



# Küme Birleşimli Sırt Çantası Probleminin Adaptif Yapay Arı Kolonisi Algoritması ile Çözümü

Rafet DURGUT<sup>1\*</sup>, İlim Betül YAVUZ<sup>2</sup>, Mehmet Emin AYDIN<sup>3</sup>

<sup>1</sup>Karabük Üniversitesi, Bilgisayar Mühendisliği Bölümü, Karabük, Türkiye

<sup>2</sup>Karabük Üniversitesi, Bilgisayar Mühendisliği Bölümü, Karabük, Türkiye

<sup>3</sup>UWE Bristol, Dept. of Computer Science and Creative Technologies, Bristol, İngiltere

rafetdurgut@karabuk.edu.tr, 1828126016 @karabuk.edu.tr, Mehmet.aydin@uwe.ac.uk

## Öz

Meta-sezgisel ve sürü zekâsı algoritmaları, NP-Zor optimizasyon problemlerine yaklaşık çözümler sunmak için uzun süredir kullanılmaktadır. Özellikle kombinatoriyal ve ikili problemler söz konusu olduğunda, algoritmalar içerisine gömülü komşu çözüm üretmek için kullanılan operatör fonksiyonları, aramanın çeşitliliğine sınırlamalar getirirken algoritmaların başarısında önemli bir rol oynar. Bu tür sınırlamalardan kaçmak ve çeşitliliği iyileştirmek için, birden fazla operatörün tek bir operatör yerine bir seçim şeması yoluyla kullanılması tercih edilir. Daha önce farklı sürü zekâsı ve meta-sezgisel algoritmalarla çeşitli kombinatoriyal problemleri çözmek için bir dizi operatör seçim şeması kullanılması daha yüksek etkinlik elde etmek için kullanılmıştır. Bu makalede, küme birleşimli sırt çantası problemleri, ilk kez, alternatif operatör seçim şemaları aracılığıyla seçilen birden fazla operatör içeren ikili bir yapay arı kolonisi algoritması ile çözülmüştür. Önerilen yöntem için farklı kredi atama yaklaşımları, farklı kayan pencere boyutları ve parametre konfigürasyonları test edilmiştir. Seçim şemalarının özellikleri kapsamlı olarak 30 kıyaslama problemi üzerinde incelenmiştir. Bu problem kümeleri için en iyi performans gösteren algoritma konfigürasyonu önerilmiştir. Çalışma, başarılı bir seçim şemasına sahip adaptif ikili yapay arı kolonisi algoritmasını sunmaktadır.

**Anahtar kelimeler:** Yapay Arı Kolonisi, Adaptif Operatör Seçimi, Küme Birleşimli Sırt Çantası Problemi

## Solving Set Union Knapsack Problems with Adaptive Binary Artificial Bee Colony

### Abstract

Metaheuristic and swarm intelligence algorithms have been utilised to solve optimization problems with NP-Hard nature providing approximate solutions for a long time. Especially in the case of combinatorial and binary problems, operator functions embedded in the algorithms to generate neighboring solutions play a crucial role in the success of the algorithms while each operator imposes limitations upon the diversity of the search. In order to escape of such limitations and improve the diversity, multiple operators are preferred to use through a selection scheme instead of a single operator. However, the nature of selection scheme whereby operators are opted out also matters for higher efficiency, where a number of operator selection schemes have been used to solve various combinatorial problems with different swarm intelligence and metaheuristic algorithms before. In this paper, set union knapsack problems are, first time, solved with a binary artificial bee colony algorithm embedded with multiple operators selected through alternative operator selection schemes. Different credit assignment approaches, different sliding window lengths and parameter configurations are tested for the proposed method. The characteristics of the selection schemes are studied and the best performing one is suggested using a comprehensive experimentation over 30 benchmark problems. The study concludes a particular variant of binary artificial bee colony algorithm with a successful selection scheme.

**Keywords:** Artificial Bee Colony, Adaptive Operator Selection, Set Union Knapsack Problem.

\* Sorumlu yazar. Rafet Durgut  
E-posta adresi: rafetdurgut@karabuk.edu.tr

Alındı : 05 Ocak 2021  
Revizyon : 08 Şubat 2021  
Kabul : 15 Şubat 2021

## 1. Giriş (Introduction)

Sırt çantası problemi eldeki imkanlardan en yüksek faydayı sağlamak amacıyla çözülmesi gereken ve doğrusal zamanda çözülmesi mümkün olmayan bir optimizasyon problemidir. Günlük yaşamda, kaynak planlama (Bitran vd., 1981), kriptografi (Odlyzko vd., 1990), lojistik (Klamroth vd., 2000), üretim sistemleri (Bretthauter vd., 2002), gibi birçok alanda uygulama alanına sahiptir.

Sırt çantası uygulanacak probleminin yapısına göre 0/1 Sırt çantası (Moradi vd., 2021), çok boyutlu sırt çantası (García vd., 2020) veya küme birleşimli sırt çantası (Wei ve Hao, 2021) gibi farklı tipleri bulunmaktadır; Küme birleşimli sırt çantası (KBSC) problemi 0-1 sırt çantası probleminin özel bir halidir. Bu problemde mevcut elemanlar buldukları kümeye göre ele alınmaktadır. KBSC probleminin şimdiye kadar çeşitli uygulama ve alanlarda değerli oluşu bilinmektedir (Goldschmidt vd., 1994).

Problemde  $n$  tane eleman için  $U = \{1, 2, \dots, n\}$  elemanlar kümesini ve  $m$  tane nesne için  $S = \{1, 2, \dots, m\}$  nesne kümesini ifade etmektedir. Öyle ki  $S$  kümesindeki her nesne  $i \in S$  ( $i = 1, 2, \dots, m$ )  $U_i \subseteq U$  karşılık gelmektedir ve bir fayda değerine ( $p_i > 0$ ) sahiptir.

$$\max P(A) = \sum_{i \in A} p_i \quad (1)$$

$$W(A) = \sum_{u_j \in U_{i \in A}} u_i w_j \leq C, A \subseteq S \quad (2)$$

Amaç fonksiyonu Eşitlik (1)'de belirtilmiş olup, bu fonksiyonun amacı maksimum faydayı sağlayacak en iyi  $A \subseteq S$  alt kümesini ( $S^*$ ) belirlemektir. Eşitlik (2)'deki  $w_j$  değişkeni elemanın ağırlığını,  $C$  ise sırt çantasının kapasite sınırını ifade etmektedir.

Goldschmidt vd. (1994) KBSC probleminin kesin çözümü için hipergraf tabanlı dinamik programlama algoritmasının kullanılmasını önermiştir. Fakat bu algoritma düşük boyutlu problemler için hızlı çözüm önermesine karşın, problem boyutu arttıkça doğrusal zamanda bir çözüm sunamamaktadır. Benzer şekilde, Arulsevan (2014) aç gözlü bir yakınsama algoritması önermiştir.

