

# Logit ve Probit Tabanlı Stokastik Kullanıcı Dengesi Atama Probleminin İki Farklı Sezgisel Metot Kullanılarak Çözülmesi

**Özgür Başkan, Soner Haldenbilen**

Pamukkale Üniversitesi, Müh. Fak., İnş. Müh. Böl., Ulaştırma Anabilim Dalı, Denizli

Tel: (258) 2963392

E-Posta: obaskan@pau.edu.tr

Tel: (258) 2963361

E-Posta: shaldenbilen@pau.edu.tr

## Öz

Ulaşım ağlarında günden güne artan araç sahipliği ve kullanımı sonucunda oluşan trafik sıkışıklıklarının en aza indirgenebilmesi ancak ulaşım ağının modellenenebilmesi ile mümkün olabilmekte, bunun için ise Başlangıç-Varış (B-V) matrislerinin belirlenmesi, atama probleminin çözülerek güzergah ve bağlantı akımlarının bulunması gerekmektedir. Trafik atama sonucu elde edilen bağlantı akımlarına bağlı olarak kavşaklardaki sinyal sürelerinin düzenlenmesi ile sıkışıklık etkileri minimum seviyelere indirgenebilmektedir. Ulaşım Ağ Tasarım (UAT) probleminin alt seviyesini oluşturan trafik atama probleminin çözümü sırasında gerçek sürücü davranışlarının modellenenebilmesi açısından kullanılacak olan güzergah seçim modelinin seçimi de oldukça önem arz etmektedir. Literatürde sıkça kullanılan güzergah seçim modelleri olarak; logit, c-logit, nested-logit, ve probit model sayılabilir. Probit güzergah seçim modeli diğer güzergah seçim modellerinden çözüm yapısı olarak oldukça farklıdır. Güzergahlar arasındaki ortak kullanılan bağlantıları dikkate aldığı için gerçek sürücü davranışlarının yansıtılması açısından oldukça önemlidir. Bu çalışmada probit güzergah seçim olasılıklarının bulunabilmesi için monte carlo benzetim yönteminden faydalanılmıştır.

Sonuç olarak bu çalışmada trafik atama probleminin çözümü için logit ve probit güzergah seçim modelleri ile Karınca Kolonisi Optimizasyonu (KKO) ve Armoni Araştırması Optimizasyon Tekniği (AAT) sezgisel metotlarının kullanıldığı atama modelleri geliştirilmiştir. İki farklı güzergah seçim modeli ve farklı tipte iki sezgisel metodun kullanıldığı atama modelleri 5 bağlantı ve 3 güzergahtan oluşan örnek bir test ulaşım ağına uygulanmıştır. Ayrıca atama sonucu elde edilen denge bağlantı akımları deterministik çözümle kıyaslanmıştır. Sonuç olarak stokastik kullanıcı denge atamasının KKO ve AAT sezgisel metotları ile farklı tipte (logit ve probit ) güzergah seçim modelleri kullanılarak başarıyla gerçekleştirilebileceği test ulaşım ağı üzerinde gösterilmiştir.

**Anahtar sözcükler:** Trafik atama, güzergah seçim modelleri, sezgisel metot

## Giriş

Ulaşım Ağ Tasarım (UAT) problemi, ağ tasarımcıları ve uygulamacılar arasında büyük ilgi uyandırmakla birlikte son yıllardaki bilgisayar teknolojilerindeki gelişiminde etkisiyle bu konudaki çalışmalar sıklıkla kazanmıştır. UAT'nın etkili şekilde yapılabilmesi, Başlangıç-Variş (B-V) matrislerinin belirlenmesi, denge güzergah ve bağlantı akımlarının bulunması ve buna bağlı olarak ağ üzerindeki sinyalizasyon sistemlerinin en uygun şekilde tasarlanabilmesi ile mümkündür. UAT probleminin çözümünde en önemli noktalardan biri de yol kullanıcılarının ulaşım ağındaki herhangi bir B-V çiftindeki seyahatleri sırasında alternatif güzergahlara nasıl dağılacaklarının en doğru şekilde tahmin edilmesidir. Yol kullanıcılarının güzergah seçimi sırasında maliyet algılamalarını esnek bir şekilde ele alan ve buna rastgelelik ekleyen bir yaklaşım olan Stokastik Kullanıcı Dengesi (SKD) kavramı son yıllarda ulaşım ağ tasarımında benimsenmeye başlamıştır. Bu yaklaşımda, deterministik yaklaşımdan farklı olarak yüksek maliyetli güzergahların kullanıcılar tarafından seçilebilme ihtimalinin varlığından söz edilebilmektedir.

