

KÜMELEME İÇİN BİR BENZETİLMİŞ TAVLAMA ALGORİTMASI YAKLAŞIMI

Dr. Tunçhan CURA

İstanbul Üniversitesi

İşletme Fakültesi

Sayısal Yöntemler Anabilim Dalı

Literatürde kümeleme için önerilmiş bir çok sayıda algoritmik yaklaşım vardır ve önemli bir kısmı da sezgisel yaklaşımlardır. Bu çalışmada bir sezgisel yaklaşım türü olan benzetilmiş tavlama yöntemiyle bir kümeleme algoritması önerilmiştir. Önerilen algoritma Gaussian Olasılık Dağılımına göre tesadüfi oluşturulan yapay problemlerde denenmiştir. Karşılaştırma yapabilmek için sıklıkla kullanılan SPSS 12.0 yazılımının “K-Means Cluster”, “Hierarchical Cluster”, “Twostep Cluster” araçlarından ve Lingo8’ den yararlanılmıştır. Sonuçlar önerilen yöntemin sağlıklı olduğunu ortaya koymuştur.

Key Words: Clustering, simulated annealing, heuristic.

A SIMULATED ANNEALING ALGORITHM APPROACH TO CLUSTERING

As the relevant literature is surveyed, plenty of algorithmic approaches appear and many of those are heuristic techniques. The clustering algorithm that has been proposed in this study is based on simulated annealing method which is a type of heuristic algorithms. This algorithm has been tested in artificial problems which have been randomly generated with respect to the Gaussian Probability Distribution. The “K-Means Cluster”, “Hierarchical Cluster”, and “Twostep Cluster”, which are the frequently used tools of SPSS 12.0 software, and the Lingo8 software have been exploited for comparison. The results have shown that the proposed technique is robust.

Anahtar Sözcükler: Kümeleme, benzetilmiş tavlama, sezgisel.

GİRİŞ

Kümeleme, bir veri kümesindeki her bir verinin özelliklerine bağlı olarak daha hassas tek bir alt küme içerisinde toplanmasıdır. Sözkonusu veri kümesi, özellikleri olan nesnelere kümesi olarak temsil edilebilir. Buna göre herhangi bir i nesnesinin diğer bir j nesnesiyle olan uzaklığı d_{ij} ile temsil edilsin. Her bir alt küme içerisinde d_{ij} değerleri en küçük olan nesnelere yerelmalıdır (bakınız Bryson ve Inness, 2007, 3255). Görüldüğü gibi kümeleme, en uyumlu nesnelere birarada bulunduğu alt kümelerin tespit edilmesine yönelik bir optimizasyon problemi olmaktadır.

Kümelemeye yönelik çeşitli çalışmalar vardır. Bunların başında McQueen' in (1967) önermiş olduğu ve sıklıkla kullanılan K-means algoritması gelmektedir. Bu yaklaşımla her bir kümede yer alan nesnelere özellik ortalamaları göz önünde bulundurularak küme içerisinde yer alan her bir nesnenin ortalamadan uzaklığı dikkate alınmıştır. Başka bir yaklaşım Johnson' un (1967) önerdiği hiyerarşik kümeleme şemalarıdır. Bu yaklaşımda her nesne kendi kümesine yerleştirilir ve içlerinde birbirine en yakın iki küme birleştirilir. Böylece küme sayısı bir azaltılır. İstenen küme sayısına ulaşılan kadar işlem devam ettirilir. Buna benzer bir başka hiyerarşik yaklaşım Ward (1993) tarafından önerilmiştir.

Kümeleme için bunların dışında sıklıkla başvurulan çeşitli sezgisel yaklaşımlar da vardır. Örneğin Shelokar ve diğerleri (2004) tarafından önerilmiş olan karınca kolonileri optimizasyonu yaklaşımı, Liu ve diğerlerinin (2004) önerdikleri genetik algoritmalar yaklaşımı ile Güngör ve Ünler' in (2007) önermiş oldukları tabu arama yaklaşımı verilebilecek örneklerin başında yer almaktadır.

