



STOKASTİK KULLANICI DENGESİ TRAFİK ATAMA PROBLEMİNİN SEZGİSEL METOTLAR KULLANILARAK ÇÖZÜLMESİ

(HEURISTIC METHODS FOR SOLVING STOCHASTIC USER EQUILIBRIUM TRAFFIC ASSIGNMENT PROBLEM)

Özgür BAŞKAN*, Soner HALDENBİLEN*

ÖZET/ABSTRACT

Bu çalışmada Stokastik Kullanıcı Dengesi (SKD) trafik atama probleminin çözümü için sezgisel metot tabanlı yeni bir çözüm algoritması önerilmiştir. Karınca Kolonisi Optimizasyonu (KKO) ve Armoni Araştırması Tekniği (AAT) kullanılarak oluşturulan Karınca Kolonisi Stokastik Trafik Atama (KAKOSTA) ve Armoni Araştırması Stokastik Trafik Atama (ARASTA) modelleri SKD trafik atama probleminin çözümünde kullanılmıştır. Geliştirilen modellerde, sürücülerin güzergah seçim davranışları probit güzergah seçim modeli kullanılarak temsil edilmekte ve SKD problemi, eşdeğer optimizasyon problemi olarak tanımlanmaktadır. Önerilen modellerin test edilmesi için 1 adet Başlangıç-Variş (B-V) çifti, 5 adet bağ ve 3 adet güzergâhtan oluşan ulaşım ağı verilmiştir. Probit güzergah seçim olasılıklarının bulunabilmesi için Monte-Carlo simülasyon tekniğinden faydalanılmıştır. Ayrıca SKD atamasının sonuçları Deterministik Kullanıcı Dengesi (DKD) ataması sonuçları ile karşılaştırılmıştır. Sayısal uygulama sonucunda, SKD probleminin çözümünde ARASTA modeli hesaplama süresi açısından KAKOSTA modeline göre avantajlı olmasına rağmen KAKOSTA modelinin amaç fonksiyonunun en küçüklenmesinde daha başarılı olduğu görülmüştür. Ayrıca probit tabanlı SKD ataması ile elde edilen sonuçların gerçek sürücü davranışlarının modellenmesinde DKD atamasına göre daha gerçekçi olduğu ve probit tabanlı SKD probleminin sezgisel metotlar kullanılarak çözülebildiği görülmektedir.

In this study, a new solution algorithm based on heuristic methods is proposed in order to solve Stochastic User Equilibrium (SUE) traffic assignment problem. Ant Colony Optimization Stochastic Traffic Assignment (ACOSTA) and Harmony search Stochastic Traffic Assignment (HASTA) models which are formed using Ant Colony Optimization and Harmony Search, are used to solve the stochastic traffic assignment problem. In the proposed models, probit route choice model is used to represent driver's behaviour. SUE assignment is also described as equivalent optimization problem. In order to illustrate applications of the proposed models, test network is used which has one Origin-Destination (O-D) pair, five links and three paths. Monte-Carlo simulation method is used to find probit route choice probabilities. Furthermore, the results of SUE assignment are compared with the Deterministic User Equilibrium (DUE). Numerical example showed that ACOSTA model has more advantages when it is compared with the HASTA model especially in terms of the value of objective function although it requires more CPU time according to HASTA model. Moreover, SUE assignment based probit route choice is more realistic in accordance with DUE assignment and it can be solved using heuristic methods.

ANAHTAR KELİMELER/KEYWORDS

Stokastik kullanıcı dengesi, Trafik atama, Karınca kolonisi optimizasyonu, Armoni araştırması tekniği, Probit seçim modeli

Stochastic user equilibrium, Traffic assignment, Ant colony optimization, Harmony search, Probit choice model

* Pamukkale Üniversitesi, Müh. Fak., İnşaat Müh. Bölümü, DENİZLİ

1. GİRİŞ

Şehir içi ulaşım ağlarında gelişen teknoloji ve buna paralel olarak artan özel araç kullanımını sonucunda trafik sıkışıklıkları meydana gelmekte ve bu durum enerji kaybı ve gecikmelerin artması gibi olumsuz etkileri de beraberinde getirmektedir. Ulaşım ağlarında sıkışıklıktan dolayı oluşan problemlerin en aza indirgenebilmesi ancak ulaşım ağının modellenenebilmesi ile mümkün olabilmekte, bunun için ise Başlangıç-Variş (B-V) matrislerinin belirlenmesi, trafik atama probleminin çözülmesi ve ağ parametrelerinin optimum değerlerinin bulunması gerekmektedir. Trafik atama probleminde güzergâh akımlarının bulunmasında önerilen yöntem, güzergâh üzerinde seyahat eden her bir yol kullanıcısının kendi seyahat maliyetini en aza indireyecek şekilde bir yaklaşımdır. Bu yaklaşım, denge durumunda kullanılan bütün güzergâhlardaki seyahat maliyetinin aynı olacağı ve bu maliyetin kullanılmayan güzergâhlardaki seyahat maliyetinden daha az veya eşit olacağı kabulüne dayanır ve DKD olarak tanımlanabilmektedir. Ayrıca DKD durumunda hiçbir kullanıcı kendi güzergâhını değiştirerek seyahat maliyetini değiştirememektedir (Wardrop, 1952). Fakat gerçekte DKD durumundan farklı olarak sürücüler güzergâhlar hakkında tam olarak bilgi sahibi değildirler ve sürücülerin güzergâh seçimleri sırasında algılama hataları olmaktadır. Bu durumda ise stokastik kullanıcı davranışlarının dikkate alınması gerekir. Stokastik modellerde bütün sürücülerin tek bir maliyet tanımlaması yerine her bir sürücünün ayrı ayrı seyahat maliyeti tanımladığı kabulü geçerlidir. Stokastik atamada olasılık seçim modelleri kullanılarak B-V talebi güzergâhlara atanır, ayrıca en düşük maliyetli güzergâhların denge noktasına kadar en fazla akımı çektiği kabul edilir.

Bu çalışmada alternatif güzergâhlar arasında ortak kullanılan bağların varlığını dikkate alan ve bu nedenle gerçek sürücü davranışlarının temsil edilmesi için daha uygun olarak nitelendirilen probit güzergâh seçim modeli kullanılmıştır. SKD trafik atama probleminin çözümü için KKO ve AAT tabanlı KAKOSTA ve ARASTA modelleri geliştirilmiştir. Sonraki bölümde önceki çalışmalar, 3. bölümde güzergâh seçim modelleri, 4. bölümde KKO ve AAT sezgisel metotları, 5. bölümde SKD trafik atama modelleri, 6. bölümde sayısal uygulama ve son bölümde ise sonuçlar ve öneriler yer alacaktır.

2. ÖNCEKİ ÇALIŞMALAR

Trafik atama problemi üzerine 1970'li yılların başından itibaren birçok çalışma yapılmış olmasına karşın günümüzde tam olarak çözümlenememiş bir konu olması nedeni ile araştırmacılar açısından güncelliğini korumaktadır. İlk çalışmalar DKD atama modelleri ile başlamış ve problemin çözümünde eşdeğer matematiksel programlama kullanılmıştır (Beckmann vd., 1956). Daha sonraları günümüze kadar bilgisayar teknolojisinin gelişmesi ve güzergâh seçim modelleri konusundaki çalışmaların artması ile birlikte SKD trafik ataması konusundaki çalışmalar hız kazanmıştır. Literatürde sıkça kullanılan güzergâh seçim modelleri olarak *Logit*, *C-Logit* ve *Probit* modeller sayılabilir. Logit modelde tüm güzergâh alternatifleri istatistiksel olarak bağımsızmış gibi düşünülürken, C-logit ve probit modellerde alternatif güzergâhlar arasındaki bağımlılık dikkate alınmaktadır.