Güzergah akımlarının bulunmasında önerilen yöntem, güzergah üzerinde seyahat eden her bir yol kullanıcısının kendi seyahat maliyetini minimum edecek şekilde bir yaklaşımdır. Bu yaklaşım denge durumunda bütün kullanılan güzergahlardaki seyahat maliyetinin aynı olacağı ve bu maliyetin kullanılmayan güzergahlardaki seyahat maliyetinden daha az veya eşit olacağı kabulüne dayanır. Bu durum ağ kullanıcı dengesi altındadır şeklinde tanımlanabilir ve hiçbir kullanıcı kendi güzergahını değiştirerek seyahat maliyetini değiştiremez (Wardrop, 1952). Bu Deterministik Kullanıcı Dengesi (DKD) durumunu doğurmaktadır. Fakat gerçekte DKD durumundan farklı olarak sürücüler güzergahlar hakkında tam olarak bilgi sahibi değildirler ve sürücülerin güzergah seçimleri sırasında algılama hataları olmaktadır. Bu nedenle SKD ataması gerçek sürücü davranışlarının modellenenebilmesi açısından daha gerçekçidir.

Bu çalışmada, SKD ataması problemi eşdeğer optimizasyon problemi olarak tanımlanmıştır. Güzergah seçiminde logit ve probit seçim modelleri kullanılmış ve geliştirilen SKD ataması algoritmasının çözümü için Karınca Kolonisi Optimizasyonu (KKO) ve Armoni Araştırması Optimizasyon Tekniği (AAT) sezgisel metotlarından yararlanılmıştır.

## Güzergah Seçim Modelleri

A ve B gibi iki nokta arasında seyahat etmek isteyen yol kullanıcısı bu iki noktayı birbirine bağlayan birçok güzergah arasında tercih yapmak zorundadır. Güzergah seçimini etkileyen faktörler arasında güzergah özellikleri ve seyahat eden kişinin sosyo-ekonomik özellikleri sayılabilir. Güzergah seçim modellerinde temel ilke, yol kullanıcılarının sürekli olarak en düşük maliyetli (sürekli) güzergahı seçeceği yönündedir. Stokastik modelde herhangi bir yol kullanıcısı tarafından algılanan maliyet rastgele bir değişken olarak varsayılır ve güzergah seçimi fayda maksimizasyonu (maliyet minimizasyonu) prensibine dayanılarak her bir kullanıcının algıladığı maliyete göre yapılır (Sheffi, 1985). SKD prensibi deterministik kabule oldukça benzerdir fakat stokastik düşünce, herhangi bir yol kullanıcısının denge durumunda tek taraflı olarak güzergahını değiştirerek seyahat maliyetini değiştiremeyeceği noktasında deterministik düşünceden ayrılır. Herhangi bir güzergahın faydası güzergah özelliklerinin fonksiyonu

olmasının yanında ulaşım ağı karar vericilerinin de karakteristiklerini yansıtır. Karar vericiler en yüksek faydaya sahip güzergahın seçileceğini kabul eder. Bunun yanında faydalar direk olarak gözlenemez veya ölçülemez. Güzergah alternatifinin  $K$  adet olduğu bir ulaşım ağında, alternatiflerin fayda vektörleri  $U = (U_1, \dots, U_K)$  olarak gösterilebilir. Gözlemlenen güzergah karakteristiklerini ve özelliklerini  $a$  ile ifade edersek  $U_k = U_k(a)$  olur. Güzergahların gözlemlenemeyen karakteristikleri ve özelliklerinin güzergah seçim etkilerini açıklayabilmek için her bir alternatifin fayda fonksiyonu, deterministik bileşen ve rastgele hata terimi olmak üzere iki bileşenden oluşur.