Metasezgisel algoritmalar, doğrusal zamanda çözülemeyen problemlere uygulanabilecek alternatif ve güçlü bir seçimdir. Doğadan esinlenilerek geliştirilen bu algoritmalar içerisinde; Genetik Algoritma (Holland, 1975, Lin vd., 2020), Parçacık Sürüşü Optimizasyonu (Russel ve Eberhart, 1995, Bansal, 2019) veya Yapay Arı Kolonisi (Karaboğa ve Baştürk, 2008, Xiang vd., 2021) gibi oldukça başarılı ve popüler yöntemler bulunmaktadır. Popülasyon tabanlı olan bu yaklaşımlarda her bir çözüm ilgili bireye atanır ve

komşu çözümlerden faydalanılarak arama uzayındaki en iyi çözümü sunan noktaya ulaşılmaya çalışılır.

Yapay arı kolonisi algoritması Karaboğa (2005) tarafından bal arılarının yiyecek bulma davranışından esinlenilerek sürekli optimizasyon problemlerine çözüm bulmak için geliştirilmiştir (Wang vd., 2020). Yöntem kullandığı eşitlikler gereği ikili optimizasyon problemlerine doğrudan uygulanamamaktadır. Bu sebeple, ikili optimizasyon problemlerine uygulanabilmesi için çeşitli düzenlemeler gerekmektedir (Lin vd., 2020). Bu düzenlemeler komşu çözüm üretilmesi için yapılmaktadır. Kiran vd. (2013) tarafından sunulan mantıksal özel veya kapısı kullanan binABC algoritması, Kasha vd. (2012) tarafından sunulan disABC algoritması gibi çeşitli komşu çözüm üretme mekanizmaları bulunmaktadır. Durgut (2020) ise, binABC algoritmasının yakınsama hızını arttırmak için bazı düzenlemeler sunmuştur.

Yapay arı kolonisi yaklaşımı ve benzeri sürü zekâsına dayalı metasezgisel optimizasyon algoritmaları, arama sürecinde ulaştıkları çözümleri geliştirerek (sömürü fazı) daha iyi çözümlere ulaşmaya çalışmakta veya arama bölgesinin farklı noktalarına ulaşarak (keşif fazı) yeni başarılı çözümlere ulaşmaya çalışmaktadır. Bahsi geçen iki faz (sömürü, keşif) arasında denge sağlanması oldukça zor olmakla beraber, bu denge yerel minimuma takılma ya da hızlı yakınsayamama probleminin oluşmaması için önemlidir (Arani vd., 2013). Bu tip problemlerin oluşma durumunu en aza indirmek, yerel minimuma takılmadan en iyi çözüme hızlı bir şekilde ulaşabilmek amacıyla adaptif operatör seçimi yaklaşımı önerilmektedir (Fialho, 2010).

Bu yaklaşımda komşu çözüm üretimi aşamasında bir operatör yerine birden çok operatör içeren operatör havuzu kullanılması öne çıkarılmıştır. Temel fikir operatörlerin birbirlerini tamamlayıcı davranış gösterebilmeleri beklentisidir. Burada tamamlayıcılık bir kriterle dayandırılarak tarif edilmektedir. Başarılı operatörlerin seçim şansının artırılması sayesinde operatörlerin birbirlerini tamamlayıcı davranabilecekleri ve böylece en iyi çözüme hızlı şekilde ulaşılması mümkün olabilecektir. Bu amaçla bu çalışma yapılmış ve tatmin edici sonuçlara ulaşılmıştır.

Bu çalışmada, küme birleşimli sırt çantası problemine kaliteli çözümler sunulabilmesi için adaptif yapay arı kolonisi yaklaşımı önerilmiştir. Literatür incelendiğinde, KBSC probleminin çözümü için kullanılmış olan Metasezgisel algoritmaların tüm süreci tek bir operatör ile yürüttüğü görülmüştür (He, 2018, Özsoydan vd., 2019). Önerilen yaklaşım ise, üç farklı komşuluk operatörü ve üç farklı operatör seçim yöntemi için çalıştırılmış ve en iyi konfigürasyon elde edilmiştir. Elde edilen sonuçlar literatürdeki diğer başarılı yöntemler ile karşılaştırılmış ve var olan yöntemlerden daha kaliteli çözümler üretilmiştir. Sonuç olarak bu çalışmanın katkısı, KBSC probleminin çözümü için literatürdeki çalışmalardan daha kaliteli çözümler üretmesi olarak görülmektedir.

## 2. YAPAY ARI KOLONİSİ (Artificial Bee Colony)

Sürü zekasına dayalı bir optimizasyon algoritması olan Yapay Arı Kolonisi (YAK) Algoritması, bal arılarının yiyecek arama/bulma davranışlarından esinlenilerek Karaboğa (2005) tarafından geliştirilmiştir.

Yapay Arı Kolonisi algoritmasının esinlendiği doğada arılar besin arama davranışlarında işçi, gözcü ve kâşif olmak üzere farklı görevlere sahiptirler. Arıların besin arama davranışlarının geçtiği aşamalar, başka bir deyişle YAK çalışma adımları Şekil 1’de verilmiştir.

### Algorithm 1 Yapay Arı Kolonisi

- 1: Başlangıç popülasyonunu oluştur.
- 2: Durdurma kriteri sağlanana kadar
- 3: Eşitlik 4’ü kullanarak komşu çözüm üret.
- 4: Seçili çözüm ile aday çözüm arasında aç gözlü seçim işlemi yap.
- 5: Her besin kaynağı için olasılık değerini hesapla.
- 6: Olasılık değerine göre besin kaynağı seç.
- 7: Eşitlik 4’ü kullanarak komşu çözüm üret.
- 8: Seçili çözüm ile aday çözüm arasında aç gözlü seçim işlemi yap.
- 9: Tüklenen besin kaynağı var ise yeni geçerli çözüm ile değiştir.
- 10: Şimdiye kadar bulunan en iyi çözümü sakla

### Şekil 1. YAK çalışma adımları (ABC Working Steps)

Başlangıç olarak yiyecek kaynaklarının üretilmesi için Kâşif arılar yiyecek kaynaklarını rastgele aramaya başlarlar. Yöntem içerisinde ise, rastgele geçerli çözüm atanması Eşitlik (3)’e göre yapılmaktadır.

$$x_{ij} = x_{ij}^{min} + rand(0,1)(x_{ij}^{max} - x_{ij}^{min}) \quad (3)$$

Eşitlik (3)’te,  $i$ . besin kaynağının  $j$ . boyutuna (parametresine) ait rastgele değer ( $x_{ij}$ ) verilen sınırlar ( $x_{ij}^{max} - x_{ij}^{min}$ ) aralığında rastgele olarak belirlenir.

Bütün besinlerin tüm boyutlarına denklemden elde edilmiş değerler atanarak ilk çözümler (kaynaklar) oluşturulur.

İşçi arı fazında, arılar mevcut yiyecek kaynağının komşuluğunda yeni aday çözüm oluşturulur. Yeni oluşturulan çözümün kalitesi eskisinden daha iyi ise aç gözlü seçim uygulanarak bu çözüm ile güncellenir. Böylelikle işçi arı fazında her arı üzerinde çalıştığı besin kaynağını geliştirmektedir.

$$V_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) \quad (4)$$

Eşitlik (4)’te her bir arı komşu bir arıdan aldığı bilgi dahilinde bu arının komşuluğunda denklem ile yeni bir çözüm üretir ve bu sayede besin kaynağını geliştirir.  $V_{ij}$  değeri,  $i$ . arının  $j$ . boyutu için üretilmiş yeni değerdir. Bu değer, mevcut kaynağın komşuluğunda rastgele başka bir kaynağın yine aynı boyut bilgisine göre ( $x_{kj}$ ) güncellenmektedir.  $\phi$  değeri hangi ölçüde ilerleneceğini ifade eden katsayıdır ve  $[-1,1]$  aralığında rastgele üretilmektedir.

$$F_i = \begin{cases} -\frac{1}{1+fi}, & fi \geq 0 \\ 1 + abs(fi), & fi < 0 \end{cases} \quad (5)$$

Bulunan kaynağın kalitesi, uygunluk fonksiyonu ( $fi$ ) sonucunda hesaplanır. Kalite değerinin sıfırdan büyük ve eşit ya da küçük olmasına göre bu kaynağa Eşitlik (5)’te bulunan denklemde hesaplanan uygunluk değeri atanmış olur.