Sürekli ulaşım ağ tasarımı probleminin SKD ataması ile çözüldüğü çalışmada güzergâh seçim modeli olarak logit model ve atama probleminde ise eğim metodu ve ardışık quadratik algoritma olmak üzere iki farklı algoritma kullanılmıştır (Davis, 1994). Bu algoritmalar örnek ulaşım ağı üzerinde test edilmiştir. Her iki metodunda SKD atama problemini çözmeye başarılı olduğu görülmüştür. Logit modellerde sıkça karşılaşılan ve çakışan güzergâhlar arasındaki korelasyonun göz ardı edilmesi ile oluşan olumsuz durumdan kurtulabilmek için

probit seçim modeli tabanlı SKD atama modeli geliştirilmiştir (Maher ve Hughes, 1997). SKD problemindeki matematiksel formülasyonun çözülebilmesi için iteratif atama metodu kullanılmıştır. Şehir içi trafik kontrolü için güzergah akımlarının tahmin edildiği çalışmada eşdeğer konveks programlama problemi formüle edilmiş ve iteratif çözüm algoritması geliştirilmiştir (Bell vd., 1997). Logit modeldeki dağılım parametresinin tahmini konusunda araştırma yapılmış ve sütun üretme metodu güzergâh numaralandırılmasından kurtulmak için önerilmiştir. SKD ve sistem optimum kavramları altında yapılan atamada güzergah seçim modeli olarak çok değişkenli logit model kullanılmıştır (Prashker ve Bekhor, 1998). Stokastik çözüm süreci *Stoch* algoritması ile gerçekleştirilmiştir (Dial, 1971).

Sürekli ağ denge tasarım probleminin çözümü için iki seviyeli programlama tekniği kullanılmış, alt seviyede DKD akımları Wardrop prensibine dayanarak hesaplanmış ve eşdeğer minimizasyon problemi olarak formüle edilmiştir (Wardrop, 1952; Chiou, 2005). Önerilen metot sıklık etkisi altındaki ulaşım ağlarındaki denge atama problemlerinin çözümünde kullanılan metotlara göre oldukça etkili çözüm sağlamıştır. Farklı kullanıcı sınıfları ve değişken talep için probit güzergah seçim modeli kullanarak SKD atama modeli önerilmiştir (Connors vd., 2007). Modelde tasarım değişkenlerine karşı kullanıcıların duyarlı olduğu probit model kullanılmıştır. Değişken zaman şartları altında SKD ataması için yeni bir metot önerilen çalışmada güzergâh tabanlı çözüm algoritması geliştirilmiştir. Bu metodun geleneksel olarak kullanılan Frank-Wolfe algoritması ile karşılaştırıldığında daha uygun ve elverişli olduğu belirtilmiştir (Han, 2007).

Son yıllarda farklı alanlarda sezgisel metotların kullanıldığı çalışmalar mevcut olmakla birlikte KKO ve AAT yöntemlerinin probit tabanlı SKD ataması konusundaki kullanımı literatürde görülmektedir (D'Acerno vd., 2006; Kuan vd., 2006; Poorzahedy ve Abulghsami, 2005; Matteuchi ve Mussone, 2006). Bu nedenle çalışmada önerilen KAKOSTA ve ARASTA modelleri literatüre katkı sağlayacaktır.

3. GÜZERGAH SEÇİM MODELLERİ

Seyahat davranışının modellenmesi talep analizlerinin yapılabilmesinde oldukça önemlidir. Ulaşım ağındaki toplam seyahat talebi, bilindiği gibi bireysel olarak seyahat edenlerin seyahat davranışlarının toplamı olarak ifade edilebilir. A ve B gibi iki nokta arasında seyahat etmek isteyen yol kullanıcısı bu iki noktayı birbirine bağlayan birçok güzergâh arasında tercih yapmak zorundadır. Güzergâh seçimini etkileyen faktörler arasında güzergâhların özellikleri ve seyahat eden kişinin sosyo-ekonomik özellikleri sayılabilir. Güzergâh seçim modellerinde temel ilke, yol kullanıcılarının sürekli olarak en düşük maliyetli güzergâhı seçeceği yönündedir.

Stokastik modellerde herhangi bir yol kullanıcısı tarafından algılanan maliyet rastgele bir değişken olarak varsayılır ve güzergâh seçimi fayda maksimizasyonu veya maliyet minimizasyonu prensibine dayanılarak her bir kullanıcının algıladığı maliyete göre yapılır. SKD prensibi DKD yaklaşımına oldukça benzerdir fakat stokastik düşünce, herhangi bir yol kullanıcısının denge durumunda tek taraflı olarak güzergâhını değiştirerek seyahat maliyetini değiştiremeyeceği noktasında DKD yaklaşımından ayrılır. Seçim modellerinde her bir yol kullanıcısı güzergâh seçim durumunda güzergâhlar ile ilişkili fayda ve çekim özelliklerine bağlı olarak bir seçimle karşı karşıya kalır. Herhangi bir güzergâhın faydası güzergâh özelliklerinin fonksiyonu olmasının yanında ulaşım ağı karar vericilerinin de karakteristiklerini yansıtmaktadır. Karar vericiler en yüksek faydaya sahip güzergâhların seçileceğini kabul etmekle beraber faydalar kesin bir şekilde ölçülememektedir. Ayrıca, seyahat edenlerin faydalarını etkileyen birçok özellik gözlemlenebilir ve rastgele olarak

oluşturulabilir. Faydaların rastgele olarak modellenmesinden dolayı seçim modelleri seçimi vermek yerine seçim olasılığını vermektedir.

Güzergâh alternatifinin k adet olduğu bir ulaşım ağında, alternatiflerin fayda vektörü $U = (U_1, \dots, U_k)$ olarak gösterilebilir. Her bir alternatifin faydası karar vericinin gözlemlenen karakteristikleri ve alternatif güzergâhların gözlemlenen özelliklerinin fonksiyonu olarak matematiksel olarak ifade edilebilir. Gözlemlenen güzergâh karakteristiklerini ve özelliklerini a vektörü ile ifade edersek $U_k = U_k(a)$ olarak gösterilebilir. Güzergâhların gözlemlenemeyen karakteristikleri ve özelliklerinin güzergâh seçim etkilerini açıklayabilmek için her bir alternatifin fayda fonksiyonu; deterministik bileşen $V_k(a)$, ve rastgele hata terimi, $\xi_k(a)$, olmak üzere iki bileşenden oluşmaktadır (Oppenheim, 1995). Burada, $\xi_k(a)$ algılama hatalarının temsil edilmesinde kullanılan rastgele hata terimidir.

$$U_k(a) = V_k(a) + \xi_k(a) \quad \forall k \in K \quad (1)$$

Fayda fonksiyonunun rastgele bileşeninin beklenen değeri (E) sıfır olmakta ve $E[\xi_k(a)] = 0$ şeklinde ifade edilebilmektedir. Bu eşitlik $E[U_k(a)] = V_k(a)$ ifadesini doğrulamaktadır (Sheffi, 1985). Bu nedenle $U_k(a)$ algılanan fayda olarak tanımlanırken, $V_k(a)$ ise ölçülen fayda olarak tanımlanmaktadır. Bu durumda $P_k(a)$ ile gösterilen k rotasının seçim olasılığı aşağıdaki şekilde gösterilebilir.