Bu çalışmada kümeleme için her bir nesnenin bulunduğu kümenin merkezine olan uzaklıklarının toplamının en küçük olduğu çözümü araştıran bir benzetilmiş tavlama algoritması önerilmiştir. Sonuçlar SPSS 12.0 yazılımının "twostep cluster", "K-means cluster", "hierarchical cluster" araçlarının ve Lingo8' in bulunduğu çözümlerle karşılaştırılmıştır. Karşılaştırılmaların yapılması için kullanılan problemler Gauss olasılık dağılımına göre tesadüfi olarak oluşturulmuştur.

1. KÜMELEME PROBLEMİ

Daha önce de değinildiği gibi bu çalışmada her bir alt küme içerisinde yer alan nesnelere, içinde buldukları kümenin merkezine olan öklid uzaklıkları temel alınmıştır. Buna göre nesne sayısı, nesnelere özellik sayısı, i nesnesinin özelliklerinin değerleri, küme sayısı ve her bir kümenin merkezi sırasıyla N , n , x_{il} ($l = 1, \dots, n$), K ve m_{kl} ($k = 1, \dots, K$) ile temsil edilirse,

herhangi bir i nesnesinin ($i = 1, \dots, N$) k kümesinin merkezine uzaklığı d_{ik} ile temsil edilir ve aşağıdaki gibi hesaplanır:

$$d_{ik} = \sum_{l=1}^n x_{il} - m_{kl} \quad i = 1, \dots, N, k = 1, \dots, K \quad (1)$$

Görüldüğü gibi (1) de nesnelere küme merkezlerine olan uzaklıkları hesaplanmaktadır. Ancak küme merkezinin nasıl hesaplandığı bu noktada daha önemli bir sorun olmaktadır. Bir kümenin merkezi, içinde yer alan nesnelere özelliklerinin ortalamasıdır. Buna göre i nesnesinin k kümesinin içinde olup olmadığını temsil eden bir W_{ik} bir-sıfır değişkeni kullanılabilir. Böylece $W_{ik} = 1$ ise i nesnesi k kümesinde yer alacaktır, $W_{ik} = 0$ ise yer almayacaktır. Bir kümenin merkezi aşağıdaki gibi hesaplanır:

$$m_{kl} = \frac{\sum_{i=1}^N W_{ik} x_{il}}{\sum_{i=1}^N W_{ik}} \quad (2)$$

Buna göre, kümeleme probleminin bu çalışmada kullanılan matematik modeli (1) ve (2)' nin yardımıyla aşağıdaki gibi olur:

$$\begin{aligned} \min \quad & \sum_{k=1}^K \sum_{i=1}^N \sum_{l=1}^n W_{ik} (x_{il} - m_{kl})^2 \\ \text{s.t.} \quad & \sum_{k=1}^K W_{ik} = 1, i = 1, \dots, N, \\ & \sum_{i=1}^N W_{ik} \geq 1, k = 1, \dots, K, \\ & m_{kl} = \frac{\sum_{i=1}^N W_{ik} x_{il}}{\sum_{i=1}^N W_{ik}}, k = 1, \dots, K, l = 1, \dots, n, \\ & W_{ik} \in (0,1), i = 1, \dots, N, k = 1, \dots, K. \end{aligned}$$

2. BENZETİLMİŞ TAFLAMA ALGORİTMASI

Benzetilmiş Tavlama (BT) algoritması Metropolis ve diğerlerinin (1958) çalışmasını temel alan Kirkpatrick ve diğerleri (1983) tarafından ortaya atılmıştır. BT eşik algoritmalarının bir türüdür (Bakınız

Aarts E. ve Lenstra J. K., 2003, 92 - 94). Adından da anlaşılacağı gibi BT, bir maddenin ısıtılıp yavaşça soğumaya bırakılması durumunda çevresiyle termal eşitliğe ulaşana kadar yavaşça soğuması sürecini taklit eder. Sözkonusu süreçte ısı seviyesinin yüksek olduğu durumlarda maddenin enerjisi azami düzeydedir ve parçacıkları tesadüfi olarak dağılmaktadır. Ancak ısı seviyesi termal eşitlik noktasına ulaştığında ise maddenin enerjisi asgari düzeyde olur ve parçacıklar kuvvetli yapısal bir bütünlüğe ulaşmış olurlar.