Gözcü arı fazında, arılar tüm görevli arıların elde ettikleri kaynak bilgilerini toplarlar. Bu bilgiler ışığında gözcü arının en iyi besin kaynağını seçebilmesi için kaynaktaki nektar miktarı ile orantılı olarak Eşitlik (6)’da belirtildiği gibi bir olasılık değeri belirlenir. Bu sayede gözcü arı aşamasında geliştirilmesi hedeflenen besin kaynakları belirlenmiş olur.

$$p_i = \frac{F_i}{\sum_{j=1}^{SN} F_i} \quad (6)$$

Kaynakların kalitesine göre bulunmuş olan uygunluk değerlerinin ardından bu kaynakların hangisinin geliştirileceği tüm kaynaklar baz alınarak hesaplanan olasılık değerine bağlıdır. Her bir çözümün olasılık değeri Eşitlik 6’da elde edilen değere göre belirlenmektedir. Bu olasılık değerlerine göre çözümler üzerinde güncelleme test edilir. Kâşif arı fazında, limit değerine ulaşan güncellemeye rağmen iyileşmeyen ilk çözüm popülasyondan atılarak, yerine rastgele ve geçerli bir çözüm dahil edilir. Bu şekilde algoritma ilk iterasyonunu tamamlayıp tekrar işçi arı aşamasına dönmektedir. Algoritma durdurma kriteri sağlanana kadar devam etmektedir.

## 3. İKİLİ YAPAY ARI KOLONİSİ (Binary Artificial Bee Colony)

Yapay arı kolonisi algoritması sürekli optimizasyon problemleri çözme amacıyla geliştirildiği için, ikili optimizasyon problemlerine doğrudan uygulanamamaktadır. Uygulanabilmesi için bazı düzenlemeler yapılmalıdır. Bu düzenlemeler iki sınıfa ayrılabilir; bunlardan biri probleme uygulama aşamasında sürekli karar değişkenlerinin ikili uzaya yerleştirilmesi (Kiran vd., 2015), diğeri ise karar değişkenlerinin ikili formda (Kiran vd., 2013) olmasıdır. İlk sınıftaki düzenleme kullanıldığında yöntemin sürekli uzayda aramaya devam eder, fakat amaç fonksiyonu içerisinde sürekli uzaydan ikili uzaya haritalama fonksiyonu gereklidir. İkinci sınıftaki düzenlemeler de ise, genellikle mantıksal karşılaştırma ve ifadeler kullanılmaktadır.

Bu çalışmada literatürde sıklıkla kullanılan binABC (Kirav vd., 2013), disABC (Kashan vd., 2013) ve yeni önerilmiş olan ibinABC (Durgut, 2020) operatörleri adaptif bir mekanizma içerisinde birlikte kullanılmaktadır.

### 3.1. BinABC Algoritması (BinABC Algorithm).

Çözüm uzayı ikili yapıda olan optimizasyon problemleri için geliştirilmiş XOR tabanlı arı kolonisi algoritmasıdır. Bu algoritma Kiran vd. tarafından “Kapasite tesis yerleştirme problemi” çözümü için geliştirilmiştir (Kirav vd., 2013). YAK algoritmasının ikili yapıya uygun hale gelmesi için Eşitlik (3) ve Eşitlik (4)’ün uygun formata dönüştürülmesi gerekmektedir.

$$X_{i,j} = \begin{cases} 0, & r_{i,j} < p \\ 1, & r_{i,j} \geq p \end{cases} \quad (7)$$

Diğer yaklaşımlarda olduğu gibi bu yöntemde de başlangıçta kullanılacak arı popülasyonu için üretilen rastgele çözümler, Eşitlik (3)’ün Eşitlik (7) olarak güncellenmesiyle oluşturulmaktadır.

$$V_i^j = X_i^j \oplus [\varphi(X_i^j \oplus X_k^j)] \quad (8)$$

İlk arı popülasyonu oluşturulduktan sonra, işçi ve gözcü arı pozisyonlarının hesaplandığı aday çözümün ifade eden Eşitlik (4), Eşitlik (8)’deki gibi güncellenir. Eşitlik (8)’de  $V_i^j$ , i. aday çözümün j. boyutunu temsil eder.  $X_i^j$  i. işçinin j. boyutu,  $X_k^j$  k. işçinin j. boyutu,  $\oplus$  XOR mantıksal operatörü,  $\varphi$  ise %50 olasılıkla mantıksal değil kapısını ifade eder. Eğer  $\varphi$  0,5’ten küçükse sonuç  $(X_i^j \oplus X_k^j)$  ifadesinin terslenmiş halidir, büyük ve eşitse sonuç terslenmemiştir.

### 3.2. DisABC Algoritması (DisABC Algorithm)

ABC nin diğer ikili versiyonu olan DisABC algoritması Kashan vd. tarafından önerilmiştir (Kashan vd., 2012). Bu algortmada YAK algoritmasının yapısal durumu baz alınarak işçi arı ( $X_i$ ) diğer bir deyişle seçili çözüm ve komşu arı ( $X_k$ ) arasındaki farklılığın ölçülmesi önemlidir. Bu noktada, Eşitlik (9)’da Jaccard benzerlik katsayısı bulunarak 1’den çıkarılır, böylelikle farklılık bulunur.

$$\text{Dissimilarity}(X_i, X_k) = 1 - \text{Similarity}(X_i, X_k) \quad (9)$$

$$\text{Dissimilarity}(X_i, X_k) = 1 - \frac{m_{11}}{m_{01} + m_{10} + m_{11}} \quad (10)$$

Eşitlik (10)’da,  $m_{01}$  değeri  $X_{i,j}=0$  ve  $X_{k,j}=1$  olduğu durumdaki bitlerin sayısını,  $m_{10}$  değeri  $X_{i,j}=1$  ve  $X_{k,j}=0$  olduğu durumdaki bitlerin sayısını,  $m_{11}$  değeri  $X_{i,j}=1$

ve  $X_{k,j}=1$  olduğu durumdaki bitlerin sayısını temsil eder.