$$P_k(a) = \Pr [U_k(a) \geq U_l(a), \forall l \in K] \quad \forall k \in K \quad (2)$$

Burada Pr ifadesi olasılık kavramını göstermektedir. Seçim olasılığı, $P_k(a)$, olasılık yoğunluk fonksiyonunun bütün özelliklerini taşımakta ve Eşitlik 3 ve Eşitlik 4'de verilen ifadeler yazılabilmektedir.

$$0 \leq P_k(a) \leq 1 \quad \forall k \in K \quad (3)$$

$$\sum_{k=1}^K P_k(a) = 1 \quad (4)$$

Güzergâh seçim modellerinde esas farklılık rastgele hata teriminin dağılımında yapılan kabuller sırasında oluşmaktadır. Seçim modelleri konusunda yapılan çalışmada ağ üzerindeki trafik akımının tamamının en düşük maliyetli güzergâhı kullanmaktansa B-V noktalarını birleştiren güzergâhlar arasında dağıtılacağı düşüncesi önerilmiştir (Dial, 1971). Bu yaklaşımda kullanılan logit seçim modelinin birtakım dezavantajları bulunmaktadır. Logit model çakışan güzergâhlardaki üst üste binen bağların özelliklerini dikkate almadığı için bu tür durumlar için uygun değildir. Probit modelin güzergâh seçim modeli olarak kullanılması durumunda ise çakışan güzergâhları göz önüne almasından dolayı ağ topolojisine duyarlı bir çözüm elde etmeye yardımcı olmaktadır (Daganzo ve Sheffi, 1977). Bu durum özellikle sıkışıklık etkisi altındaki ulaşım ağlarında sıkça görülen bir sorundur. Probit modelde seçim olasılıkları rastgele faydaların, Çok Değişkenli Normal Dağılıma (ÇDND) sahip olduğu varsayımıyla elde edilmektedir. Probit modelin çözümü için basitleştirici kabullerin yapılması oldukça önemlidir aksi takdirde kapalı form çözümü oldukça zor ve yavaş bir çözüm olmaktadır (Sheffi, 1985).

3.1. Probit Model

ÇDND fonksiyonu bilinen normal yoğunluk fonksiyonunun çok değişkenli olarak genişletilmiş hali olup probit modelde rastgele vektörün, $\xi = (\xi_1, \dots, \xi_k)$, dağılımını tanımlamaktadır. Bu dağılım, ortalama μ ve kovaryans matris Σ , ile tanımlanmakta ve $\xi \sim \text{ÇDND}(\mu, \Sigma)$ şeklinde ifade edilmektedir. Bu ifade ξ vektörünün, ortalama vektör μ ve kovaryans matris Σ ile ÇDND sergilediğini göstermektedir. Kovaryans matris rastgele vektörün bileşenlerinin varyanslarını içermekte ve Eşitlik 5'de verildiği gibi ifade edilmektedir.

$$(\Sigma)_{kk} = \text{var}(\xi_k) \quad \forall k \quad \text{ve} \quad (\Sigma)_{kl} = \text{cov}(\xi_k, \xi_l) \quad \forall k \neq l \quad (5)$$

Probit seçim modelinde verilen bir kovaryans matrisi ve alternatif özelliklerini belirleyen a vektörü için fayda vektörünün, $U(a)$, dağılımı ÇDND olarak Eşitlik 6'da verildiği gibi ifade edilebilmektedir.

$$U(a) \sim \text{ÇDND} [V(a), \Sigma] \quad (6)$$

Herhangi bir seçim modelinde alternatifin seçim olasılığı, o alternatifin faydasının seçim alternatifleri içindeki en yüksek faydaya sahip olma olasılığına göre hesaplanmaktadır. Probit modelde iki adet güzergâh seçim alternatifi olması durumunda seçim olasılıkları olasılık dağılım tabloları yardımıyla hesaplanabilmekte iken ikiden fazla alternatif olduğu zaman probit seçim olasılıklarının hesaplanması oldukça zor olmaktadır. Bu durumda yaklaşık analitik çözümler ya da Monte Carlo simülasyon metodu kullanılmaktadır. Literatürde probit seçim olasılıkları hesabı için birçok yaklaşık analitik metot önerilmiştir. Bunlar sayısal integrasyon algoritmaları ve ardışık yaklaşık metotlardır. Her iki metodunda büyük ölçekli ulaşım ağlarında seçim olasılıklarının hesaplanmasında oldukça fazla hesaplama yükü getirdiği bilinmektedir (Sheffi, 1985).

Alternatif sayısının fazla olması durumunda probit seçim olasılıklarının hesaplanmasında kullanılabilen diğer bir yöntem olan Monte Carlo metodunda mevcut alternatiflere ait fayda fonksiyonları için simülasyon algoritması iteratif olarak aşağıdaki gibi gerçekleştirilebilmektedir.

Adım 0: Başla. $n=1$ ise her bir bağ için hata terimleri ile ölçülebilen faydaları topla.

Adım 1: Her bir güzergah için algılanan faydaları hesapla.

Adım 2: En yüksek faydayı veren güzergahı kaydet.

Adım 3: Verilen simülasyon sayısına (N) ulaşıldıysa simülasyonu sonlandır aksi takdirde $n=n+1$ yap.

Buradan k . rotanın seçim olasılığı, P_k , aşağıdaki gibi bulunur;


$$P_k \cong \frac{N_k}{N} \quad (7)$$

Burada P_k ; k rotasının seçim olasılığı, N_k ; k rotasının kaydedilme sayısı, N ise Monte Carlo simülasyon sayısıdır. Çalışmada simülasyon sayısı 10 olarak alınmıştır (Başkan, 2009).

4. SEZGİSEL METOTLAR

4.1. Karınca Kolonisi Optimizasyonu

KKO son zamanlarda optimizasyon problemlerinin çözümünde kullanılan sezgisel bir yaklaşımdır (Dorigo ve Di Caro, 1999). İlk çalışmalarda KKO algoritması karınca sistemi olarak önerilmiş ve gezgin satıcı problemi üzerine uygulanmıştır. KKO algoritmaları gerçek karıncaların yiyecek bulma davranışlarının gözlemlenmesi ile ortaya çıkmıştır (Denebourg vd., 1983). Şekil 1'de görüldüğü gibi gerçek karıncalar yiyeceğe giden yolları üzerine bir engel koyulduğu zaman iki yoldan bir tanesini tercih edeceklerdir. Şekil 1 (a)'da görülen AE yolu üzerindeki karınca kolonisi yolu üzerinde Şekil 1 (b)'deki gibi bir engel olduğu zaman karıncalar engel etrafından dönebilmek için HB ve BC yollarından bir tanesini tercih edeceklerdir.