Fiziksel tavlama süreci bir optimizasyon problemi çözümünün aranması sürecine benzetilebilir. Buna göre yüksek ısı seviyesine karşılık gelen bir tesadüfi başlangıç çözümünün enerjisi amaç fonksiyonunun değerine karşılık gelmektedir. Böylece çözüm aranırken, t ısı seviyesinde i çözümünden j komşu çözümüne geçme olasılığı aşağıdaki gibi hesaplanır:

$$P_i\{j' \text{ yi kabul et}\} = \min \left(e^{-\frac{f(i)-f(j)}{t}}, 1 \right) \quad (3)$$

Görüldüğü gibi BT algoritmasına göre yüksek ısı seviyeli durumlarda daha uzaktaki komşu çözümlerin kabul edilme olasılığı daha yüksek olmakta, böylece bu sıçrama hareketleri sayesinde lokal en küçük noktaya takılma sorunu engellenebilmektedir.

3. KÜMELEME için BT TASARIMI

BT algoritmasının en önemli unsurlarından birisi yukarıda da kısaca girişi yapılmış olan komşuların araştırılmasıdır. Adından da açıkça görüldüğü gibi en küçük enerjili durum araştırılırken, tekrarlar bir pozisyonun komşuları araştırılır ve (3)' teki fonksiyona göre bulunan komşu çözüm kabul edilir veya edilmez. Böylece söz konusu yeni çözüm en düşük enerjinin aranmasında yeni odak noktası olmaktadır.

Bu çalışmada K adet kümeye N adet nesne başlangıçta tesadüfi olarak dağıtılmaktadır. Bu uygulama BT algoritmalarının en temel başlangıç çözümü belirleme biçimidir. Söz konusu durum en yüksek ısı seviyesinin olduğu durumdur. Bu ilk çözüm yukarıdaki gibi i çözümü olarak nitelenecek olursa, j komşu çözümü i ' de tesadüfi olarak iki kümenin seçilmesi ve bu iki küme içerisinde tesadüfi iki pozisyondaki elemanların yer değiştirilmesi ile belirlenir.

Matematiksel olarak daha rahat izah edebilmek için çözüm s matrisiyle temsil edilmektedir. Sözkonusu matrisin boyutu $K \times N$ ' dir. Başka bir ifadeyle satırlarda kümeler kolonlarda da nesnelere bulunmaktadır. Ancak herhangi bir kolonda sıfır değeri bulunabilir, bunun anlamı ilgili pozisyonda herhangi bir nesne bulunmamakta olduğudur. Buna göre s matrisinin her satırının bir kümeyi temsil ettiği açıkça görülmektedir.

	1	2	3	4	5	6
s_1	0	1	5	0	0	2
s_2	0	0	3	0	0	0
s_3	4	0	0	6	0	0

Şekil 1. Herhangi bir çözümü temsil eden s matrisi

Her satır bir vektör olduğundan kümeler bu çalışmada vektör olarak temsil edilmişlerdir. Şekil 1' de 3 kümenin ve 6 nesnenin olduğu örnek bir s çözüm matrisi gösterilmektedir. Buna göre s_1 vektörü incelendiğinde birinci kümeye 1 inci, 5 inci ve 2 inci nesnelere yerleştirilmiş olduğu görülmektedir.

4. ENERJİ FONKSİYONU

```

g(sk)
sk: s çözüm matrisinin k inci satırı
begin
  ol = 0, l = 1, ..., n
  sonuç = 0
  for l = 1 to n
    eleman_sayısı = 0
    for i = 1 to N
      if ski > 0 then
        ol = ol + xskil
        eleman_sayısı = eleman_sayısı + 1
      End if
    End for
    if eleman_sayısı = 0 then
      sonuç = 1050 // Her bir kümede en az
      bir nesne bulunmalı
    Algortimayı sonlandır
    End if
    ol = ol / eleman_sayısı
  End for
  for l = 1 to n
    for i = 1 to N
      if ski > 0 then
        sonuç = sonuç + (ol - xskil)2
      End if
    End for
  End for
  return sonuç
End

```

Şekil 2. s_k vektörünün enerji fonksiyonu.