Eşitlik (11) için, Aday çözüm:  $V_i$ , pozitif ölçek faktörü:  $\varphi$

$$\text{Dissimilarity}(V_i, X_i) \approx \varphi \times \text{Dissimilarity}(X_i, X_k) \quad (11)$$

Eşitlik (12) için  $n_1$  ve  $n_0$  katsayıları sırasıyla  $X_i$  binary (ikili) vektördeki 1 ve 0’ların sayısını temsil eder. Model sonucunda aday çözüm ve seçili çözüm arasındaki farklılık en aza indirgenmeye çalışılmaktadır. Seçili çözümde 1 olan hanelerden (bitlerden) seçilir, aday çözüme aktarılır ve diğer bitler sıfırlanır.

$$M_{11} + M_{01} = n_1, \quad M_{10} \leq n_0,$$

$M_{01}, M_{10}, M_{11} \geq 0$  ve tam sayı olmak üzere;

$$\min \left[ \left( 1 - \frac{M_{11}}{M_{01} + M_{10} + M_{11}} \right) - \varphi \left( 1 - \frac{m_{11}}{m_{01} + m_{10} + m_{11}} \right) \right] \quad (12)$$

### 3.3. IbinABC Algoritması (IbinABC Algorithm)

Durgut (2020), binABC operatörünü iyileştirerek ibinABC algoritmasını önermiştir. ibinABC algoritması iki yeni düzenleme içermektedir. Bunlardan ilki komşuluk operatörünün birden fazla bit üzerinde uygulanmasıdır. Operatörün uygulanacağı bit sayısı Eşitlik (13)’e göre belirlenmektedir.

$$d_t = \text{rast}[0, a] + 0.1D * e^{-(t/t_{max})} + 1 \quad (13)$$

Eşitlik 10’da a yöntem parametresi olup, ölçeklendirme için kullanılmaktadır. D, problem boyutunu, t o anki iterasyon değerini,  $t_{max}$  ise maksimum iterasyon sayısını ifade eder.

Bir diğer düzenleme ise  $\varphi$  değişkenin seçili ( $X_i$ ) ve komsu ( $X_k$ ) çözümün uygunluk değerine göre belirlenmesidir. binABC algoritmasında  $\varphi$  değeri rastgele olarak belirlenmektedir. Böyle bir durumda, iki çözümün uygunluk değerlerinin bir önemi yoktur. ibinABC’de ise eğer komsu çözüm daha iyi ise komşuluk operatöründe komsu çözümün ilgili hanesi (biti) işleme daha fazla etkili olacak şekilde belirlenmektedir. Aksi durumda ise,  $\varphi$  iterasyon değerine göre Eşitlik (14) ’teki gibi belirlenmektedir.

$$\varphi = \begin{cases} \varphi_{max} - \frac{(\varphi_{max} - \varphi_{min})}{\varphi_{max}} t, & f(X_i) < f(X_k) \\ 0, & \text{aksi halde} \end{cases} \quad (14)$$

#### 4. Adaptif İkili Yapay Arı Kolonisi (Adaptive Binary Artificial Bee Colony)

İkili yapay arı kolonisi içerisine adaptif bir yapı eklemek için iki temel problemi yanıtlamak gerekmektedir. Bunlardan ilki operatörlerin başarısının nasıl değerlendirileceği ve atanacak kredinin nasıl belirleneceğidir. İkinci problem ise, operatörlerin mevcut kredilere göre nasıl seçileceğidir. Her iki problemde kendi içerisinde farklı sorunlar barındırmaktadır.

Bir operatöre kredi değeri atanması için ilk olarak operatörün önceki uygulamalardaki başarısı dikkate alınmalıdır. Üretilen komşu çözümlerin amaç değerine göre veya iyileşme durumuna göre ödül atanmalıdır. Bu çalışmada ödül değeri Eşitlik (15)'e göre belirlenmektedir.

$$\text{ödül} = \frac{PD}{GB} (f(x') - f(x)) \quad (15)$$

Burada, PD problem boyutunu, GB o ana kadar elde edilmiş en iyi çözümün amaç fonksiyon değerini,  $x'$  aday çözümü,  $x$  ise mevcut çözümü ifade etmektedir. Her bir komşu çözüm üretilmesi sonucunda ödül değeri hesaplanmakta ve eğer pozitif bir değer elde edilmiş ise dikkate alınmaktadır. Her iterasyon sonrasında operatörlerin toplam ödül değerleri belirlenmektedir. Ardından bu ödül değerlerine göre operatörlere kredi değeri ataması yapılmaktadır. Bu noktada, o iterasyondaki elde edilen ödül değerleri kullanılabilir gibi belirli sayıda iterasyondan elde edilecek ödüller de dikkate alınabilir. Önceki çalışmalarımızda (Durgut ve Aydın, 2020) görüldüğü üzere anlık ödül kullanımının yerine ortalama ve en yüksek ödül değerlerinin kredi atamasında kullanılması daha faydalı sonuçlar üretmektedir.

Her bir operatöre ait kredi değerleri belirlendikten sonra operatör seçimi için kullanılabilir farklı yaklaşımlar mevcuttur. Bunlardan ilki Probability Matching (PM) yaklaşımıdır. Bu yaklaşımda operatörlerin seçilme olasılığı kredi değerlerine göre dağıtılır. Eşitlik (16) kullanılarak her bir olasılığın o iterasyondaki seçilme olasılığı belirlenir.

$$p_{i,t} = p_{min} + (1 - (K - 1) * p_{min}) \frac{Kred_{i,t}}{\sum_{j=1}^K Kred_{j,t}} \quad (16)$$

Eşitlik (16)'daki  $K$  değişkeni kullanılacak operatör sayısını,  $p_{min}$  en kötü operatöre atanacak minimum olasılık değerini,  $Kred_{i,t}$  ise  $i$ . operatörün kredi değerini ifade etmektedir. Bir diğer operatör seçimi yöntemi olan

Adaptive Pursuit (AP) ise “kazanan tümünü alır” prensibini kullanır. En iyi operatör en yüksek olasılık değeri ile güncellenirken diğer operatörler minimum olasılığa sahip olur. Yöntemin olasılık atama eşitliği Eşitlik (17)'de verilmiştir.

$$p_{i,t+1} = \begin{cases} p_{i,t} + \beta(p_{max} - p_{i,t}), & \text{eğer } i_t = i_t^* \\ p_{i,t} + \beta(p_{min} - p_{i,t}), & \text{aksi durumda} \end{cases} \quad (17)$$

Eşitlik (17)'de  $\beta$  uyarılma katsayısı,  $i_t^*$  ise en yüksek krediye sahip operatördür. Bu iki yaklaşımda operatörlerin kullanım sayıları ile ilgilenmemektedir. Bu sebeple az kullanılan operatörlere öncelik tanımamaktadır. Upper Confidence Bound (UCB) yaklaşımında ise az fırsat bulan operatörlere daha fazla fırsat sunmak amacıyla kullanılmaktadır. Yöntem Eşitlik (18)'e göre operatörlere seçim olasılığı atamaktadır.

$$p_{i,t+1} = \begin{cases} 1 - (K - 1)p_{min}, & \text{eğer } i_t = i_t^* \\ p_{min}, & \text{aksi durumda} \end{cases} \quad (18)$$

$i_t^*$  ise Eşitlik (19)'a göre belirlenmektedir. Burada  $C$  ayarlama katsayısı  $n$  ise seçilme sayılarıdır.

$$i_t^* = \underset{i=1..K}{\operatorname{argmax}} \{kred_{i,t} + C \sqrt{\frac{2 \log \sum_{j=1}^K n_{j,t}}{n_{i,t}}}\} \quad (19)$$

Operatörlere olasılık değeri atanmasından sonra rulet tekerine seçim yöntemi uygulanarak, operatör seçim işlemi gerçekleştirilmektedir. Çalışmada kullanılan algoritmanın çalışma adımları Şekil 2'de verilmiştir.