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

Burada  $U_k(a)$  algılanan fayda,  $V_k(a)$ , ölçülen fayda ve  $\xi_k(a)$  ise hata terimi olarak tanımlanabilir.

### Probit Model

Probit modelin güzergah seçim modeli olarak kullanılması, çakışan güzergahları göz önüne almasından dolayı ağ topolojisine duyarlı bir çözüm elde etmeye yardımcı olur. Probit modelde alternatiflerin algılanan faydaları,  $[U(i), U(j), \dots]$ , çok değişkenli normal dağılıma (ÇDND) sahip olduğu varsayımıyla elde edilir (Daganzo, 1979). ÇDND bilinen normal yoğunluk fonksiyonunun çok değişkenli olarak genişletilmiş halidir ve rastgele vektörün,  $\xi = (\xi_1, \dots, \xi_K)$ , dağılımını tanımlar ve  $\xi \sim (\mu, \Sigma)$  şeklinde ifade edilir. Bu ifade  $\xi$  vektörünün, ortalama vektör  $\mu$  ve kovaryans matrisi  $\Sigma$  ile ÇDND sergilediğini gösterir.

Bu durumda verilen bir kovaryans matrisi ve alternatif özelliklerini belirleyen  $a$  vektörü için fayda vektörünün,  $U(a) = [U_1(a), \dots, U_K(a)]$ , dağılımı çok değişkenli normal dağılım olarak Denklem (2)'deki gibi modellenir;

$$U(a) \sim [V(a), \Sigma] \quad (2)$$

Herhangi bir seçim modelinde alternatifin seçim olasılığı, o alternatifin faydasının seçim alternatifleri içindeki en yüksek faydaya sahip olma olasılığına göre hesaplanır. Probit modelde bu seçim olasılığı, ikili alternatif olma durumunda olasılık dağılım tabloları vasıtasıyla hesaplanabilir. İki'den fazla alternatif olduğu zaman probit seçim olasılıklarının hesaplanması oldukça zordur. Literatürde probit seçim olasılıkları hesabı için birçok yaklaşık analitik metot önerilmiştir. Bunlar nümerik integrasyon algoritmaları ve ardışık yaklaşık metotlardır (Clark, 1961). Güzergah sayısının çok olması durumunda analitik yaklaşım sergileyen hiçbir metot pratik ve kolay bir şekilde ulaşım ağına uygulanamaz (Sheffi, 1985). Probit seçim olasılıklarının hesaplanabilmesi için önerilen diğer bir yöntem Monte Carlo benzetim yöntemidir (Maher ve Hughes, 1997). Bu çalışmada probit seçim olasılıklarının bulunabilmesi için Monte Carlo simülasyon metodundan faydalanılmıştır. Alternatif güzergahlara ait fayda fonksiyonları  $U_k = V_k + \xi_k \quad \forall k \in K$  şeklinde gösterildiği zaman verilen  $V = (V_1, \dots, V_K)$  değerleri için Monte Carlo simülasyon algoritması iteratif olarak şu şekilde gerçekleştirilir;  $n$ . iterasyondaki hata terimleri ile görünen faydaların,  $V_K$ , toplanması ile her bir güzergah için algılanan faydalar bulunabilir. Bu aşamadan sonra her bir iterasyonda en yüksek faydayı veren güzergah kaydedilir. Bu süreç  $N$  kez tekrar

edilir. Buradan  $k$ .alternatifin seçim olasılığı,  $P_k$ , en yüksek faydayı sağlayan güzergahın kaydedilme sayısının ( $N_k$ ) simülasyon sayısına bölümü ile elde edilebilir.