Bu çalışmada önerilen BT algoritması çözüm matrisi yaklaşımında her bir satır (vektör) bir kümeyi

temsil etmektedir. Buna göre herhangi bir vektörün enerji fonksiyonu kod taslağı şekil 2’ de verilen $g(s_k)$ fonksiyonuyla temsil edilecek olursa, mevcut çözümün toplam enerjisi (4)’ deki gibi hesaplanır.

$$f_i(s) = \sum_{k=1}^K g(s_k) \quad (4)$$

5. İYİLEŞTİRME OPERATÖRÜ

Bilindiği gibi BT algoritması komşu çözümleri tesadüfi olarak belirlemektedir. Aslında, sezgisel yaklaşımların hemen hepsinin mantığı kısmen de olsa tesadüflüğe dayanmaktadır. Bazı durumlarda mevcut çözüm en iyi çözüme çok yakın olmasına rağmen komşu çözümün tesadüfen oluşturulması sebebiyle en iyiye ulaşması çok güç olabilir. Örneğin üç kümenin ve 150 nesnenin olduğu bir durum düşünülebilir. Böyle bir durumda öyle bir çözüme ulaşılmış olsun ki yalnız 100 numaralı nesne 2. kümeden alınıp 3. kümeye konulsa en iyi çözüme ulaşılacak olsun. İşte böyle bir komşunun seçilebilme olasılığı çok düşüktür. Bu durumda şekil 3’ te kod taslağı verilmiş olan iyileştirme operatörü bu amaç için kullanılabilir. Görüldüğü gibi bu operatör iç içe girmiş döngüler yardımıyla ikili olarak mevcut çözüm matrisinin hücrelerindeki değerleri yer değiştirmektedir. Böylece örnekteki 100 numaralı nesne 2. kümeden alınıp 3. kümeye kesinlikle yerleştirilecektir.

6. KÜMELEME İÇİN BT ALGORİTMASI

Buraya kadar anlatılanlar biraraya getirildiği takdirde şekil 4’ te gösterilen Kümeleme BT Algoritması

<pre> t = 1000 tesadüfi olarak başlangıç s matrisini oluştur F = f(s) F^{eniyi} = F s^{eniyi} = s f_k = g(s_k), k = 1, ..., K while t > 16 do for nrep = 1 to 500 k = round(random(0, 1) × (K - 1)) + 1 do k* = round(random(0, 1) × (K - 1)) + 1 until k ≠ k* i = round(random(0, 1) × (N - 1)) + 1 do i* = round(random(0, 1) × (N - 1)) + 1 until S_{ki} ≠ S_{k*i*} s_{ki} ile S_{k*i*} 'ı yerdeğiştir Δ = f_k + f_{k*} - g(s_k) - g(s_{k*}) Δ if random(0, 1) < min(e^{-t}, 1) then </pre>	<pre> g_k = g(s_k) k = 1, ..., K. for k = 1 to K for k* = k + 1 to K for i = 1 to N for i* = 1 to N if s_{ki} ≠ S_{k*i*} then s_{ki} ile S_{k*i*} 'ı yerdeğiştir if g_k + g_{k*} ≤ g(s_k) + g(s_{k*}) then s_{ki} ile S_{k*i*} 'ı yerdeğiştir else g_k = g(s_k) g_{k*} = g(s_{k*}) End if End if End for End for End for End for End for F = ∑_{k=1}^K g(s_k) </pre>
--	--

Şekil 4. Kümeleme BT Algoritması

<pre> g_k = g(s_k) k = 1, ..., K. for k = 1 to K for k* = k + 1 to K for i = 1 to N for i* = 1 to N if s_{ki} ≠ S_{k*i*} then s_{ki} ile S_{k*i*} 'ı yerdeğiştir if g_k + g_{k*} ≤ g(s_k) + g(s_{k*}) then s_{ki} ile S_{k*i*} 'ı yerdeğiştir else g_k = g(s_k) g_{k*} = g(s_{k*}) End if End if End for End for End for End for End for F = ∑_{k=1}^K g(s_k) </pre>
--