Şekil 1. Gerçek karınca davranışları (Colorni vd., 1991)

Tekniğin en temel unsurlarından biri haberleşme aracı olarak kullanılan ve problemlerde çözümün kalitesini gösteren gerçek karıncaların geçtikleri yollara bıraktıkları *feromon* kimyasalıdır. Feromon kimyasalı karıncalar tarafından güncellenmekte ve bir bilgiyi temsil etmektedirler. Bir yolda feromon izinin yoğun olması o yolun tercih edilme olasılığını artırmaktadır. Karınca kolonisi ilk olarak deterministik düşünceye göre eşit olasılıkta seçim yapacak ve kısa olan yolu tercih eden karıncalar yiyeceğe ulaşmış daha kısa zamanda yuvalarına geri döneceklerdir. Bu süreç sırasında karıncalar geçtikleri yerlere feromon denen kimyasal maddeyi bırakacaklar ve kısa olan yolda az bir zaman sonra daha fazla feromon birikmeye başlayacaktır (Şekil 1 (c)). Karıncalar bir sonraki turlarında artık feromonun fazla olduğu kısa olan yolu tercih etmeye başlayacaklar ve bir süre sonra karınca kolonisinin tamamına yakını yiyeceğe ulaşmak için kısa olan yolu tercih edecektir. Karıncaların bu davranış kalıplarının incelenmesi ile bu sistemin özellikle en kısa yol problemleri üzere pek çok optimizasyon probleminde kullanılabileceği ortaya atılmıştır (Dorigo, 1992; Dorigo ve Stützle, 2004).

Çalışmada kullanılan KKO yaklaşımında her bir karınca, bir önceki iterasyondaki en iyi karıncaya ve β vektörüne, $\beta=(\beta_1, \beta_2, \dots, \beta_n)$, bağlı olarak, aramaya iterasyonlar boyunca devam etmektedir (Başkan vd., 2009). KKO algoritması, başlangıç, feromon güncellenmesi ve çözüm evresi olmak üzere 3 ana kısımdan oluşmaktadır. Kullanılan KKO yaklaşımının ana

şekli Şekil 2’de verilmiştir. Şekilde görüldüğü gibi 5 adet karıncanın çözüm uzayı (ÇU) içinde optimum çözümü bulmak için rastgele aramaya başladığı farz edilirse başlangıç evresi denilen bu evrede *eski karınca kolonisi* oluşturulur. Bu aşamadan sonra feromon güncellenmesi gerçekleştirilir. Çözüm evresinde Eşitlik 8 ve Eşitlik 9 kullanılarak eski karınca kolonisinden elde edilen en iyi çözüm değerine göre *yeni karınca kolonisi* elde edilir. Elde edilen iki farklı karınca kolonisinin en iyi değerleri karşılaştırılır ($E_1 \leftrightarrow E'_1, E_2 \leftrightarrow E'_2, \dots, E_T \leftrightarrow E'_T$). İlk iterasyonun sonunda iki koloninin karşılaştırılması ile elde edilen en iyi değer ve β vektörü kullanılarak çözüm uzayı sınırlandırılır.



Şekil 2. KKO algoritması (Başkan vd., 2009)

Kullanılan KKO yaklaşımında m adet karınca m adet vektör olarak nitelendirilmiştir (x^k ($k = 1, 2, \dots, m$)). Her bir karıncanın çözüm vektörü Eşitlik 8 ile güncellenmektedir.

$$x_t^{k(yeni)} = x_t^{k(eski)} \pm \alpha \quad (t = 1, 2, \dots, T) \quad (8)$$

Burada $x_t^{k(yeni)}$ t . iterasyonda yeni elde edilen k . karınca vektörü, $x_t^{k(eski)}$ t . iterasyonda başlangıç evresinde üretilen k . karınca vektörü ve α sıçrama uzunluğunu hesaplamak için rastgele üretilen vektör olarak temsil edilmiştir. $x_t^{k(yeni)}$ t . iterasyonda Eşitlik 8 yardımıyla başlangıç evresinde elde edilen eski karınca vektörüne sıçrama uzunluğunun eklenmesi veya çıkartılmasıyla bulunur. Her bir iterasyonun son adımında iterasyonun başında üretilen koloni büyüklüğü kadar yeni bir karınca kolonisi oluşturulur. Eşitlik 8’de artı veya eksi işaretinin hangisinin kullanılacağı x_t^k ’nin optimum değer sağında veya solunda olmasına göre belirlenmektedir. Eğer x_t^k , optimum değer solunda ise pozitif tersi durumda ise negatif değeri kullanılmaktadır. Hareket yönü Eşitlik 9 ile aşağıdaki gibi belirlenebilmektedir.

$$\bar{x}_t^{eniye} = x_t^{eniye} + (x_t^{eniye} * 0.01) \quad (9)$$

Eğer $f(\bar{x}_t^{eniye}) \leq f(x_t^{eniye})$ ise Eşitlik 8’de (+) işareti kullanılır aksi durumda ise (-) işareti kullanılır. (\pm) işareti optimum değere ulaşmak için arama yönünü belirler. Feromon miktarı (τ_t) Eşitlik 10 kullanılarak ilk olarak gerçek karınca kolonilerini temsil edecek şekilde

buharlaştırılır daha sonra ise Eşitlik 11 yardımıyla feromon miktarı güncelleştirilir. Feromon miktarı sadece en iyi amaç fonksiyonu etrafında yoğunlaştırılır. Bu süreç verilen problemin çözümü için gerekli olan durma kriteri sağlanıncaya kadar devam ettirilir. Bu çalışmada başlangıç feromon miktarı 100 olarak alınmıştır.

$$\tau_t = 0.1 * \tau_{t-1} \quad (10)$$

$$\tau_t = \tau_{t-1} + 0.01 * f(x_{t-1}^{eniyi}) \quad (11)$$

4.2. Armoni Araştırması Tekniği

İlk olarak Geem vd. tarafından geliştirilen AAT, bir orkestradaki müzisyenlerin çaldıkları notalar ile armonik açıdan en iyi melodinin elde edilmesi prensibine dayanmaktadır (Geem vd., 2001). Bir orkestrada tüm orkestra elemanlarının birbirleri ile armonik açıdan uyumlu bir şekilde çalmaları ile en estetik melodiye yaklaşıırken, optimizasyon sürecinde en iyi çözüm amaç fonksiyonu değerinin global optimuma giderek yaklaşması sonucu elde edilebilmektedir (Ceylan ve Ceylan, 2009). AAT, taşkın modellemesi, su dağıtım şebekelerinin optimum tasarımı, sektörel enerji talebi modellemesi ve kafes sistemlerin optimum tasarımı gibi çeşitli mühendislik problemlerinin çözümüne uygulanmıştır (Kim vd., 2001; Geem, 2006; Ceylan vd., 2008; Saka, 2009). AAT süreci temel olarak 5 adımdan oluşmaktadır.

Adım 1: Problemin kurulması ve algoritma parametrelerinin tanımlanması

Eşitlik 12’de örnek bir optimizasyon problemi tanımlanmaktadır:

$$\min Z = F(x) \quad x_i \in \mathbf{x}_i, \quad i = 1, 2, \dots, N \quad (12)$$

Burada, $F(x)$ minimize edilecek olan amaç fonksiyonunu, x_i karar değişkenlerini (orkestradaki enstrümanları), \mathbf{x}_i her karar değişkeni için kullanılan çözüm vektörünü, N ise toplam karar değişkeni sayısını (orkestra büyüklüğünü) göstermektedir. Armoni araştırması çözüm sürecini kontrol eden 3 farklı parametre mevcuttur. Bunlar sırasıyla, armoni araştırmasındaki çözüm vektörü sayısı olan armoni belleği kapasitesi (ABK), armoni belleğinden (AB) yapılacak değişken seçimi oranı olan armoni belleğini dikkate alma oranı (ABDAO) ve ton ayarlama oranıdır (TAO).