### Logit Model

Logit modelde alternatif güzergahların faydalarının Gumbel dağılımı sergilediği kabulü yapılmıştır (Ceylan, 2002).  $p$  güzergahının gerçek maliyeti  $C_p$ , algılanan maliyeti  $U_p$  ve rastgele hata terimi  $\varepsilon_p$  olarak gösterildiği zaman buradan rastgele fayda  $U_p = C_p + \varepsilon_p$  şeklinde ifade edilebilir. Gumbel dağılımının özelliğinden dolayı hata teriminin ortalaması  $E(\varepsilon_p) = 0$  ve varyansı ise  $var(\varepsilon_p) = \pi^2 / 6\alpha^2$  şeklinde gösterilebilir. Buradan logit seçim olasılığı Denklem (3)'de gösterildiği gibidir.

$$K_p^w(g) = P(U_k > U_p) = \frac{\exp(-\alpha C_p)}{\sum_{k \in P_w} \exp(-\alpha C_k)}, \forall k \neq p \in P_U \forall w \in W \quad (3)$$

Burada  $p$  ve  $k$ ,  $w \in W$  B-V çifti arasındaki alternatif güzergahlar ve  $\alpha$  dağılım parametresidir.

## Sezgisel Metotlar

### Karınca Kolonisi Optimizasyonu

KKO son zamanlarda çözümü zor optimizasyon problemlerinin çözümünde kullanılan sezgisel bir yaklaşımdır (Dorigo, 1992; Dorigo ve Di Caro, 1999). KKO algoritmaları, optimizasyon problemlerinin çözümü için gerçek karıncaların yiyecek bulma davranışlarının gözlemlenmesi ile ortaya çıkmıştır (Dorigo ve Stützle, 2004). Bu çalışmada klasik KKO yaklaşımlarından farklı bir yaklaşım uygulanmıştır (Baskan ve diğ., 2009). Bu yaklaşımda her bir karınca bir önceki iterasyondaki en iyi karıncaya ve  $\beta'$  ya bağlı olarak aramaya iterasyonlar boyunca devam etmektedir.  $\beta$  vektörü ( $\beta = (\beta_1, \beta_2, \dots, \beta_n)$ ,  $n = \text{değişken sayısı}$ ) KKO yaklaşımının performansının iyileştirilmesi için oldukça önemlidir. Çözüm sürecinin başında her bir karınca çözüm uzayı (ÇU) içinde rastgele olarak en iyi çözümü aramaya başlar. İlk iterasyonun sonunda çözüm uzayı bir önceki iterasyondan elde edilen en iyi çözüm ve  $\beta'$  ya bağlı olarak sınırlandırılır. Daha sonra optimum çözüm, arama süreci boyunca sınırlı ÇU içinde aranmaya devam edilir.

Kullanılan KKO yaklaşımında  $m$  adet karınca  $m$  adet vektör olarak nitelendirilmiştir. ( $x^k$  ( $k = 1, 2, \dots, m$ )). Her bir karıncanın çözüm vektörü Denklem (4) ile güncellenir.

$$x_t^{k(yeni)} = x_t^{k(eski)} \pm \alpha \quad (t = 1, 2, \dots, I) \quad (4)$$

Burada  $x_t^{k(yeni)}$   $t$ . iterasyondaki  $k$ . karınca vektörü,  $x_t^{k(eski)}$   $t$ . iterasyonda önceki adımda elde edilen karınca vektörü ve  $\alpha$  ise sıçrama uzunluğunu hesaplamak için rastgele üretilen vektör olarak temsil edilmiştir. Her bir iterasyonun son adımında iterasyonun başında üretilen koloni büyüklüğü kadar yeni bir karınca kolonisi oluşturulur. Feromon

miktarı ( $\tau_t$ ) Denklem (5) kullanılarak ilk olarak gerçek karınca kolonilerini temsil edecek şekilde buharlaştırılır daha sonra ise Denklem (6) yardımıyla feromon miktarı güncellenir. Bu süreç verilen iterasyon sayısına kadar devam ettirilir. Bu çalışmada başlangıç feromon miktarı 100 olarak alınmıştır.