Şekil 3. s çözüm matrisi için iyileştirme operatörü

elde edilir. Görüldüğü gibi algoritmada bazı sabit değerler kullanılmıştır. Bu değerlerin hepsi empirik olarak belirlenmiştir. Örneğin *iyileştirme operatörü*' nün çağırılma olasılığı 0.001, başlangıç ısı seviyesi 1000, son ısı seviyesi 16’ dan büyük ve soğuma programı $t_d = t_{d-1} \times 0.92$ (d : döngü numarası) olarak belirlenmiştir.

7. KARŞILAŞTIRMALI PROBLEMLER

Bu kısımda bazı kümeleme problemleri önerilen BT algoritmasını test etmek için kullanılmaktadır. Bunun için dört farklı kümeleme problemi Gaussian dağılımına göre tesadüfi olarak oluşturulmuştur. Tüm problemlerde sonuç grafiklerinin rahat gösterilebilmesi için $n = 2$ alınmıştır. Problemler Pentium M 2.13 GHz kişisel bilgisayarda denenmiştir.

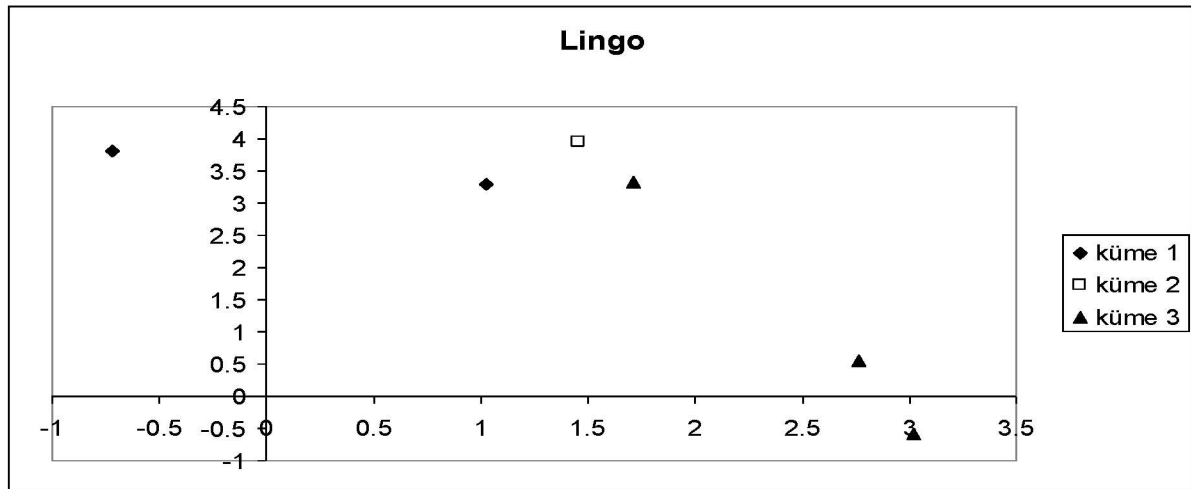
Problem 1

İlk problem birinci kısımda verilmiş olan matematiksel optimizasyon modelinin bir yazılımla (Lingo8) incelenmesi amacıyla oluşturulmuştur. Model son derece basit görünmektedir. Ancak küme


