

GUIDE – Hücresel Küme Ayırıştırma Uygulaması: Yeraltı suyu Arsenik İçeriği Durum Çalışması

GUIDE – Cell Declustering Application: Case Study on Groundwater Arsenic Content

Güneş Ertunc^{1*}

¹ Hacettepe Üniversitesi, Mühendislik Fakültesi, Maden Mühendisliği Bölümü, 06800 Ankara

* Sorumlu yazar, e-mail: gertunc@hacettepe.edu.tr, ORCID: 0000-0003-0914-2745

Özet

Bir sahada rastlantı değişkenin çok yüksek veya çok düşük aykırı değerlere sahip alanlarında daha yoğun örneklemme, değişkenin dağılımını daha iyi anlayabilmek adına, genellikle tercihli olarak yapılmaktadır. Ancak bu durum, bu değişkenin gerçek dağılımı ile yanlış bir farkın ortaya çıkmasına neden olmaktadır. Tercihli örneklemeden kaynaklanan yanlış ortalama farkını önlemek için, numuneler düzenli aralıklarla veya rastgele toplanmalıdır. Alternatif olarak, değişkenin saha genelindeki ortalamasını doğru bir şekilde ortaya koymak için hücresel küme ayırıştırma yöntemi (cell declustering) uygulanmalıdır. GUIDE (Geostatistical Utility in Domaining and Estimation) mekansal verilerin istatistiksel analizi, krigleme yöntemi ile kestirimini ve jeolojik homojen bölgelerin belirlenmesi için çözüm araçları barındıran modüler uygulamalar bütününden oluşan bir bilgisayar programıdır. Bu çalışmanın amacı, GUIDE ile hücresel küme ayırıştırma uygulaması sunmaktır. Yeraltı suyu arsenik ölçümlerinin analiz değerleri ile programın işleyışı durum çalışması olarak verilmiştir. Durum çalışmasında yüksek arsenik değerlerinin tercihli olarak yoğun şekilde örneklenmesi sonucunda ortaya çıkan istatistikler ile hücresel küme ayırıştırma uygulandıktan sonra oluşan istatistikler ve histogram sonuçları karşılaştırılmıştır.

Anahtar Kelimeler: Hücre küme ayırıştırma, istatistik, yeraltı suyu, arsenik

Abstract

In order to have better understanding on the distribution of the variable, more intensive sampling in the areas of the random variable with very high or very low outliers in a field is usually done preferentially. However, this situation causes a biased difference with the actual distribution. Samples should be collected at regular intervals or randomly to avoid biased mean difference due to preferential sampling. Alternatively, the cell declustering method should be applied to accurately represent the statistics of the variable. GUIDE (Geostatistical Utility in Domaining and Estimation) is a computer program consisting of modular applications that contain tools for exploratory data analysis of spatial data, kriging estimation and domaining. Within the scope of this study, the cell declustering application of the program is presented and the analysis of groundwater arsenic measurements is given as a case study. In the case study, the statistics obtained as a result of preferential sampling of high arsenic values and the statistics and histogram results after cell declustering method is compared.

Keywords: Cell declustering, statistics, groundwater, arsenic

1.Giriş

Çoğu zaman bir bölgesel değişkene ilişkin kararlar, mekansal verinin düzenli olmayan konumsal dağılımına göre istatistiksel analizine göre verilmektedir. Özniteligin değerleri, sahada var olan heterojenlik nedeniyle genellikle farklı şekilde etkilenir. Örneğin, cevherleşme, yeraltındaki jeolojik ortamlara; veya yeraltı suyunda kirletici konsantrasyonları suyun akış yönlerine bağlanabilir. Değişkenin sahanın bir bölümünde anormal derecede yüksek veya düşük değerlere sahip olması çok olağan ve sıkılıkla karşılaşılan bir durumdur. Aykırı değerlerin olduğu bölgelerde tercihli şekilde daha sık örneklem alınmasının özniteligin yapısını daha iyi anlayabilmek için olduğu göz önüne alındığında anlaşılabılır bir durumdur. Ancak, bu değişkenin gerçek dağılımında yanlış bir fark ortaya çıkacağı mutlaka dikkate alınması gereken bir durumdur.