#### Algorithm 2 Adaptif Yapay Arı Kolonisi

- 1: Başlangıç popülasyonunu oluştur.
- 2: Durdurma kriteri sağlanana kadar
- 3: Kullanılacak operatörleri seç ve Toplam ödülleri sıfırla.
- 4: Operatörü kullanarak komşu çözüm üret.
- 5: Seçili çözüm ile aday çözüm arasında aç gözlü seçim işlemi yap.
- 6: Ödül hesapla. Eğer ödül değeri pozitif ise toplam ödüle ekle.
- 7: Her besin kaynağı için olasılık değerini hesapla.
- 8: Olasılık değerine göre besin kaynağı seç.
- 9: Kullanılacak operatörleri seç ve Toplam ödülleri sıfırla.
- 10: Operatörü kullanarak komşu çözüm üret.
- 11: Seçili çözüm ile aday çözüm arasında aç gözlü seçim işlemi yap.
- 12: Ödül hesapla. Eğer ödül değeri pozitif ise toplam ödüle ekle.
- 13: Tüklenen besin kaynağı var ise yeni geçerli çözüm ile değiştir.
- 14: Operatör kredilerini güncelle.
- 15: Şimdiye kadar bulunan en iyi çözümü sakla

Şekil 2. Adaptif YAK çalışma adımları (Adaptive ABC working steps)

#### 5. Deneysel Çalışmalar (Experimental Studies)

KBSC problemi kapasite kısıtlı optimizasyon problemi olduğu için geçersiz çözümler mevcuttur. YAK içerisinde geçersiz çözümlere izin verilmediğinden dolayı, çözümler üzerinde onarma işlemi yapılması gerekmektedir. He vd. (2018) önerdikleri çalışmada aç gözlü bir onarma yaklaşımı

uygulamaktadır. Bu yaklaşımda elemanlar küme içerisindeki frekanslarına ve fayda değerlerine göre sıralanır. Ardından kapasite sınırını aşan en değersiz elemanlar çantadan çıkarılır. Eğer mevcut kapasitede hala eleman eklenebilecek yer mevcut ise, en yüksek fayda sağlayacak elemanlar çanta içerisine eklenir. Daha detaylı bilgi için (He vd., 2018), (Özsoydan, Bakyasoğlu, 2019) ve (Özsoydan, 2019) çalışmaları incelenebilir.

Yöntemlerin başarılarının karşılaştırılabilmesi için He vd. (2018) 30 problem örneği içeren veri kümesi oluşturmuşlardır. Tüm problem örnekleri  $m\_n\_x\_y$  formatına göre oluşturulmuştur.  $m$  ve  $n$  nesne ve eleman sayılarını ifade ederken  $x$  ve  $y$  elemanların yoğunluğunu ve toplam ağırlığın çanta kapasitesine oranını ifade etmektedir. Veri kümesini, nesne ve eleman sayısına göre üç farklı gruba ayrılmış olup sayıları 100'den 500'e kadar artmaktadır. Kullanılan örnek veri kümesi Tablo 1'de verilmiştir.

**Tablo 1.** Kullanılan problem örnekleri. (The problem instances)

Grup 1 ( $m > n$ )		Grup 2 ( $m = n$ )		Grup 3 ( $m < n$ )	
Örnek No	Örnek Adı	Örnek No	Örnek Adı	Örnek No	Örnek Adı
G1_1	sukp 100_85_0.1_0.75	G2_1	sukp 100_100_0.1_0.75	G3_1	sukp 85_100_0.1_0.75
G1_2	sukp 100_85_0.15_0.85	G2_2	sukp 100_100_0.15_0.85	G3_2	sukp 85_100_0.15_0.85
G1_3	sukp 200_185_0.1_0.75	G2_3	sukp 200_200_0.1_0.75	G3_3	sukp 185_200_0.1_0.75
G1_4	sukp 200_185_0.15_0.85	G2_4	sukp 200_200_0.15_0.85	G3_4	sukp 185_200_0.15_0.85
G1_5	sukp 300_285_0.1_0.75	G2_5	sukp 300_300_0.1_0.75	G3_5	sukp 285_300_0.1_0.75
G1_6	sukp 300_285_0.15_0.85	G2_6	sukp 300_300_0.15_0.85	G3_6	sukp 285_300_0.15_0.85
G1_7	sukp 400_385_0.1_0.75	G2_7	sukp 400_400_0.1_0.75	G3_7	sukp 385_400_0.1_0.75
G1_8	sukp 400_385_0.15_0.85	G2_8	sukp 400_400_0.15_0.85	G3_8	sukp 385_400_0.15_0.85
G1_9	sukp 500_485_0.1_0.75	G2_9	sukp 500_500_0.1_0.75	G3_9	sukp 485_500_0.1_0.75
G1_10	sukp 500_485_0.15_0.85	G2_10	sukp 500_500_0.15_0.85	G3_10	sukp 485_500_0.15_0.85

Yöntem üç farklı adaptif operatör seçimi (Probability Matching (PM), Adaptive Pursuit (AP) ve Upper Confidence Bound (UCB)) ile test edilmiştir. Ödül mekanizması olarak pencere boyunca ortalama ve en yüksek ödül miktarları karşılaştırılmıştır. Pencere boyutu olarak ise küçük (5) ve orta (25) değerleri test edilmiş olup, bu kavram yöntem içerisinde son 5 ve 25 iterasyon boyunca elde edilen ödül değerlerini temsil etmektedir. Minimum seçilme olasılığı ( $P_{min}$ ) ise 0.1 ve 0.2 değerleri için test edilmiştir. Yöntem parametresi olan  $Alpha$  için ise 0.1, 0.5 ve 0.9 değerleri kullanılmıştır.

Parametre ayarlama için literatürdeki çalışmalarda olduğu gibi G2\_6 problem örneği kullanılmıştır. Bu fazda 30 ve diğer çalıştırmalarda için algoritma 100 farklı kez çalıştırılmış ve sonuçlar tablo halinde görselleştirilmiştir. Popülasyon boyutu 20 olarak seçilmiştir. Maksimum iterasyon sayısının belirlenmesi için ise önceki çalışmalar referans alınarak eleman veya nesne sayısına göre büyük olan belirlenmiştir.

Tablo 2'de üç yöntem üzerinden parametre ayarlama için elde edilen sonuçlar görülmektedir. AP için en iyi konfigürasyonların; ortalama ödül, pencere uzunluğu için 5, minimum olasılık değeri için 0.2 ve  $Alpha$  katsayısı için 0.9 değerleri olduğu görülmektedir. PM için ise AP'den farklı olarak pencere uzunluğunun 5 olduğu görülmektedir. UCB ise diğer yöntemlerden farklı olarak daha küçük  $Alpha$  değeri için en başarılı sonuçlarını üretmiştir. Bu üç yöntem arasında en iyi

ortalama değer PM ile üretildiği için sonraki deneylerde bu yöntem kullanılmıştır.