$$\tau_t = 0.1 * \tau_{t-1} \quad (5)$$

$$\tau_t = \tau_{t-1} + 0.01 * f(x_{t-1}^{eniyi}) \quad (6)$$

Denklem (4)'de artı veya eksi işaretinin hangisinin kullanılacağı  $x_t^k$  'nın bulunan en iyi değerin sağında veya solunda olmasına göre belirlenmektedir. Eğer  $x_t^k$ , en iyi çözümünü solunda ise pozitif tersi durumda ise negatif değeri kullanılır. Hareket yönü Denklem (7) ile aşağıdaki gibi belirlenir;

$$\bar{x}_t^{eniyi} = x_t^{eniyi} + (x_t^{eniyi} * 0.01) \quad (7)$$

Eğer  $f(\bar{x}_t^{eniyi}) \leq f(x_t^{eniyi})$  ise Denklem (4)'de (+) işareti kullanılır aksi durumda ise (-) işareti kullanılır. ( $\pm$ ) işareti global optimum değerine ulaşmak için arama yönünü belirler. SKD ataması için kullanılan KKO metodu hakkında detaylı bilgiye Baskan ve diğ. (2009)'den ulaşılabilir.

### Armoni Araştırması Optimizasyon Tekniği

Geem ve diğ. (2001) tarafından geliştirilen Armoni Araştırması Tekniği, bir orkestradaki müzisyenlerin çaldıkları notalar ile armonik açıdan en iyi melodinin elde edilmesi prensibine dayanmaktadır. Farklı enstrümanlar ile çalınan nota ve tonların estetik kalitesi, müzik çalışmalarında pratik yaparak iyileştirilirken, fonksiyon çözümünde bu iyileştirme birbirini takip eden iterasyonlarla gerçekleştirilmektedir (Geem, 2006). Armoni araştırması süreci 5 adımdan oluşmaktadır (Ceylan ve diğ., 2008).

#### Adım 1: Problemin kurulması ve algoritma parametrelerinin tanımlanması

Burada, herhangi bir  $F(x)$  amaç fonksiyonu,  $x_i$  karar değişkenleri (orkestradaki enstrümanları),  $X_i$  her karar değişkeni için kullanılan çözüm uzayı ve N ise toplam karar değişkeni sayısı (orkestra büyüklüğü) olarak tanımlanır. Armoni araştırması çözüm sürecini kontrol eden 3 farklı parametre mevcuttur. Bunlar sırasıyla armoni belleği kapasitesi (HMS), armoni belleğini dikkate alma oranı (HMCR) ve ton ayarlama oranıdır (PAR).

#### Adım 2: Armoni belleğinin oluşturulması

Armoni belleği, tüm çözüm vektörlerinin ve amaç fonksiyonunun aldığı değerlerin saklandığı bellektir. Fonksiyon değerleri sayesinde, ilgili çözüm vektörlerinin kalitesi değerlendirilmektedir. Bu adımda, armoni belleği matrisi, rastgele üretilen çok sayıda çözüm vektörü ile doldurulur ve bu vektörler için ilgili amaç fonksiyonu değerleri hesaplanır.

#### Adım 3: Yeni armoninin oluşturulması

Bu adımda, yeni armoni vektörü  $x' = (x'_1, x'_2, x'_3, \dots, x'_N)$ , armoni belleğinde bulunan tonlara göre ve tamamen rastgele seçilen tonlara göre üretilmektedir. Değişkenlerin armoni belleğinden seçilip seçilmeyeceğinin belirlenmesi, değeri 0 ile 1 arasında değişen HMCR oranına göre yapılmaktadır. Burada, HMCR bir karar değişkeninin değerinin mevcut armoni belleğinden seçilme olasılığını gösterirken, (1-HMCR) oluşturulan yeni karar değişkeninin mevcut çözüm uzayı içerisinde rastgele olarak seçilmesine karşılık gelmektedir. Bu aşamadan sonra, ton ayarlama işleminin gerekli olup olmadığının belirlenmesi için her karar değişkeninin değerlendirilmesi yapılmaktadır. Bu işlem ise PAR parametresi ile yapılmaktadır.