Veriler üzerindeki heterojen saha özgür etkilerin neden olduğu düzensiz örneklemme ve bu yanılılığı (biasness) hesaba katmak için, mekansal verileri analiz etmek için önemli bir jeostatistiksel araç olarak hücre küme ayrıştırma yöntemi literatürde bir çok araştırmacı tarafından sunulmuştur (Deutsch ve Journal, 1998; Deutsch ve ark., 1999; Pyrcz ve Deutsch, 2002; Renard ve ark., 2020).

Belirsizlik değerlendirme ve jeostatistiksel benzetim gibi analizlerde rastlantı değişkenini temsil eden dağılımlar veya kategorik özniteligi ilişkin oranlar temel girdi parametreleridir. Bu dağılımları veya oranları belirlemede kümeleme teknikleri oldukça sıkılıkla kullanılmaktadır. Bu teknik ile her bir veriye ($z_i=1,\dots,n$) çevresindeki verilere yakınlığına bağlı olarak bir ağırlık ($w_i=1,\dots,n$) atanır. Birbirlerine yakın olan verilere daha az ağırlık atanırken, birbirinden çok uzak olan veriler daha fazla ağırlık kazanır. Buradaki temel varsayımdır, daha yakın verilerin tercihen düşük veya yüksek değerli alanlardan toplandığıdır. Kümeleme tekniği ile parametrik olmayan dağılım ve özet istatistikler atanmış ağırlıklar kullanılarak oluşturulur.

GUIDE (Geostatistical Utility in Domaining and Estimation) mekansal verilerin istatistiksel analizi, krigleme yöntemi ile kestirim ve jeolojik homojen bölgelerin belirlenmesi için çözüm araçları barındıran modüler uygulamalar bütününden oluşan ve yazar tarafından kodlanan bir bilgisayar programıdır. MATLAB CompilerTM ile derlenmiştir ve çalışmaya konu olan Hücre Küme Ayrıştırma uygulama modülü <http://yunus.hacettepe.edu.tr/~gertunc/HKA.rar> adresinden ücretsiz bir şekilde indirilebilir.

2.Yöntem

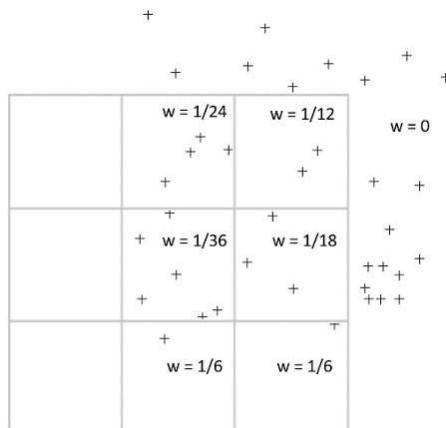
İlk olarak Journel (1983) tarafından sunulan hücresel küme ayrıştırma yöntemi, veri setinin yayıldığı alana uyarlanan iki boyutlu bir ızgara ve bu ızgarayı oluşturan hücrelere düşen örnek noktalarının bulunma yüzdelere göre, örneklerde ağırlık atanması esasına dayanır. Bu ızgarayı oluşturan hücreler, jeostatistiksel kestirim veya benzetimde kullanılan blok kavramından tamamen farklıdır. Hücre boyutu, bu yöntemde seyrek örneklenen bölgelerdeki veriler arasındaki uzaklığa ile ilişkilidir. Bu yüzden, yöntem ismini Türkçeleştirirken blok yerine hücre kelimesi daha uygun bulunmuştur. Hücrede yalnızca bir tane örnek bulunması durumunda ağırlık aşağıdaki formül ile bulunur.

$$w_i = \frac{1}{\frac{n_{dh}}{n_{vs}}}$$

Burada, w_i : i lokasyonundaki örneğe ait ağırlığı, n_{dh} : ızgara yapısındaki toplam dolu hücre sayısını ve n_{vs} : hücre içindeki veri sayısını ifade etmektedir.

Tüm örneklerde atanan ağırlıklar ile ağırlıklandırılmış istatistikler (Q1, ortalama, Q3, ve histogram dağılımı) hesaplanır. Bu sayede ağırlıklandırılmış veriler ile hesaplanan istatistikler, tercihli örneklem durumunda yanlış ve yanıldıcı istatistikleri düzeltmiş olur.