Adım 2: Armoni belleğinin oluşturulması

Bu adımda, armoni belleği matrisi, rastgele üretilen çok sayıda çözüm vektörü ile doldurulur ve bu vektörler için ilgili amaç fonksiyonu değerleri hesaplanır.

$$\begin{bmatrix} x_1^1 & x_2^1 & \cdots & x_{N-1}^1 & x_N^1 \\ x_1^2 & x_2^2 & \cdots & x_{N-1}^2 & x_N^2 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_1^{ABK-1} & x_2^{ABK-1} & \cdots & x_{N-1}^{ABK-1} & x_N^{ABK-1} \\ x_1^{ABK} & x_2^{ABK} & \cdots & x_{N-1}^{ABK} & x_N^{ABK} \end{bmatrix} \Rightarrow \begin{bmatrix} f(x^1) \\ f(x^2) \\ \vdots \\ f(x^{ABK-1}) \\ f(x^{ABK}) \end{bmatrix} \quad (13)$$

Adım 3: Yeni armoninin oluşturulması

Bu adımda, yeni armoni vektörü $\mathbf{x}' = (x'_1, x'_2, x'_3, \dots, x'_N)$, armoni belleğinde bulunan tonlara göre ve/veya tamamen rastgele seçilen tonlara göre üretilmektedir. Armoni belleğinde bulunan tonlara göre, yeni armoni vektörüne ait ilk karar değişkeni x'_1 mevcut armoni belleği $(x_1^1, \dots, x_1^{ABK})$ içerisinde herhangi bir değerden rastgele olarak seçilmektedir. Seçim işleminin nasıl yapıldığı Eşitlik 14'de verilmiştir:

$$x'_i = \begin{cases} x'_i \in \{x_1^1, x_1^2, x_1^3, \dots, x_1^{ABK}\} & \text{ABDAO olasılığı durumu} \\ x'_i \in X_i & \text{(1-ABDAO) olasılığı durumu} \end{cases} \quad (14)$$

Bu aşamadan sonra, ton ayarlama işleminin gerekli olup olmadığının belirlenmesi için her karar değişkeninin değerlendirilmesi yapılmaktadır. Karar değişkenleri için bu işlem TAO parametresi ile aşağıda verildiği şekilde yapılmaktadır:

$$x'_i = \begin{cases} x'_i \pm rst * b_g & \text{TAO} \\ x'_i & \text{(1-TAO)} \end{cases} \quad (15)$$

Burada rst olarak verilen ifade (0-1) arasında üretilen rastgele sayıyı temsil etmekte, b_g ise kullanıcıya özel bant genişliği olarak kullanılmaktadır. Dikkat edilmesi gereken önemli bir nokta, ABDAO ve TAO parametrelerinin, algoritmanın sırasıyla global ve yerel optimum çözümleri elde etmesinde tetikleyici rol almasıdır. Çalışmada ABK, ABDAO ve TAO parametreleri için sırasıyla 20, 0.90 ve 0.30 değerleri kullanılmıştır (Lee vd., 2005).

Adım 4: Armoni belleğinin güncellenmesi

Bu adımda, yeni vektör bellek içindeki en kötü vektörden daha iyi bir sonuç veriyorsa belleğe dahil edilir ve en kötü vektör bellekten çıkarılır.

Adım 5: Durma kriterinin kontrolü:

Bu adımda verilen durma koşulunun sağlanıp sağlanmadığı kontrol edilir. Koşulun sağlanmaması durumunda, Adım 3 ile 5 arasındaki işlemler istenen koşul sağlanıncaya kadar tekrar edilir. Şekil 3'de AAT'nin algoritma adımları görülmektedir.

link maliyeti, t_a , ve varyansı, γt_a , olacak şekilde normal dağılım sergilediği kabul edilir ve Eşitlik 17'deki gibi ifade edilebilir.

$$T_a \sim (t_a, \gamma t_a) \quad (17)$$

Burada γ oransal sabit veya varyans sabiti olarak tanımlanmaktadır (Sheffi, 1985). γ Değeri çalışmada "1" olarak alınmıştır (Başkan, 2009). Eşitlik 18'de verilen algılanan güzergâh seyahat maliyetleri bağ-güzergâh belirleme matrisi kullanılarak elde edilebilir (Bell ve Lida, 1997).

$$C_k^{rs} = \sum_a T_a \delta_{a,k}^{rs} \quad \forall k, r, s \quad (18)$$

Burada C_k^{rs} , r ve s olarak belirtilen B-V çifti arasındaki k güzergâhı üzerindeki algılanan seyahat maliyeti, T_a , a bağı üzerindeki algılanan maliyet ve $\delta_{a,k}^{rs}$ ise bağ-güzergâh belirleme matrisinin elemanıdır. k güzergâhının algılanan maliyeti, üzerinde bulunan bağların algılanan maliyetlerinin toplamıdır ve normal dağılım özelliğinden dolayı algılanan güzergâh seyahat maliyetleri, ölçülebilen güzergâh maliyeti etrafında normal dağılır. Ayrıca r ve s B-V çifti arasındaki k güzergâhının varyansı Eşitlik 19'daki gibi gösterilebilir.

$$\text{var}(C_k^{rs}) = \sum_a \gamma t_a \delta_{a,k}^{rs} = \gamma c_k^{rs} \quad (19)$$

Burada c_k^{rs} , r ve s B-V çifti üzerindeki k güzergâhının ölçülebilen maliyetidir. Güzergâh seyahat maliyetleri bununla birlikte birbirlerinden bağımsız değildir. Eğer k ve l gibi iki güzergâh bazı bağları ortak kullanıyorsa ilgili güzergâhların algılanan seyahat maliyetleri birbiri ile ilişkilidir. Bu iki güzergâhın algılanan seyahat maliyetleri arasındaki kovaryans ortak kullandıkları bağ oranı ile ilişkili olup Eşitlik 20'de verildiği gibi gösterilebilir.

$$\text{cov}(C_k^{rs}, C_l^{rs}) = \sum_a \gamma t_a \delta_{a,k}^{rs} \delta_{a,l}^{rs} = \gamma c_{k,l}^{rs} \quad (20)$$

Burada, $c_{k,l}^{rs}$, r ve s B-V çifti arasındaki k ve l güzergâhlarının ortak kullandıkları bağlar üzerinde ölçülen seyahat süresidir. Algılanan güzergâh seyahat sürelerinin dağılımı, matris notasyonu kullanılarak ÇDND özelliklerinden üretilebilir. $T = (\dots, T_a, \dots)$ vektörünün algılanan bağ seyahat süre vektörünü temsil ettiği ve normal dağılımlı kabul edilmesi durumunda Eşitlik 21'de verilen ifade yazılabilir.

$$T \sim \text{ÇDND}(t, \Sigma) \quad (21)$$

Burada $t = (\dots, t_a, \dots)$ gerçek bağ maliyetleri vektörü, $\Sigma = [\gamma t \cdot I]$ kovaryans matris ve I ise birim matristir. Eşitlik 21'de verilen bağ kovaryans matrisi köşegeneldir. Köşegen üzerinde γt_a ile belirtilen varyans değerleri bulunmakla birlikte tüm kovaryans terimleri sıfırdır. r ve s B-V çifti arasındaki güzergâhlar için $(C^{rs} = (\dots, C_k^{rs}, \dots))$ algılanan seyahat

süreleri vektörü $C^{rs} = T \cdot \Delta^{rs}$ olarak belirtilebilir. Bu vektörün eklenik olasılık fonksiyonu Eşitlik 22'de verildiği gibidir. Burada Δ^{rs} , r ve s B-V çifti arasındaki bağ-güzergâh belirleme matrisidir.