#### Adım 4: Armoni belleğinin güncellenmesi

Bu adımda, armoni belleğindeki tüm amaç fonksiyonu değerleri en iyiden en kötüye doğru sıralanır. Daha sonra yeni armoni vektörü, armoni belleği içindeki en kötü vektör ile karşılaştırılır. Eğer 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.

## Stokastik Kullanıcı Dengesi Atama Problemi ve Geliştirilen Algoritma

Trafik ataması ulaşım ağına seyahat eden yolcuların oluşturduğu trafiğin yüklenmesidir. Bu süreçte her bağlantıdaki trafik hacminin yol kapasitesine göre taşınıp taşınamayacağı belirlenir. Bu çalışmada logit ve probit güzergah seçim modellerinin kullanıldığı SKD atama modeli geliştirilmiştir. SKD ataması problemi Denklem (8)'de görülen amaç fonksiyonunun minimum edilmesiyle çözülebilir.

$$v_a = \sum_{w \in W} \sum_{p \in P_w} f_p^w \delta_{ap}^w, a \in A$$

$$\sum_{p \in P_w} f_p^w = q_w, w \in W$$

$$f_p^w \geq 0, p \in P_w, w \in W$$

Kısıtlarına bağlı olarak;


$$\min(f_1^1, \dots, f_p^w; f_1^{1*}, \dots, f_p^{w*}) = \sum_{w \in W} \sum_{p \in P} (f_p^w - f_p^{w*})^2 \quad (8)$$

Burada  $A$  yol ağındaki bağlantılar kümesi,  $W$  (B-V) kümesi,  $P_w$   $w \in W$  B-V çiftindeki güzergahlar kümesi,  $q_w$   $w \in W$  B-V seyahat talebi,  $f_p^w$   $p \in P_w$  güzergahındaki akım,  $f_p^{w*}$   $p \in P_w$  güzergahındaki denge akımı,  $v_a$   $a$  bağlantısındaki akım ve  $\delta_{ap}^w$  ise bağlantı/güzergah belirleme matrisinin elemanıdır ve aşağıdaki gibi ifade edilir:

$\delta_{ap}^w = 1$  ,  $w \in W$  B-V çiftindeki  $p$  güzergahı  $a$  bağlantısını kullanıyorsa

$\delta_{ap}^w = 0$  , aksi durumda

Şekil 1’de probit ve logit tabanlı SKD atama modelinin akış diyagramı görülmektedir.




Şekil 1 Probit ve logit seçim tabanlı SKD ataması modeli akım şeması.

## SKD Ataması Örnek Sayısal Uygulama

Önerilen modelin test edilmesi için 5 bağlantı ve 3 güzergahtan oluşan örnek ulaşım ağı seçilmiştir. Şekil 2’de ulaşım ağı verilmiştir. Güzergah 1 ve 2 tarafından bağlantı 1, güzergah 2 ve 3 tarafından ise bağlantı 5 ortak kullanılmaktadır (*Güzergah 1*: 1-2, *Güzergah 2*: 1-3-5, *Güzergah 3*: 4-5). Denklem (9)’da ağın çözümünde kullanılacak olan maliyet fonksiyonu verilmiştir. Burada  $t_a^0$ , serbest akım seyahat süresi;  $v_a$ ,  $a$

bağlantısı üzerindeki akım;  $c_a$ ,  $a$  bağlantısının kapasitesi;  $t_a(v_a)$ ,  $a$  bağlantısının ölçülebilir maliyeti ve  $A$  bağlantılar kümesidir. Tablo 1’de ulaşım ağına ait bilgiler verilmiştir.

$$t_a(v_a) = t_a^0 * (1 + 0.15(\frac{v_a}{c_a})^4) \quad \forall a \in A \quad (9)$$




Şekil 2 Test ulaşım ağı.