ortalamalarının dinamik oluşu ve optimize edilecek değişkenlere bağlı olarak değişmesi uygun (feasible) bir çözümün dahi bulunabilmesini çok güçleştirmektedir. Buna göre çok basit bir problem olarak $N = 6$ ve $K = 3$ olduğu durum incelenmiştir. Problem ortalamaların $\mu_1 = \{3, 0\}$, $\mu_2 = \{0, 3\}$ ve $\mu_3 = \{1.5, 2.5\}$ standart sapmaların ise $\sigma_1 = \{0.3, 1\}$, $\sigma_2 = \{1, 0.5\}$ ve $\sigma_3 = \{2, 1\}$ olduğu Gaussian dağılımından tesadüfi olarak örneklerin seçilmesiyle oluşturulmuştur. Böylece Lingo8 modeli şekil 5' teki gibidir. Şekil 6' da Lingo8' in bulduğu sonuç, şekil 7' de ise BT algoritmasının bulduğu sonuç gösterilmektedir. Görüldüğü gibi Lingo8 ancak uygun bir çözüm bulabilmiştir. Amaç fonksiyon değeri D ile temsil edilecek olursa $D_{Lingo8} = 10.719$ iken $D_{BT} = 1.182$ dir.

```
MODEL:
sets:
  K/1..3/;
  N/1..6/;
  p/1..2/;
  Nxp(N, p): x;
  KxN(K, N): W;
  Kxp(K, p): m;
endsets
data:
x = 3.183821505591241,1.5159106555167672, ...;
enddata
min = @sum(K(k): @sum(N(i): @sum(p(l): W(i, k) * (x(i, l) - m(k, l)) * (x(i, l) - m(k, l)))));
@for(N(i): @sum(K(k): W(i, k)) = 1);
@for(K(k): @sum(N(i): W(i, k)) >= 1);
@for(KxN: @bin(W));
@for(K(k): @for(p(l): m(k, l) = @sum(N(i): W(i, k) * x(i, l)) / @sum(N(i): W(i, k)));
END
```

Şekil 5. Kümeleme için Lingo8 modeli



Şekil 6. Lingo8' in bulduğu sonuç.



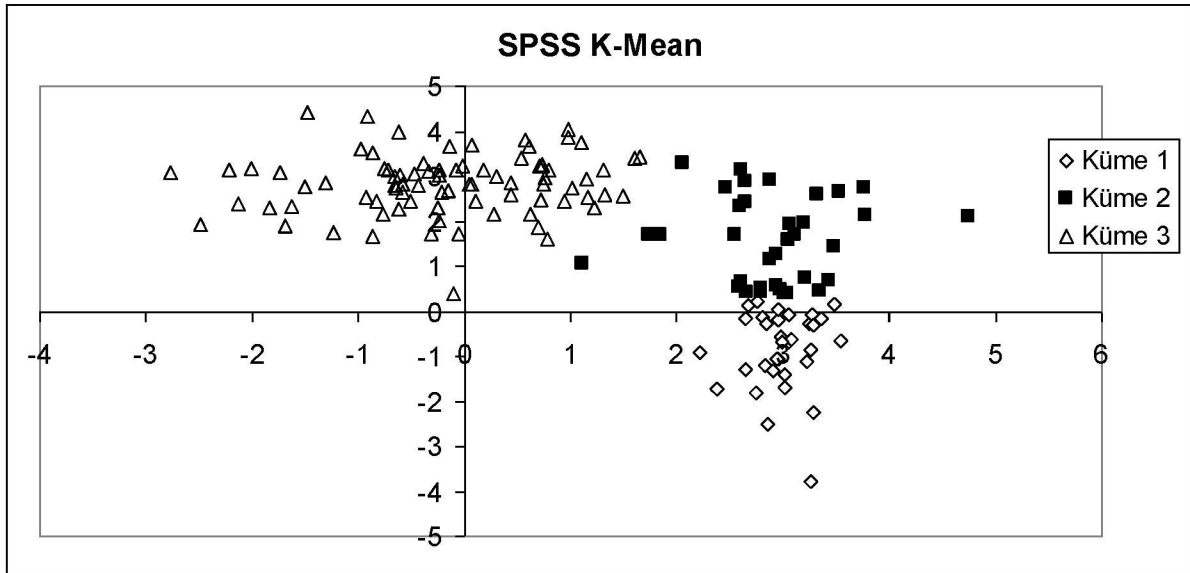
Şekil 7. BT algoritmasının bulduğu sonuç