$$C^{rs} \sim \text{ÇDND}(c^{rs}, \Sigma^{rs}) \quad \forall r, s \quad (22a)$$

Burada;

$$c^{rs} = t \cdot \Delta^{rs} \quad \forall r, s \quad (22b)$$

$$\Sigma^{rs} = \Delta^{rsT} \cdot [\gamma t \mathbf{I}] \cdot \Delta^{rs} \quad \forall r, s \quad (22c)$$

Sonuç olarak, Eşitlik 17- Eşitlik 22'nin kullanılması ile probit güzergâh seçim olasılıklarının bulunmasından sonra, SKD trafik ataması problemi Eşitlik 23'de görülen amaç fonksiyonunun minimum edilmesiyle çözülebilir (Ceylan, 2008).

$$v_a = \sum_{rs \in R} \sum_{k \in K_{rs}} f_k^{rs} \delta_{ak}^{rs}, \quad a \in A$$

$$\sum_{k \in K_{rs}} f_k^{rs} = q_{rs}, \quad rs \in R$$

$$f_k^{rs} \geq 0, \quad k \in K_{rs}, \quad rs \in R$$

Kısıtlarına bağlı olarak;


$$\min(f_1^1, \dots, f_k^{rs}; f_1^{1*}, \dots, f_k^{rs*}) = \sum_{rs \in R} \sum_{k \in K_{rs}} (f_k^{rs} - f_k^{rs*})^2 \quad (23)$$

Burada A yol ağındaki bağlar kümesi, R (B-V) kümesi, K_{rs} , $rs \in R$ B-V çiftindeki güzergâhlar kümesi, q_{rs} $rs \in R$ B-V seyahat talebi, f_k^{rs} $k \in K_{rs}$ güzergâhındaki akım, f_k^{rs*} $k \in K_{rs}$ güzergâhındaki denge akımı, v_a a bağındaki akım olup, δ_{ak}^{rs} ise bağ-güzergâh belirleme matrisinin elemanıdır ve aşağıdaki gibi ifade edilir:

$$\delta_{ak}^{rs} = 1, \quad rs \in R \text{ B-V çiftindeki } k \text{ güzergâhı } a \text{ bağımlı kullanıyorsa,}$$

$$\delta_{ak}^{rs} = 0, \quad \text{aksi durumda}$$


Şekil 4'de SKD atama probleminin çözümü için geliştirilen KAKOSTA ve ARASTA modellerinin akış diyagramı görülmektedir.



Şekil 4. KAKOSTA ve ARASTA modelleri akım şeması

6. SAYISAL UYGULAMA

Önerilen KAKOSTA ve ARASTA modellerinin test edilmesi için 1 adet B-V çifti, 5 adet bağ ve 3 adet güzergâhtan oluşan ulaşım ağı seçilmiştir. Şekil 5’de ulaşım ağı verilmiştir. Güzergâh 1 ve 2 tarafından bağ 1, güzergâh 2 ve 3 tarafından ise bağ 5 ortak kullanılmaktadır (*Güzergâh 1: 1-2, Güzergâh 2: 1-3-5, Güzergâh 3: 4-5*). Çizelge 1’de ulaşım ağına ait bilgiler verilmiştir. SKD trafik ataması probleminin çözümü için KAKOSTA ve ARASTA modelleri Visual Basic 6.0 dilinde kodlanmış ve Pentium Core2 2.00 Ghz bilgisayarda çalıştırılmıştır.



Şekil 5. Ulaşım ağı (Başkan, 2009)

Çizelge 1. Ulaşım Ağı Bilgileri (Başkan, 2009)


Bağ No	Bağ Kapasitesi (taşıt/saat)	Serbest Akım Seyahat Süreleri (t_a^0 (sn))
1	300	23
2	200	34
3	400	12
4	350	45
5	400	23

Örnek ağ için B-V talebi 400 taşıt/saat olarak alınmıştır (Başkan, 2009). SKD trafik ataması probleminin çözümü için Eşitlik 23'de verilen amaç fonksiyonunun KAKOSTA modeli ile çözülmesi sonucu elde edilen yakınsama grafiği Şekil 6'da verilmiştir. B-V talebine uygun olarak ÇU sınırlandırma vektörü $\beta=(400, 400, 400)$ olarak alınmıştır. Şekilde görüldüğü gibi amaç fonksiyonu değerinin salınımı 160 iterasyondan sonra azalmaktadır. Amaç fonksiyonunun minimum değeri olarak 268 iterasyon sonunda 0.51 taşıt/saat değeri elde edilmiştir. KAKOSTA modeli ile SKD trafik atama probleminin çözümü 40.5 CPU süresidir. KAKOSTA modeli ile elde edilen SKD bağ akımları Çizelge 2'de görülmektedir.

Çizelge 2. KAKOSTA modeli SKD bağ akımları


Bağ No	Akım (taşıt/saat)	S^* (akım/kapasite)
1	320	1.07
2	160	0.80
3	160	0.40
4	80	0.23
5	240	0.60

*Kapasite Kullanma Oranı



Şekil 6. KAKOSTA modeli ile SKD trafik ataması yakınsama grafiği

Çizelge 2’de görüldüğü gibi 1 nolu bağ denge durumunda kapasite üstü çalışmaktadır. Bunun sebebi güzergah 3’ün maliyetinin oldukça fazla olması ve sürücülerin büyük bir oranının 1 ve 2 nolu güzergahları seçmesidir. 4 nolu bağın maliyetinin diğer bağlara göre daha fazla olmasına rağmen SKD ataması sonucu güzergah 3’ün toplam talebin % 20’sini aldığı görülmektedir. Şekil 5’de verilen örnek ulaşım ağının ARASTA modeli ile çözülmesi ile Şekil 7’de verilen yakınsama grafiği elde edilmiştir.



Şekil 7. ARASTA modeli ile SKD trafik ataması yakınsama grafiği

ARASTA modeli ile SKD trafik ataması probleminin çözümü işleminde 9.8 CPU süresi sonunda amaç fonksiyonunun minimum değeri olarak 5.41 taşıt/saat değeri elde edilmiştir. Çizelge 3’de ARASTA modeli ile elde edilen bağ akımları verilmiştir. Çizelgeden

görülebileceği gibi elde edilen sonuçlar KAKOSTA modeli ile elde edilen sonuçlara oldukça yakındır. Ayrıca ARASTA modeli ile çözüm KAKOSTA modeline göre yaklaşık %75 oranında daha kısa sürede gerçekleştirilebilmektedir. Ancak her iki model ile elde edilen amaç fonksiyonu değerleri karşılaştırıldığı zaman KAKOSTA modeli ile elde edilen amaç fonksiyonu değerinin ARASTA modeli ile elde edilen değere göre oldukça düşük olduğu görülebilir. Bu nedenle SKD trafik ataması probleminin çözümünde KAKOSTA modeli, CPU süresi açısından ARASTA modeline göre başarısız olmasına rağmen amaç fonksiyonu değerinin en küçüklenmesi açısından ARASTA modeline göre daha başarılıdır.