Tablo 1 Ulaşım Ağı Bilgileri.

| Bağlantı No | Bağlantı Kapasitesi (ta/sa) | Serbest Akım Seyahat Süreleri (sn) |
|-------------|-----------------------------|------------------------------------|
| 1           | 300                         | 23                                 |
| 2           | 200                         | 34                                 |
| 3           | 400                         | 12                                 |
| 4           | 350                         | 45                                 |
| 5           | 400                         | 23                                 |

Örnek ağ için B-V talebi 400 ta/sa olarak alınmıştır. Logit güzergah seçim modeli ile SKD ataması probleminin çözümü iki farklı sezgisel metot kullanılarak gerçekleştirilmiş ve amaç fonksiyonunun değişimi Şekil 3’de verilmiştir. Şekilde görüldüğü gibi KKO yaklaşımı ile 280 iterasyon, AAT yaklaşımı ile 815 iterasyon sonucunda amaç fonksiyonunun minimum değeri elde edilmiş ve SKD bağlantı akımları bulunmuştur. Logit-SKD bağlantı akımları Tablo 2’de görülmektedir.



Şekil 3 Logit - SKD ataması amaç fonksiyonu değişimi.

Tablo 2 SKD bağlantı akımları.

| Bağlantı<br>No | KKO             |      |                 |      | AAT             |      |                 |      |
|----------------|-----------------|------|-----------------|------|-----------------|------|-----------------|------|
|                | Probit          |      | Logit           |      | Probit          |      | Logit           |      |
|                | Akım<br>(ta/sa) | S*   | Akım<br>(ta/sa) | S*   | Akım<br>(ta/sa) | S*   | Akım<br>(ta/sa) | S*   |
| 1              | 320             | 1.07 | 312             | 1.04 | 320             | 1.07 | 312             | 1.04 |
| 2              | 160             | 0.80 | 154             | 0.77 | 160             | 0.80 | 154             | 0.77 |
| 3              | 160             | 0.40 | 158             | 0.40 | 160             | 0.40 | 158             | 0.40 |
| 4              | 80              | 0.23 | 88              | 0.25 | 80              | 0.23 | 88              | 0.25 |
| 5              | 240             | 0.60 | 246             | 0.61 | 240             | 0.60 | 246             | 0.61 |


\*Kapasite kullanım oranı

Probit-SKD ataması probleminin çözümü iki farklı sezgisel metot kullanılarak gerçekleştirilmiş ve amaç fonksiyonunun değişimi Şekil 4'de verilmiştir. Şekilde görüldüğü gibi KKO yaklaşımı ile 261 iterasyon, AAT yaklaşımı ile 945 iterasyon sonucunda amaç fonksiyonunun minimum değeri elde edilmiş ve SKD bağlantı akımları bulunmuştur. Tablo 2'de görüldüğü gibi KKO ve AAT teknikleri ile yapılan SKD ataması için probit ve logit seçim modeli durumlarında aynı denge bağlantı akımlarına ulaşılmıştır. Fakat KKO metodu AAT metoduna göre iterasyon sayısına bakıldığında zaman oldukça az iterasyon sayısı ile sonuca ulaşmaktadır. Ayrıca Tablo 2'de görüldüğü gibi bağlantı 1 her iki güzergah seçim modeli ile yapılan atama sonucu 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. Karşılaştırma yapılması açısından Tablo 3'de DKD ataması durumu için denge bağlantı akımları verilmiştir. SKD atamasına göre bağlantı 4'ün çok daha az akım aldığı ve güzergah 3 seçeneğinin seçilme olasılığının oldukça düşük olduğu görülmektedir.

Tablo 3 DKD bağlantı akımları.

| Bağlantı No | Akım (ta/sa) | S*   |
|-------------|--------------|------|
| 1           | 381          | 1.27 |
| 2           | 152          | 0.76 |
| 3           | 229          | 0.57 |
| 4           | 19           | 0.05 |
| 5           | 248          | 0.62 |

\*Kapasite kullanım oranı



Şekil 4 Probit - SKD ataması amaç fonksiyonu değişimi.