Şekil 3'te yöntemlerin (PM için elde edilmiş en iyi konfigürasyon için) zamana bağlı olarak verilmiş kredilerin ortalama değerleri ve Şekil 4'te ödül değerleri verilmiştir. Başlangıçta daha çok başarılı çözüm üretilebildiği için, ödül değerleri ve buna bağlı olarak kredi değerleri de yüksektir. Fakat yeni üretilen çözümlerin iyileşme oranları ve sayıları azalmaya başladığında ödül değeri ve dolayısıyla kredi değerleri de azalmaktadır. Bu noktada operatör seçiminin farklılıkları oldukça azdır.

Şekil 5 ve Şekil 6'da ise, sırasıyla operatör kullanım sayıları ve başarılı çözüm üretme sayıları verilmiştir. Kullanım grafikleri de 30 çalıştırmanın ortalaması olarak verilmiştir. Her üç yaklaşımda da başlangıç iterasyonlarında ibinABC daha fazla kullanılmaktadır. Farklılık, seçilme sayılarıdır. AP yaklaşımı kredisine göre bu operatöre diğer yaklaşımlarda daha çok fırsat vermiştir. UCB algoritmasında geçişler daha yumuşak olmasına karşın, en sert geçişler AP yaklaşımındadır. PM yaklaşımında 100. İterasyondan sonra disABC daha çok öne çıkmaya başlamıştır.

**Tablo 2.** Parametre ayarlama için elde edilen sonuçlar (The results of parameter tuning)


Ödül	Pencere	$P_{min}$	Alpha	AP		PM		UCB	
				En iyi	Ortalama	En iyi	Ortalama	En iyi	Ortalama
Ortalama	5	0.1	0,1	10998	10658,63	11113	10719,8	10948	10650,2
			0,5	11012	10676,30	10961	10692,13	10892	10686,57
			0,9	10735	10638,30	11023	10693,8	11054	10693,07
			0,1	11039	10670,40	10889	10700,8	<b>11410</b>	<b>10697,23</b>
			0,5	11113	10667,50	11000	10697,07	11081	10712,23
			0,9	10793	10651,83	<b>11425</b>	<b>10713,03</b>	11057	10697,7
	25	0.2	0,1	11178	10709,37	11093	10679,13	10793	10667,37
			0,5	11106	10704,50	11081	10670,27	11113	10657,9
			0,9	11025	10672,17	11051	10652,43	11106	10663,37
			0,1	11093	10662,50	11305	10687,93	10889	10677,67
			0,5	11082	10682,70	10851	10667,5	11025	10692,53
			0,9	<b>11425</b>	<b>10708,63</b>	11139	10700,73	10804	10669,37
En Yüksek	5	0.1	0,1	11007	10657,13	11222	10704,13	11039	10684,9
			0,5	11046	10683,53	11064	10724,37	11113	10689,3
			0,9	10949	10690,63	11178	10692,93	10835	10666,57
			0,1	11093	10722,43	11093	10684,7	11093	10656,2
			0,5	11081	10691,70	11139	10666,73	10931	10660,97
			0,9	10949	10634,17	11057	10671,23	10953	10657,57
	25	0.2	0,1	11078	10683,90	11132	10691,23	11251	10693,33
			0,5	11425	10691,93	11251	10697,4	11113	10708,83
			0,9	10990	10707,43	11410	10723,53	10953	10688,03
			0,1	10968	10681,27	10860	10654,13	11093	10715,7
			0,5	11093	10695,57	10990	10700,33	11178	10724,33
			0,9	10966	10662,50	11037	10704,23	11132	10713,1

**Kredi Grafiği**




**Şekil 3.** Operatör seçim yöntemlerinin iterasyona bağlı kredi değerleri (The credit values of operator selection methods through iterations)

### Ödül Grafiği



Şekil 4. Operatör seçim yöntemlerinin iterasyona bağlı ödül değerleri (The reward values of operator selection methods through iterations)


### Operatör Kullanım Sayıları



Şekil 5. Operatör kullanım sayılarının iterasyona göre değişimi (The usage counters of operator selection methods through iterations)



### Operatör Başarılı Güncelleme Sayıları



Şekil 6. Operatör başarı sayılarının iterasyona göre değişimi (The succes counters of operator selection methods through iterations)

Önerilen yaklaşım ile elde edilmiş sonuçlar literatürde var olan diğer yöntemler ile karşılaştırmalı olarak Ek Tablo' da verilmiş olup, karşılaştırılan yöntemlere ait değerler (He, 2018) ve (Özsoydan vd., 2019) çalışmalarından doğrudan alınmıştır. Bu tabloda 100 farklı çalıştırma sonucunda elde edilmiş en iyi sonuç, ortalama, standart sapma değerleri verilmiştir. Geliştirilen yaklaşım ile karşılaştırılan diğer yöntemler; A-SUKP, BABC, ABCBin, BinDE, GPSO\*, GPSO algoritmalarıdır. A-SUKP, KBŞÇ problemi için önerilmiş yakınsama algoritmasıdır. GA, Genetik Algoritma, BABC ve ABCBin İkili YAK algoritmalarıdır. BinDE ikili diferansiyel evrim algoritması, GPSO\* ve GPSO ise ağırlıklı ikili parçacık sürüşü algoritmasıdır.

Elde edilen sonuçların anlamlılığını kolaylaştırmak adına, Tablo 3'te ilk problem grubu için algoritmaların başarı sıralamaları verilmiştir. Önerilen adaptif

operatör seçimi yaklaşımı hem diğer YAK düzenlemelerinden hem de güncel literatürdeki çalışmalar içerisinde ortalama başarı sırasına göre birinci sıradadır. Burada 10 farklı örnek için 7 kez en iyi çözümleri sunmuş 3 kez ise ikinci sırada kalmıştır. En yakın rakibi GPSO olmuştur.

Tablo 4'te ise, ikinci grup problem örnekleri için algoritmaların performansları karşılaştırılmıştır. Önerilen çalışma bu problem örnekleri içerisinde en

başarılı algoritma olmuştur. Burada 10 farklı örnek için 6 kez en iyi çözümleri sunmuş, 4 kez ise ikinci sırada kalmıştır. En yakın rakibi GPSO olmuştur.

Tablo 5'te ise, üçüncü grup problem örnekleri için algoritmaların performansları karşılaştırılmıştır. Önerilen çalışma bu problem örnekleri içerisinde en başarılı algoritma olmuştur. 10 farklı örnek için 7 kez en iyi çözümleri sunmuş 3 kez ise ikinci sırada kalmıştır. En yakın rakibi GPSO olmuştur.