Çizelge 3. ARASTA modeli SKD bağ akımları

Bağ No	Akım (taşıt/saat)	S* (akım/kapasite)
1	323	1.08
2	161	0.81
3	162	0.41
4	73	0.21
5	234	0.59

*Kapasite Kullanma Oranı

SKD yaklaşımından farklı olarak DKD prensibine göre sürücüler B-V çifti arasındaki güzergahların ölçülebilen maliyetlerine göre seçim yapacaklar ve tüm sürücüler en düşük maliyetli güzergahı seçecektir. Çizelge 4'de DKD trafik ataması durumu için elde edilen denge bağ akımları verilmiştir. DKD trafik ataması Ardışık Ortalamalar Yöntemi (AOY) kullanılarak gerçekleştirilmiştir (Başkan, 2009). SKD atamasına göre 4 nolu bağın çok daha az akım aldığı ve güzergah 3 seçeneğinin seçilme olasılığının oldukça düşük olduğu görülmektedir.

Çizelge 4. DKD bağ akımları

Bağ No	Akım (taşıt/saat)	S* (akım/kapasite)
1	381	1.27
2	152	0.76
3	229	0.57
4	19	0.05
5	248	0.62

*Kapasite Kullanma Oranı

DKD trafik ataması yapılması durumunda 1 nolu bağın kapasitesinin oldukça üstünde hizmet verdiği Çizelge 4'de görülmektedir. 1 nolu bağın, 1 ve 2 nolu güzergâhlar tarafından ortak kullanılması ve ilgili güzergâhların maliyetlerinin 3 nolu güzergâha göre daha düşük olması nedeniyle DKD prensibi altında 1 nolu bağ kapasite üstü çalışmakta iken 3 nolu güzergâh ise toplam talebin ancak % 5'ni çekebilmektedir. SKD yaklaşımı altında ise 3 nolu güzergâh B-V talebinin yaklaşık % 20'sini karşılamaktadır. Bu nedenle SKD yaklaşımının trafik atama probleminin çözümünde sürücülerin güzergâh seçimleri sırasında yapacakları

muhtemel algılama hatalarını yansıtması açısından DKD yaklaşımına oranla daha başarılı olduğu görülmektedir.

7. SONUÇLAR VE ÖNERİLER

Günümüzde trafik atama probleminin, sürücülerin seyahat ettikleri ağ ile ilgili bilgi düzeylerini ve yapılan seyahatlerdeki rastgeleliği de göz önünde bulunduran yaklaşımlar altında çözülme ihtiyacı bulunmaktadır. Literatürde trafik atama probleminin çözümü için DKD ve SKD yaklaşımları altında farklı metotlar bulunmakla birlikte daha etkin ve hızlı çözüm yöntemlerine ihtiyaç olduğu açıktır. Çalışmada KAKOSTA ve ARASTA modelleri probit tabanlı SKD probleminin çözümü için literatürde ilk defa uygulanmıştır.

SKD trafik atama probleminin çözümü için uygulanan KAKOSTA ve ARASTA modellerinde güzergah seçim olasılıklarının belirlenmesi için alternatif güzergahların ortak kullandıkları bağlar arasındaki kovaryans değerlerini de göz önünde bulunduran probit model kullanılmış ve probit rota seçim olasılıklarının hesaplanabilmesi için Monte-Carlo simülasyon tekniğinden faydalanılmıştır. Probit model gerçek sürücü davranışlarının modellenebilmesi, güzergahlar arasındaki korelasyonu dikkate alması ve sürücülerin bağ maliyetlerini algılamadaki farklılıklarını temsil etmesi açısından güzergah seçiminde oldukça önemlidir. Ayrıca güzergah seçim olasılıkları sürücüler tarafından algılanan maliyetler üzerinden hesaplanmakta ve sürücülerin güzergah seçiminde hata yapma olasılıkları da göz önüne alınmaktadır.

Önerilen modellerin çözüm yeteneğini göstermek amacıyla test ulaşım ağı üzerinde sayısal uygulama gerçekleştirilmiştir. Sonuçlara göre probit tabanlı SKD probleminin KAKOSTA ve ARASTA modelleri ile çözülebildiği görülmektedir. Sonuçlara göre ARASTA modeli CPU süresi açısından KAKOSTA modeline göre daha başarılı iken KAKOSTA modelinin amaç fonksiyonu değerinin en küçüklenmesi aşamasında ARASTA modeline göre daha başarılı olduğu bulunmuştur. Ayrıca DKD ataması sonuçları ile SKD atamasının sonuçları karşılaştırılmış ve SKD prensibinin gerçek sürücü davranışlarının modellenebilmesi açısından daha iyi sonuçlar verdiği görülmüştür. Gelecek çalışmalarda probit tabanlı SKD trafik ataması probleminin çözümü için uygulanan KAKOSTA ve ARASTA modellerinin daha büyük ve sıklık etkisi altındaki ulaşım ağlarındaki performansı incelenecektir.

SEMBOLLER ve KISALTMALAR

ABDAO	: Armoni belleğini dikkate alma oranı
ABK	: Armoni belleği kapasitesi
A	: Bağlar kümesi
a	: Gözlemlenen güzergah karakteristikleri vektörü
BPR	: Bağ maliyet fonksiyonu (Amerikan Karayolları Bürosu)
C_k^{rs}	: r - s başlangıç-varış çifti arasındaki k güzergâhının algılanan maliyeti
c_k^{rs}	: r - s başlangıç-varış çifti arasındaki k güzergâhının ölçülebilen maliyeti
$c_{k,l}^{rs}$: k ve l güzergâhlarının ortak kullandıkları bağlar üzerinde ölçülen maliyet
C^{rs}	: Algılanan güzergâh maliyetleri vektörü
c^{rs}	: Ölçülebilen güzergâh maliyetleri vektörü
c_a	: a bağının kapasitesi (taşıt/saat)

ÇDND	: Çok değişkenli normal dağılım
cov	: Kovaryans
E	: Eski karınca kolonisi
E'	: Yeni karınca kolonisi
E	: Beklenen değer
f_k^{rs}	: r - s başlangıç-varış çiftindeki $k \in K$ güzergâhındaki akım (taşıt/saat)
f_k^{rs*}	: r - s başlangıç-varış çiftindeki $k \in K$ güzergâhındaki denge akımı (taşıt/saat)
I	: Birim matris
int	: Tamsayı değer
k	: Alternatif güzergâh sayısı
K_{rs}	: $rs \in R$ başlangıç-varış çiftindeki güzergâhlar kümesi
l_a	: a bağıının uzunluğu
m	: Karınca sayısı
N	: Monte-Carlo benzetim sayısı
N_k	: k güzergâhının kaydedilme olasılığı
P_k	: k güzergâhının seçilme olasılığı
Pr	: Olasılık ifadesi
R	: Başlangıç-varış çiftleri kümesi
q_{rs}	: $rs \in R$ başlangıç-varış çiftindeki seyahat talebi
TAO	: Ton ayarlama oranı
T	: Algılanan bağ maliyetleri vektörü
t	: Ölçülebilen bağ maliyetleri vektörü
t_a^0	: a bağı üzerindeki serbest akım seyahat süresi (sn)
t_a	: q akımında a bağı üzerindeki seyahat süresi (sn)
T_a	: a bağıının algılanan maliyeti (sn)
U_k	: k güzergâhının algılanan faydası
var	: Varyans
V_k	: k güzergâhının ölçülen faydası
v_a	: a bağıındaki akım (taşıt/saat)
$x_t^{k(yeni)}$: t . iterasyonda yeni üretilen k . karınca vektörü
$x_t^{k(eski)}$: t . iterasyonda başlangıç evresinde üretilen k . karınca vektörü
x_t^{eni}	: t . iterasyonda başlangıç evresindeki en iyi karınca vektörü
ξ	: Rastgele hata terimi
μ	: Ortalama vektör
Σ	: Kovaryans matris
β	: Karınca Kolonisi çözüm uzayı sınırlandırma vektörü
τ_t	: Feromon miktarı
α	: Sıçrama uzunluğu
γt_a	: a bağıının varyansı
γ	: Varyans sabiti
$\delta_{a,k}^{rs}$: r - s başlangıç-varış çifti arasındaki bağ-güzergâh belirleme matrisi elemanı
Δ^{rs}	: r - s başlangıç-varış çiftindeki bağ-güzergâh belirleme matrisi