Şekil 1'de 18 örnek lokasyonu ve 6 dolu hücre için oluşan durum ve ağırlıklar göreselleştirilmişdir.

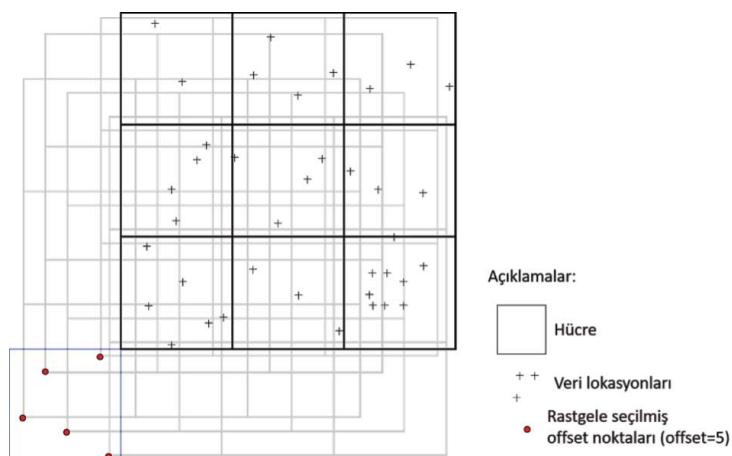


Şekil 1 Dolu hücreler ve örneklerin herbirinin aldığı ağırlıklar.

Şekil 1'deki duruma göre, ızgaranın en güneyinde orta ve sağ alt hücrelerinde yalnızca birer örnek bulunduğu için her iki örnek ağırlık olarak $1/6$ değerini almışlardır. Diğer hücrelerdeki durumlarda artan örneklerde göre ters orantı ile ağırlıklar düzenlenmiştir. Bu durumda hücre içine düşen örnek sayısı arttıkça, bu örneklerde atanan ağırlıklar azalmaktadır.

2.1 Offset sayısı

Izgaranın hangi lokasyondan başladığının örnek lokasyonlara atanan ağırlıklar üzerinde doğrudan etkisi olduğundan, her numuneye ortalama bir ağırlık sağlamak için çeşitli sayıda başlangıç noktası kullanılır. Rastlantısal seçilen başlangıç noktası sayısı “offset sayısı” ile ifade edilmektedir. Endüstri pratigi göz önüne alındığında bu değer 25 ile 100 arasında değişeceğin şekilde belirlenmiştir. Şekil 2'de, offset sayısının 5 olarak aldığı durum görselleştirilmiştir.



Şekil 2 Beş farklı offset noktasına göre ızgaralar.

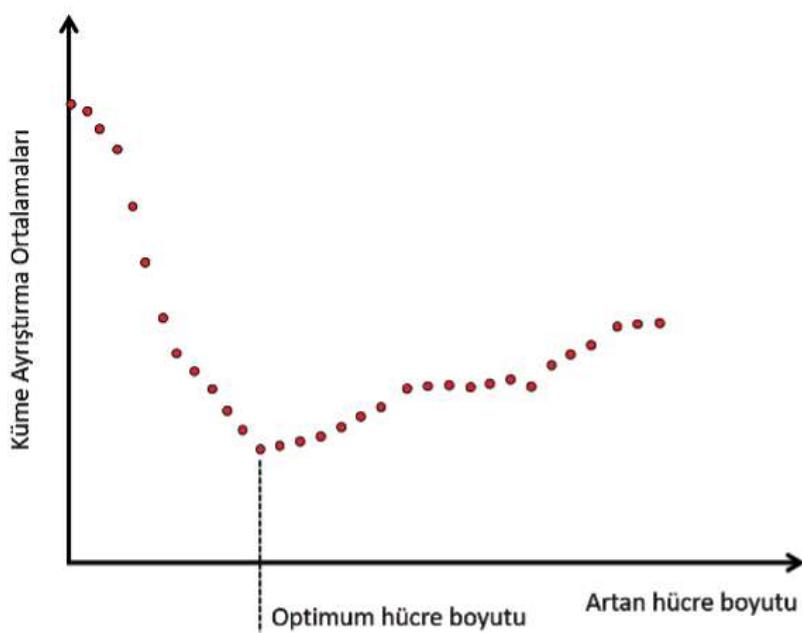
Şekil 2'ye göre 5 farklı durumda örnekler atanan ağırlıkların ortalamaları, seçili hücre boyutuna göre atanan ağırlıklar olarak belirlenir.