Problem 2


İkinci problemde $N = 150$ ve $K = 3$ tür. Problem ortalamaların $\mu_1 = \{3, 0\}$, $\mu_2 = \{0, 3\}$ ve $\mu_3 = \{1.5, 2.5\}$ standart sapmaların ise $\sigma_1 = \{0.3, 1\}$, $\sigma_2 = \{1, 0.5\}$ ve $\sigma_3 = \{2, 1\}$ olduğu Gaussian dağılımından tesadüfi olarak örneklerin seçilmesiyle oluşturulmuştur. BT algoritması 9.203 saniyede sonucu bulmuştur. Diğer teknikler ile karşılaştırmalı sonuçlar tablo 1’ de verilmiştir. En iyi iki çözüm olan SPSS 12.0 K-Means tekniği ile BT’ nin sonuç grafikleri sırasıyla şekil 8 ve şekil 9’ da gösterilmiştir.

Tablo 1. Problem 2’ nin tüm tekniklere göre amaç fonksiyonu değerleri

Kullanılan Teknik	D
BT Algoritması	183.0604
SPSS K-Means	191.3374
SPSS Hierarchical	270.59
SPSS Twostep	823.9007



Şekil 8. SPSS 12.0 K-Means sonucu.



Şekil 9. BT algoritmasının bulduğu sonuç

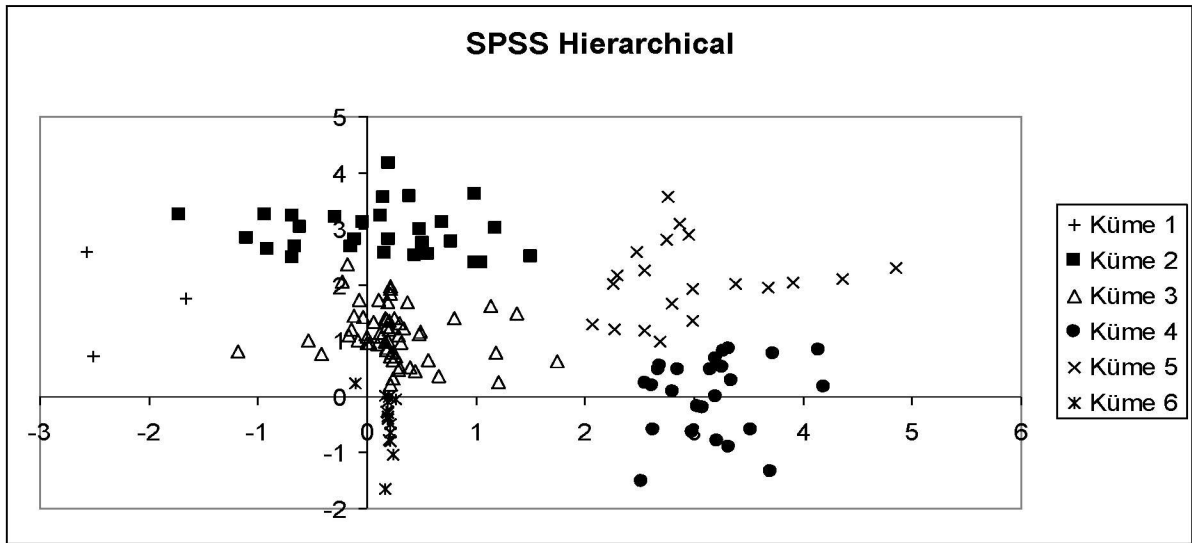
Problem 3

Üçüncü problemde $N = 150$ ve $K = 6$ dir. Problem ortalamaların $\mu_1 = \{3, 0\}$, $\mu_2 = \{0, 3\}$, $\mu_3 = \{1.5, 2.5\}$, $\mu_4 = \{0.2, 0.1\}$, $\mu_5 = \{1.2, 0.8\}$ ve $\mu_6 = \{0.1, 1.1\}$ standart sapmaların ise $\sigma_1 = \{0.3, 1\}$, $\sigma_2 = \{1, 0.5\}$, $\sigma_3 = \{2, 1\}$, $\sigma_4 = \{0.03, 1\}$, $\sigma_5 = \{2, 0.5\}$ ve $\sigma_6 = \{0.2, 0.4\}$ olduğu Gaussian dağılımından tesadüfi olarak örneklerin seçilmesiyle oluşturulmuştur. BT algoritması 16.453 saniyede sonucu bulmuştur. Diğer teknikler ile karşılaştırmalı sonuçlar tablo 2’ de verilmiştir. En iyi iki çözüm olan SPSS 12.0 Hierarchical tekniği ile BT’ nin


sonuç grafikleri sırasıyla şekil 10 ve şekil 11’ de gösterilmiştir.