KAYNAKLAR

- Başkan Ö. (2009): “Karınca Kolonisi Optimizasyonu ile Ulaşım Ağ Tasarımı”, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, s. 140.
- Başkan O., Haldenbilen S., Ceylan H., Ceylan H. (2009): “A New Solution Algorithm for Improving Performance of Ant Colony Optimization”, *Applied Mathematics and Computation*, 211 (1), s. 75-84.
- Beckmann M. J., McGuire C. B., Winsten C. B. (1956): “Studies in the Economics of Transportation”, Yale University Press, New Haven, Conn.
- Bell M. G. H., Lida Y. (1997): “Transportation Network Analysis”, John Wiley and Sons, Chichester, UK.
- Bell M. G. H., Shield, C. M., Busch F., Kruse G. (1997): “A Stochastic User Equilibrium Path Flow Estimator”, *Transportation Research Part C*, 5, s. 1972-210.
- Ceylan H. (2008): “Genetik Algoritma ve Oyun Teorisi Yaklaşımları ile Şehir İçi Trafik Yönetimi”, Tübitak Kariyer Projesi (104I119), 7. ara rapor, s. 58.
- Ceylan H., Ceylan H. (2009): “Şehir İçi Karayolu Ağlarının Ayrık Tasarımında Sezgisel Armoni Araştırması Yöntemi Uygulaması”, İstanbul, 8. Ulaştırma Kongresi, s. 195-208.
- Ceylan H., Ceylan H., Haldenbilen S., Baskan O. (2008): “Transport Energy Modeling with Meta-Heuristic Harmony Search Algorithm, an Application to Turkey”, *Energy Policy* 36, s. 2527-2535.
- Chiou S. W. (2005): “Bilevel Programming for the Continuous Transport Network Design Problem”, *Transportation Research Part B*, 39, s. 361-383.
- Colomi A., Dorigo M., Maniezzo V. (1991): “Distributed Optimization by Ant Colonies”, Paris, France, Proceedings of ECAL-European Conference on Artificial Life, s. 134-142.
- Connors R. D., Sumalee A., Watling D. P. (2007): “Sensitivity Analysis of the Variable Demand Probit Stochastic User Equilibrium with Multiple User-Classes”, *Transportation Research Part B*, 41, s. 593-615.
- D’Acerno L., Montella B., De Lucia F. (2006): “A Stochastic Traffic Assignment Algorithm Based on Ant Colony Optimization”, ANTS 2006, LNCS 4150, s. 25-36.
- Daganzo C., Sheffi Y. (1977): “On Stochastic Models of Traffic Assignment”, *Transportation Science*, 11, s. 253-274.
- Davis G. A. (1994): “Exact Local Solution of the Continuous Network Design Problem via Stochastic User Equilibrium Assignment”, *Transportation Research Part B*, 28, s. 61-75.
- Denebourg J. L., Pasteels, J. M., Verhaeghe J. C. (1983): “Probabilistic Behavior in Ants: A Strategy of errors?”, *Journal of Theoretical Biology*, 10, s. 259-271.
- Dial R. (1971): “A Probabilistic Multipath Traffic Assignment Algorithm which Obviates Path Enumeration”, *Transportation Research* 5 (2), s. 83-111.
- Dorigo M., Di Caro G. (1999): “Ant Colony Optimization: A New Meta-Heuristic”, In: Proceedings of the 1999 Congress on Evolutionary Computation, Vol. 2, s. 1470-1477.
- Dorigo M. (1992): “Optimization, Learning and Natural Algorithms”, PhD Thesis, Politecnico di Milano, Italy.
- Dorigo M., Stützle T. (2004): “Ant Colony Optimization”, Cambridge, MIT Press.
- Geem Z. W. (2006): “Optimal Cost Design of Water Distribution Networks Using Harmony Search”, *Engineering Optimization* 38 (3), s. 259-280.
- Geem Z. W., Kim J. H., Loganathan G. V. (2001): “A New Heuristic Optimization Algorithm: Harmony Search”, *Simulation* 76 (2), s. 60-68.
- Han S. (2007): “A Route-Based Solution Algorithm for Dynamic User Equilibrium Assignments”, *Transportation Research Part B*, 41, s. 1094-1113.

- Kim J. H., Geem Z. W., Kim E. S. (2001): "Parameter Estimation of the Nonlinear Muskingum Model using Harmony Search", *Journal of the American Water Resources Association* 37 (5), s. 1131-1138.
- Kuan S. N., Ong H. L., Ng K. M. (2006): "Solving the Feeder Bus Network Design Problem by Genetic Algorithms and Ant Colony Optimization", *Advances in Engineering Software*, 37, s. 351-359.
- Lee K. S., Geem Z. W., Lee S. H., Bae K. W. (2005): "The Harmony Search Heuristic Algorithm for Discrete Structural Optimization", *Engineering Optimization*, 37 (7), s. 663-684.
- Maher M. J., Hughes P. C. (1997): "A Probit-Based Stochastic User Equilibrium Assignment Model", *Transportation Research Part B*, 31, s. 341-355.
- Matteuchi M., Mussone L. (2006): "Ant Colony Optimization Technique for Equilibrium Assignment in Congested Transportation Networks", Washington, USA, *Proceedings of the 8th annual conference on Genetic and evolutionary computation*, s. 87-88.
- Oppenheim N. (1995): "Urban Travel Demand Modeling: From Individual Choices to General Equilibrium", New York, John Wiley and Sons, Inc.
- Prashker J. N., Bekhor S. (1998): "Investigation of Stochastic Network Loading Procedures", *Transportation Research Record*, 1645, s. 94-102.
- Poorzahedy H., Abulghsami F. (2005): "Application of Ant System to Network Design Problem", *Transportation*, 32, s. 251-273.
- Saka M. P. (2009): "Optimum Design of Steel Sway Frames to BS5950 Using Harmony Search Algorithm", *J. of Constr. Steel Research* 65 (1), s. 36-43.
- Sheffi Y. (1985): "Urban Transport Networks: Equilibrium Analysis with Mathematical Programming Methods", New Jersey, USA, Prentice-Hall Inc., Englewood Cliffs.
- Wardrop J. G. (1952): "Some Theoretical Aspects of Road Traffic Research", *Proceedings of the Institute of Civil Engineers. Part II*, 1 (2), s. 325-378.