Tablo 3. İlk grup problem örnekleri (G1\_1 – G1\_10) için algoritmaların performansları (The performance of algorithms on first group problem instances)

P. No	A-SUKP	GA	BABC	ABCBin	binDE	GPSO*	GPSO	PMABC
G1_1	7	3	5	8	6	4	2	1
G1_2	8	7	2	5	4	6	3	1
G1_3	8	6	4	7	5	3	1	2
G1_4	8	5	4	7	6	3	2	1
G1_5	8	6	3	7	5	4	2	1
G1_6	8	3	5	7	6	4	2	1
G1_7	7	4	5	8	6	3	1	2
G1_8	7	5	4	8	6	3	2	1
G1_9	8	6	3	7	4	5	1	2
G1_10	8	7	4	3	6	5	2	1
Ortalama:	7,7	5,2	3,9	6,7	5,4	4	1,8	1,3

**Tablo 4.** İkinci grup problem örnekleri (G2\_1 – G2\_10) için algoritmaların performansları (The performance of algorithms on second group problem instances)

P. No	A-SUKP	GA	BABC	ABCBin	binDE	GPSO*	GPSO	PMABC
G2_1	8	5	4	7	6	3	2	1
G2_2	8	7	2	6	4	5	3	1
G2_3	8	6	3	7	5	4	2	1
G2_4	8	3	5	7	6	4	2	1
G2_5	7	6	3	8	5	4	1	2
G2_6	7	4	5	8	6	3	2	1
G2_7	8	5	4	7	6	3	1	2
G2_8	8	6	3	7	5	4	1	2
G2_9	8	6	3	7	4	5	1	2
G2_10	8	6	3	7	4	5	2	1
Ortalama:	7,8	5,4	3,5	7,1	5,1	4	1,7	1,4

**Tablo 5.** Üçüncü grup problem örnekleri (G3\_1 – G3\_10) için algoritmaların performansları (The performance of algorithms on third group problem instances)

P. No	A-SUKP	GA	BABC	ABCBin	binDE	GPSO*	GPSO	PMABC
G3_1	8	5	3	7	4	6	2	1
G3_2	8	7	1	5	3	6	4	2
G3_3	8	6	3	7	4	5	1	2
G3_4	8	6	3	7	4	5	2	1
G3_5	8	5	4	7	6	3	2	1
G3_6	8	6	3	7	5	4	2	1
G3_7	8	6	3	7	5	4	1	2
G3_8	8	4	5	7	6	3	2	1
G3_9	8	3	5	7	6	4	2	1
G3_10	8	6	3	7	4	5	2	1
Ortalama:	8	5,4	3,3	6,8	4,7	4,5	2	1,3

## 6. Sonuçlar (Conclusions)

Temel metasezgisel optimizasyon algoritmalarının başarısı kullandıkları komşu çözüm üretme operatörleri ile doğrudan ilişkilidir. Bu operatörün yerel minimumdan kurtulabilme ve hızlı yakınsama kabiliyetlerine aynı anda sahip olması oldukça zordur. Bu kabiliyetleri kazandırabilmek için yöntemlerin arama uzayının koşullarına göre adaptif olması gerekmektedir. Bu adaptasyon sayesinde zor problemlerin çözümü hızlandırılabilir. Bu çalışmada yapay arı koloni algoritmasına adaptif operatör seçimi eklenerek, ilk kez, küme birleşimli sırt çantası problemleri üzerindeki etkisi ortaya konulmuştur. Ele alınan problem için, üç farklı operatör seçim yöntemi ile yapay arı kolonisinin birleştirilmesi ve detaylı parametre analizi yapılmış olup, en iyi konfigürasyon belirlenmiştir. En iyi konfigürasyonda son 5 iterasyon boyunca elde edilmiş ödüllerin ortalama değerleri kullanılması halinde en iyi çözümler elde edilmiştir. Ardından, 30 farklı problem örneği için üretilmiş çözümler literatürdeki çalışmalar ile karşılaştırılmıştır. Karşılaştırma sonucunda önerilen yöntemin literatürdeki çalışmalardan daha gürbüz çözümler ürettiği görülmüştür.

Sonraki çalışmalarda, Operatör sayısının artırılarak KBŞÇ problemi üzerindeki etkisi incelenebilir. Bu sayede operatörlerin problem üzerindeki etkinliği ortaya konulabilir.

## Kaynaklar (References)

- Arani, B.O., Mirzabeygi, P., Panahi, M.S., 2013, "An improved PSO algorithm with a territorial diversity-preserving scheme and enhanced exploration-exploitation balance.", *Swarm and Evolutionary Computation*, 11,1-15.
- Arulselvan, A., 2014, "A note on the set union knapsack problem.", *Discrete Applied Mathematics*, 169, 214-218.
- Bansal, J.C., 2019, "Particle swarm optimization. In *Evolutionary and swarm intelligence algorithms*", Springer, Cham, 11-23.
- Bitran, G.R., Hax, A.C., 1981, "Disaggregation and resource allocation using convex knapsack problems with bounded variables.", *Management Science*, 27(4), 431-441.
- Brethauer, K.M., Shetty, B., 2002, "The nonlinear knapsack problem-algorithms and applications." *European Journal of Operational Research* 138(3), 459-472.
- Durgut, R., Aydın, M.E., 2020, "Adaptive binary artificial bee colony algorithm.", *Applied Soft Computing*, 107054.
- Durgut, R., 2020, "Improved binary artificial bee colony algorithm.", *arXiv preprint, arXiv, 2003(11641)*.
- Eberhart, R., Kennedy, J., 1995, "A new optimizer using particle swarm theory.", *MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science*. Ieee.
- Fialho, A., 2010, "Analyzing bandit-based adaptive operator selection mechanisms.", *Annals of Mathematics and Artificial Intelligence*, 60(1-2), 25-64.
- García, J., Lalla-Ruiz, E., Voss, S. and Droguett, E. L., 2020, "Enhancing a machine learning binarization framework by perturbation operators: analysis on the multidimensional knapsack problem", *International Journal of Machine Learning and Cybernetics*, 1-20.

- Goldschmidt, O., Nehme, D., Yu., G., 1994, "Note: On the set-union knapsack problem." *Naval Research Logistics (NRL)*, 41(6),833-842.
- He, Y., 2018, "A novel binary artificial bee colony algorithm for the set-union knapsack problem.", *Future Generation Computer Systems*, 78, 77-86.
- Holland, J., 1975, "Adaptation in natural and artificial systems: an introductory analysis with application to biology.", *Control and artificial intelligence*.
- Karaboga, D., Basturk.B., 2008, "On the performance of artificial bee colony (ABC) algorithm.", *Applied soft computing*, 8(1),687-697.
- Karaboga D.,2005 "An Idea Based on Bee Swarm for Numerical Optimization", Technical Report-TR06.
- Kashan, M.H., Nahavandi, N. and Kashan, A. H., 2012, "DisABC: A new artificial bee colony algorithm for binary optimization.", *Applied Soft Computing*, 12(1),342-352.
- Kiran, M.S., Gündüz, M., 2003, "XOR-based artificial bee colony algorithm for binary optimization.", *Turkish Journal of Electrical Engineering & Computer Sciences*, 21(2), 2307-2328.
- Klamroth, K., Margaret, M.W., 2000, "Dynamic programming approaches to the multiple criteria knapsack problem.", *Naval Research Logistics (NRL)*, 47(1), 57-76.
- Kiran, M.S., 2015, "The continuous artificial bee colony algorithm for binary optimization.", *Applied Soft Computing*, 33, 15-23.
- Lin, G., Xu, H., Chen, X., Guan, J., 2020, "An effective binary artificial bee colony algorithm for maximum set k-covering problem.", *Expert Systems with Applications*, 161, 113717.
- Mirjalili, S., 2019, "Genetic algorithm. In *Evolutionary algorithms and neural networks* ", Springer, Cham, 43-55.
- Moradi, N., Kayvanfar, V., Rafiee, M., 2021, "An efficient population-based simulated annealing algorithm for 0-1 knapsack problem", *Engineering with Computers*, 1-20.
- Odlyzko, A.M., 1990, "The rise and fall of knapsack cryptosystems.", *Cryptology and computational number theory*, 42, 75-88.
- Ozsoydan, F.B., Baykasoglu, A., 2019, "A swarm intelligence-based algorithm for the set-union knapsack problem.", *Future Generation Computer Systems*, 93, 560-569.
- Ozsoydan, F. B., 2019, "Artificial search agents with cognitive intelligence for binary optimization problems.", *Computers & Industrial Engineering*, 136, 18-30.
- Wei, Z., Hao, J. K., 2021, "Kernel based tabu search for the Set-union Knapsack Problem", *Expert Systems with Applications*, 165, 113802.
- Wang, H., Wang, W., Xiao, S., Cui, Z., Xu, M., Zhou, X., 2020, "Improving artificial bee colony algorithm using a new neighborhood selection mechanism.", *Information Sciences*, 527, 227-240.
- Xiang, W.L., Li, Y.Z., He, R.C., An, M.Q., 2021, "Artificial bee colony algorithm with a pure crossover operation for binary optimization", *Computers & Industrial Engineering*, 152, 107011.