2.2 Hücre boyutu

Hücre küme ayırtırma yönteminin bir diğer önemli parametresi hücre boyutudur. Çok küçük seçilen hücre boyutunda, dolu hücre sayısı örnek sayısına eşit olacağinden her bir örneğe atanan ağırlık 1'e eşit olacaktır. Çok büyük boyutlu bir hücre durumunda ise tüm örnek lokasyonları eşit şekilde ağırlanacaktır. Her iki durumda ağırlıklı ortalama değerleri birbirine eşittir. Bu yüzden, hücre küme ayırtırma yönteminde optimum hücre boyutu seçebilmek için küçükten büyüğe doğru değişen her hücre boyutu için ayrı ayrı hesaplama yapılmaktadır.

Optimum hücre boyutu, seyrek örneklenen lokasyondaki verilerin aralığıdır. Bu optimum boyut tam olarak bilinmemektedir ve doğru boyutun seçilmesine yardımcı olmak için bir dizi hücre boyutu girdi parametresi olarak düşünülmelidir. Bu nedenle, en büyük hücre boyutu çok büyük ayarlanmamalıdır.

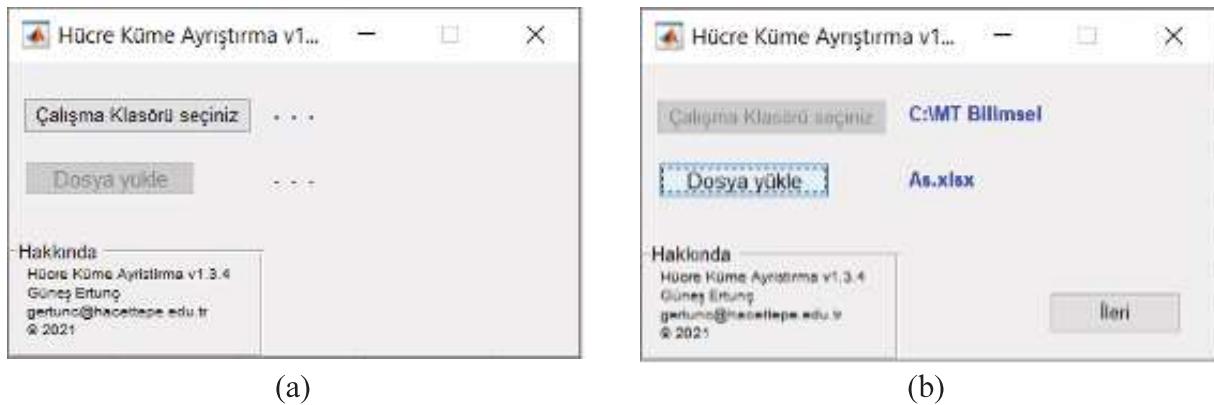
Optimum hücre boyutunu seçmek için en iyi yaklaşım, çeşitli hücre boyutları için küme ayırtırma ortalamayı değerlendirmek ve bu ortalamayı en aza indirmeye veya en yüksek değere ulaştırmaya yakın bir değer seçmektir. Şekil 3'te, küme ayırtırılan ortalamanın artan hücre boyutuyla değişimi verilmiştir.



