 2015.
 20. Anand S., Afreen N., Yazdani S., A Novel and Efficient Selection Method in Genetic Algorithm, *International Journal of Computer Applications*, 129 (15), 7-12, 2015.
 21. Shukla A., Pandey H. M., Mehrotra D., Comparative review of selection techniques in genetic algorithm, *Futuristic Trends on Computational Analysis and Knowledge Management*, 515-519, 2015.
 22. Pandey H. M., Performance evaluation of selection methods of genetic algorithm and network security concerns, *Procedia Computer Science*, 78, 13-18, 2016.
 23. Irfianti A. D., Wardoyo R., Hartati S., Sulistyoningsih E., Determination of Selection Method in Genetic Algorithm for Land Suitability, *MATEC Web of Conferences*, 58, 2016.
 24. Abd Rahman R., Ramli R., Jamari Z., Ku-Mahamud K. R., Evolutionary Algorithm with Roulette-Tournament Selection for Solving Aquaculture Diet Formulation, *Mathematical Problems in Engineering*, 1-16, 2016.
 25. Beg A. H., Islam M. Z., Genetic Algorithm with Novel Crossover, Selection and Health Check for Clustering, *Computational Intelligence and Machine Learning*, 575-580, 2016.
 26. Alkhayri W. R., Owis S., Shkoukani M., A New Selection Operator-CSM in Genetic Algorithms for Solving the TSP, *International Journal of Advanced Computer Science and Applications*, 7 (10), 62-66, 2016.
 27. Saini N., Review of Selection Methods in Genetic Algorithms, *International Journal of Engineering and Computer Science*, 6 (12), 22261-22263, 2017.
 28. Yadav S. L., Sohal A., Comparative Study of Different Selection Techniques in Genetic Algorithm, *International Journal of Engineering, Science and Mathematics*, 6 (3), 174-180, 2017.
 29. Chehoury A., Younes R., Khoder J., Perron J., Ilinca A., A Selection Process for Genetic Algorithm Using Clustering Analysis, *Algorithms*, 10 (4), 123, 2017.
 30. Kalınlı A., Aksu Ö., Genetic algorithm model based on dominant gene selection operator, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 26 (4), 869-875, 2011.
 31. Brauers W. K. M., Zavadskas E. K., A multi-objective decision support system for project selection with an application for the Tunisian textile industry, *Ekonomika a management*, 15 (1), 28-43, 2012.
 32. Demir A. S., Gelen M. B., A New Approach to Solving Multi-Objective Flow-Shop Scheduling Problems: A MultiMoora-Based Genetic Algorithm, *Journal of Engineering Research*, 9 (4A), 191-200, 2021.
 33. Gonçalves J. F., de Magalhães Mendes J. J., Resende M. G., A hybrid genetic algorithm for the job shop scheduling problem, *European journal of operational research*, 167 (1), 77-95, 2005.
 34. Della Croce F., Tadei R., Volta G., A genetic algorithm for the job shop problem, *Computers & Operations Research*, 22 (1), 15-24, 1995.

35. Kalayci C. B., Ertenlice O., Akyer H., Aygoren H., A review on the current applications of genetic algorithms in mean-variance portfolio optimization, Pamukkale University Journal of Engineering Sciences, 23 (4), 470-476, 2017.
36. Pour N., Tavakkoli-Moghaddam R., Asadi H., Optimizing a multi-objectives flow shop scheduling problem by a novel genetic algorithm, International Journal of Industrial Engineering Computations, 4 (3), 345-354, 2013.
37. Konak A., Coit D. W., Smith A. E., Multi-objective optimization using genetic algorithms: A tutorial, Reliability Engineering & System Safety, 91 (9), 992-1007, 2006.
38. Blickle T., Thiele L., A comparison of selection schemes used in genetic algorithms, Evolutionary Computation, 27-33, 1995.
39. Xie H., Zhang M., Andreae P., Johnston M., Is the not-sampled issue in tournament selection critical?, Evolutionary Computation, 3710-3717, 2008.
40. Brauers W. K. M., Zavadskas E. K., The MOORA method and its application to privatization in a transition economy, Control and Cybernetics, 35, 445-469, 2006.
41. Brauers W. K. M., Zavadskas E. K., Project management by MULTIMOORA as an instrument for transition economies, Technological and Economic Development of Economy, 16 (1), 5-24, 2010.
42. Datta S., Sahu N., Mahapatra S., Robot selection based on grey-MULTIMOORA approach, Grey Systems: Theory and Application, 3 (2), 201-232, 2013.
43. Kundakcı N., Combined multi-criteria decision making approach based on MACBETH and MULTI-MOORA methods, Alphanumeric Journal, 4 (1), 17-26, 2016.
44. Brauers W. K. M., Zavadskas E. K., Robustness of MULTIMOORA: a method for multi-objective optimization, Informatica, 23 (1), 1-25, 2012.
45. Brauers W. K. M., Kildienė S., Zavadskas E. K., Kaklauskas A., The construction sector in twenty European countries during the recession 2008–2009–country ranking by MULTIMOORA, International Journal of Strategic Property Management, 17 (1), 58-78, 2013.
46. Brauers W. K. M., Zavadskas E. K., Kildienė S., Was the Construction Sector in 20 European Countries Anticyclical during the Recession Years 2008-2009 as Measured by Multicriteria Analysis (MULTIMOORA)?, Procedia Computer Science, 31, 949-956, 2014.
47. Veeraiah T., Pratapa Reddy Y., V S Mohan Kumar P., W D S Milton P., Optimization of Flow Shop Scheduling by MATLAB, International Journal of Mechanical Engineering (IJME), 222-226, 2017.