## Ek (Appendix)

**Ek Tablo:** Problem örnekleri üzerinde yöntemlerden elde edilen sonuçlar (Results obtained from methods on problem instances).

P. No	A-SUKP			GA			BABC			ABCBin			binDE			GPSO*			GPSO			PMABC		
	En iyi	Ort	Std	En iyi	Ort	Std	En iyi	Ort	Std	En iyi	Ort	Std	En iyi	Ort	Std	En iyi	Ort	Std	En iyi	Ort	Std	En iyi	Ort	Std
G1_1	12459	12459	0	13044	12956	130.66	13251	13029	92.63	13044	12819	153.06	13044	12991	75.95	13167	12937	190	13283	13051	37.41	13251	13056,31	44
G1_2	11119	11119	0	12066	11546	214.94	12238	12155	53.29	12238	12049	96.11	12274	12124	67.61	12210	11778	277	12274	12085	95.38	12274	12137,04	60
G1_3	11292	11292	0	13064	12493	320.03	13241	13064	99.57	12946	11862	324.65	13241	12941	205.7	13302	12766	305	13405	13287	93.18	13405	13266,85	110
G1_4	12262	12262	0	13671	12803	291.66	13829	13359	234.99	13671	12537	289.53	13671	13110	269.69	13993	12949	326	14044	13493	328.72	14215	13640,36	223
G1_5	8941	8941	0	10553	9981	142.97	10428	9995	154.03	9751	9339	158.15	10420	9899	153.18	10600	10090	236	11335	10670	227.85	11411	10702,97	163
G1_6	9432	9432	0	11016	10350	215.13	12012	10903	449.45	10913	9958	276.9	11661	10499	403.95	11935	10750	525	12245	11607	477.8	12245	11711,15	293
G1_7	9076	9076	0	10083	9642	168.94	10766	10065	241.45	9674	9188	167.08	10576	9681	275.05	10698	9947	295	11484	10916	367.75	11244	10733,08	229
G1_8	8514	8514	0	9831	9327	192.2	9649	9136	151.9	8978	8540	161.83	9649	9021	150.99	10168	9417	360	10710	9865	315.38	10328	10071,65	120
G1_9	9864	9864	0	11031	10568	123.15	10784	10452	114.35	10340	9910	120.82	10586	10364	93.39	11258	10566	260	11722	11185	322.98	11546	11195,34	142
G1_10	8299	8299	0	9472	8693	180.12	9090	8858	94.55	8789	8364	114.1	9191	8784	131.05	9759	8779	300	10022	9300	277.62	10194	9361,02	182
G2_1	13634	13634	0	14044	13806	144.91	13860	13735	70.76	13860	13547	199.11	13814	13676	119.53	13963	13740	120	14044	13855	96.23	14044	13920,20	91
G2_2	11325	11325	0	13145	12235	388.66	13508	13352	155.14	13498	13103	343.46	13407	13212	287.45	13498	12937	418	13508	13347	194.34	13508	13434,01	66
G2_3	10328	10328	0	11656	10889	237.85	11846	11194	249.58	11191	10424	197.88	11535	10969	302.52	11972	11233	369	12522	11899	391.83	12350	11890,76	211
G2_4	9784	9784	0	11792	10828	334.43	11521	10945	255.14	11287	10346	273.47	11469	10717	341.08	12167	11027	21	12317	11585	275.32	12317	11691,87	187
G2_5	10208	10208	0	12055	11755	144.45	12186	11946	127.8	11494	10922	182.63	12304	11865	160.42	12736	11934	294	12695	12411	225.8	12713	12583,80	127
G2_6	9183	9183	0	10666	10099	337.42	10382	9860	177.02	9633	9187	147.78	10382	9710	208.48	10724	9907	399	11425	10568	327.48	11093	10688,38	118
G2_7	9751	9751	0	10570	10112	157.89	10626	10101	196.99	10160	9549	141.27	10462	9976	185.57	11048	10400	282	11531	10959	274.9	11310	10861,11	140
G2_8	8497	8497	0	9235	8794	169.52	9541	9033	194.18	9033	8366	153.4	9388	8768	212.24	10264	9195	312	10927	9845	358.91	10725	9880,29	283
G2_9	9615	9615	0	10460	10185	114.19	10755	10328	91.61	10071	9738	111.64	10546	10228	103.32	10647	10205	190	10888	10681	125.36	10885	10637,93	82
G2_10	7883	7883	0	9496	8883	158.21	9318	9181	84.91	9262	9618	141.32	9312	9096	145.45	9839	9107	258	10194	9704	252.84	10176	9819,00	160
G3_1	10231	10231	0	11454	11093	171	11664	11183	184	11206	10880	164	11352	11075	119	11710	11237	169	12045	11487	138	12020	11590,33	171
G3_2	10483	10483	0	12124	11326	417	12369	12082	194	12006	11485	248	12369	11876	337	12369	11684	354	12369	11994	437	12369	12156,68	184
G3_3	11508	11508	0	12841	12237	198	13047	12523	201	12308	11668	177	13024	12278	234	13298	12514	356	13696	13204	367	13609	13307,07	136
G3_4	8621	8621	0	10920	10352	208	10602	10151	153	10376	9684	185	10547	10085	161	10856	10208	264	11298	10801	206	11298	10817,49	140
G3_5	9961	9961	0	10994	10640	127	11158	10776	117	10269	9957	141	11152	10661	150	11310	10762	199	11568	11318	183	11538	11217,25	191
G3_6	9618	9618	0	11093	10190	250	10528	9898	187	10051	9424	197	10528	9832	233	11226	10309	389	11517	10899	300	11590	11042,90	217
G3_7	8672	8672	0	9799	9433	164	10085	9538	185	9235	8905	112	9883	9315	192	8971	9552	234	10483	10013	202	10397	9955,62	105
G3_8	8064	8064	0	9173	8704	154	9456	9090	157	8932	8407	149	9352	8847	211	9389	8881	283	10338	9525	286	9865	9439,48	141
G3_9	9559	9559	0	10311	9993	118	10823	10483	228	10537	9615	151	10728	10159	198	10595	10145	200	11094	10688	168	11018	10603,61	126
G3_10	8157	8157	0	9329	8849	142	9333	9086	116	8799	8348	123	99218	8920	169	9807	8917	267	10104	9383	241	9686	9389,84	125