Tablo 2. Problem 3’ ün tüm tekniklere göre amaç fonksiyonu değerleri

Kullanılan Teknik	D
BT Algoritması	88.7992
SPSS K-Means	100.9936
SPSS Hierarchical	87.01999
SPSS Twostep	527.228



Şekil 10. SPSS 12.0 Hierarchical sonucu




Şekil 11. BT algoritmasının bulduğu sonuç

Problem 4

Dördüncü problemde $N = 450$ olmak kaydıyla diğer parametereler üçüncü problem için kullanılanla aynı


olarak alınmıştır. BT algoritması 325.578 saniyede sonucu bulmuştur. Diğer teknikler ile karşılaştırmalı sonuçlar tablo 3' te verilmiştir. En iyi iki çözüm olan SPSS 12.0 K-Mean tekniği ile BT' nin sonuç grafikleri sırasıyla şekil 12 ve şekil 13' te gösterilmiştir.



Şekil 12. SPSS 12.0 K-Mean sonucu

Tablo 3. Problem 4' ün tüm tekniklere göre amaç fonksiyonu değerleri

Kullanılan Teknik	D
BT Algoritması	367.3931
SPSS K-Mean	369.9486
SPSS	876.0893
Hierarchical	
SPSS Twostep	1996.158



Şekil 13. BT algoritmasının bulduğu sonuç

SONUÇ

Bu çalışmada önerilen yöntem, en sık kullanılan yöntemlerden bazıları ile kıyaslanmıştır. Sonuçlar incelendiğinde bir problem hariç hepsinde önerilen BT algoritması daha başarılı olmuştur. Söz konusu problemde ise en iyi çözüme oldukça yakın bir çözüm elde edilmiştir. Çalışma süreleri incelendiğinde algoritmanın problem boyutuna bağlı olarak makul sürelerde çözümü bulduğu söylenebilmektedir. Böylece sonuç olarak BT yaklaşımının kümeleme için başarıyla kullanılabileceği görülmektedir.

KAYNAKÇA

- Aarts E., Lenstra J. K., 2003, **Local Search in Combinatorial Optimization**, Princeton University Press, USA.
- Bryson K. M. O., Inness T. R., 2007, "A hybrid clustering algorithm", **Computers & Operations Research**, 34, 3255 – 3269.
- Güngör Z., Ünler A., (Baskıdaki Makale), "K-Harmonic Means Data Clustering with Tabu-Search Method", **Applied Mathematical Modeling**.

- Johnson S., 1967, "Hierarchical clustering schemes", **Psychometrika**, 2, 241–254.
- Kirkpatrick S., Gerlatt C. D. Jr., Vecchi M.P., 1983, "Optimization by Simulated Annealing", **Science**, 220, 671-680.
- Liu Y., Chen K., Liao X., Zhang W., 2004, "A genetic clustering method for intrusion detection", **Pattern Recognition**, 37, 927 – 947
- McQueen J., 1967, "Some methods for classification and analysis of multivariate observations", **Proceedings of the fifth Berkeley symposium on mathematical statistics and probability**, 281–297.
- Metropolis N., Rosenbluth A.W., Rosenbluth M. N., Teller A.H., Teller E., 1958, "Equations of State Calculations by Fast Computing Machines", **J. Chem. Phys.**, 21, 1087- 1092.
- Shelokar P.S., Jayaraman V.K., Kulkarni B.D., 2004, "An ant colony approach for clustering", **Analytica Chimica Acta**, 509, 187 – 195
- Ward J., 1993, "Hierarchical grouping to optimize an objective function", **Journal of American Statistical Association**, 58, 236–244.