## Sonuçlar

Trafik atama problemi günümüzde, sürücülerin seyahat ettikleri ağ ile ilgili bilgi düzeylerini ve yapılan seyahatlerdeki rastgeleliği de göz önünde bulunduran SKD yaklaşımı ile ele alınmaktadır. Güzergah seçim olasılıklarının elde edilebilmesi için çözülmesi gereken denklem sistemlerinin konveks olmayan yapısı ve içsel bağımlılığı nedeniyle geleneksel türeve dayalı çözüm yöntemleri SKD çözümünde etkili olamamaktadır. Bu çalışmada KKO ve AAT tekniklerinin kullanıldığı SKD atama modeli geliştirilmiştir. Geliştirilen çözüm algoritmasında güzergah seçim olasılıklarının belirlenmesi için logit model ve ayrıca alternatif güzergahların ortak kullandıkları bağlantılar arasındaki kovaryans değerlerini de göz önünde bulunduran probit model kullanılmıştır. Probit güzergah seçim olasılıklarının hesaplanabilmesi için Monte-Carlo benzetim tekniğinden faydalanılmıştır. Probit model gerçek sürücü davranışlarının modellenebilmesi, güzergahlar arasındaki korelasyonu dikkate alması ve sürücülerin bağlantı maliyetlerini algılamadaki farklılıklarını temsil etmesi açısından güzergah seçiminde oldukça önemlidir. Önerilen algoritmanın çözüm yeteneğini göstermek amacıyla örnek bir ulaştırma ağı üzerinde sayısal uygulama gerçekleştirilmiştir. Sonuçlara göre KKO tekniği, AAT tekniğine göre SKD probleminin çözümünde daha az iterasyon sayısında başarılı sonuçlar vermektedir. Ayrıca DKD ataması sonuçları ile önerilen probit ve logit tabanlı SKD atamasının sonuçları karşılaştırılmış ve önerilen

algoritmanın gerçek sürücü davranışlarının modellenebilmesi açısından daha gerçekçi sonuçlar verdiği görülmüştür.

**Teşekkür** Bu çalışma Pamukkale Üniversitesi Bilimsel Araştırma Projeleri Birimi ve Tübitak tarafından desteklenen BAP-FBE-002 ve 104I119 nolu projeler kapsamında gerçekleştirilmiştir.

## Kaynaklar

Baskan, O., Haldenbilen, S., Ceylan, H. and Ceylan, H. (2009) A new solution algorithm for improving performance of ant colony optimization. Applied Mathematics and Computation, 211(1), 75-84.

Ceylan, H., Ceylan, H., Haldenbilen, S. and Baskan, O. (2008) Transport energy demand modeling with meta-heuristic harmony search algorithm, an application to Turkey, Energy Policy, 36, 2527-2535.

Ceylan, H. (2002) A Genetic Algorithm Approach to the Equilibrium Network Design Problem. PhD Thesis, University of Newcastle upon Tyne, England.

Clark, C. E. (1961) The greatest of a finite set of random variables. Operations Research, 9, 145-162.

Daganzo, C. (1979) Multinomial Probit: The Theory and its Application to Demand Forecasting. Academic Press, New York.

Dorigo, M. and Di Caro, G. (1999) Ant colony optimization: A new meta-heuristic. In: Proceedings of the 1999 Congress on Evolutionary Computation, vol. 2, 1470-1477.

Dorigo, M. (1992) Optimization, learning and natural algorithms. PhD Thesis, Politecnico di Milano, Italy.

Dorigo, M. And Stützle, T. (2004) Ant Colony Optimization. The MIT Press, Massachusetts Institute of Technology, Cambridge.

Geem, Z. W., Kim, J. H. and Loganathan, G. V. (2001) A New Heuristic Optimization Algorithm: Harmony Search, Simulation, 76(2), 60-68.

Geem, Z. W. (2006) Optimal Cost Design of Water Distribution Networks Using Harmony Search, Engineering Optimization, 38(3), 259-280.

Maher, M.J. and Hughes, P.C. (1997) A probit-based stochastic user equilibrium assignment model. Transportation Research Part B, 31, 341-355.

Sheffi, Y. (1985) Urban Transport Networks: Equilibrium Analysis with Mathematical Programming Methods. Prentice-Hall Inc., Englewood Cliffs, New Jersey, USA.

Wardrop, J. G. (1952) Some theoretical aspects of road traffic research. In: Proceedings of Institute of Civil Engineering. Part II, 1(2), 325-362.