Şekil 3 Değişen hücre boyutlarına göre hücre küme ayırtırma ortalamaları

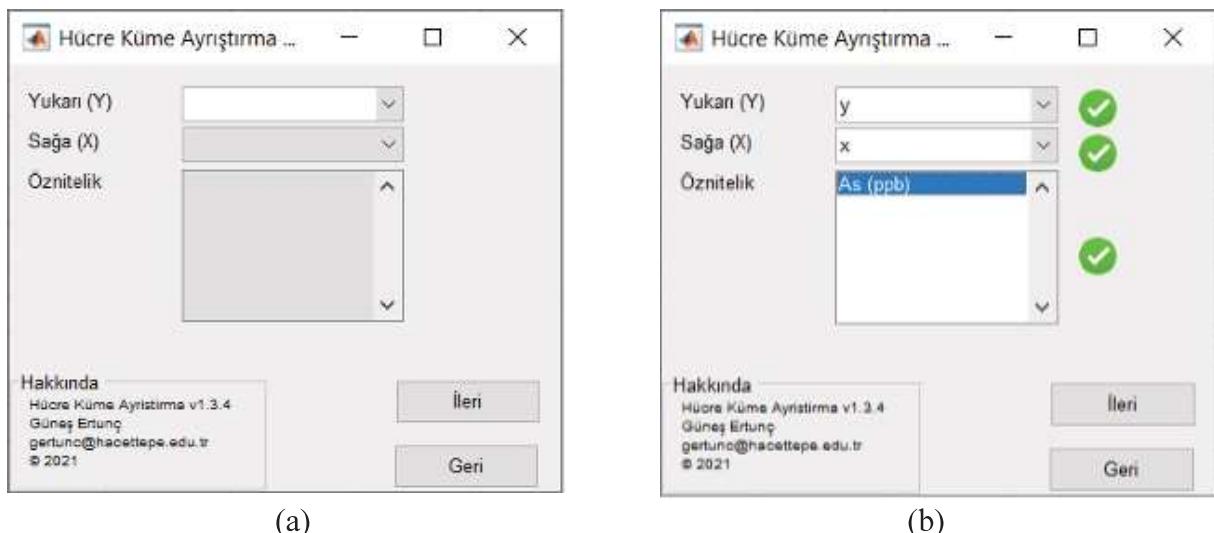
3. GUIDE – Hücresel Küme Ayırtırma Modülü ve Durum Çalışması

Hücre Küme Ayırtırma modülü toplam 4 girdi ekranından oluşmaktadır. Öncelikle, kullanıcı MS Office Excel formatındaki dosyasının bulunduğu klasörü “Çalışma Klasörü” olarak belirler.



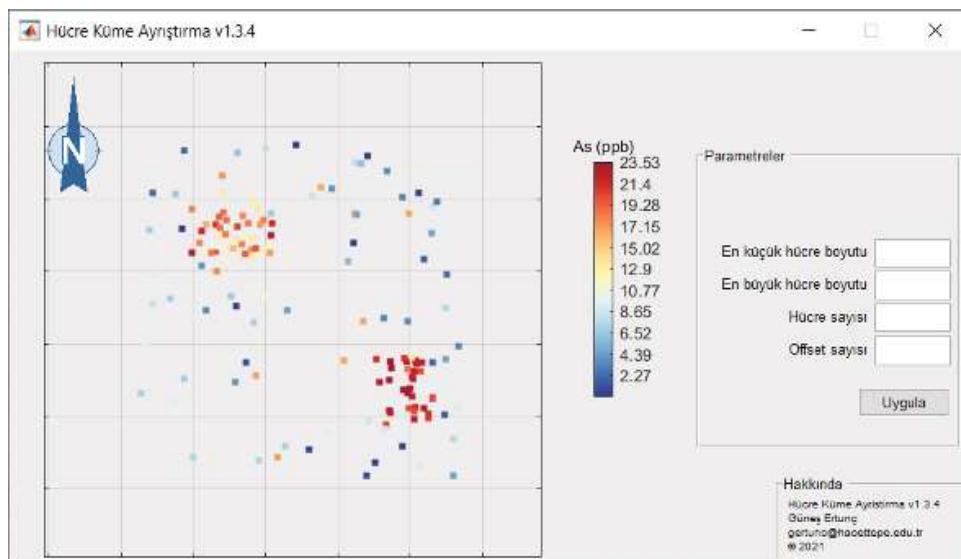
Şekil 4 a) Dosya yükleme ekranı, b) Yüklenmiş dosya ekranı

Uygulama iki boyutlu olduğu için kullanıcı bir sonraki öznitelik seçim ekranında Yukarı (Y), Sağ (X) koordinat sütunlarını seçtikten sonra öznitelik seçimi yapar (Şekil 5).



Şekil 5 a) Öznitelik seçim ekranı, b) Sütunların eşleştirilmesi

İleri butonu ile kullanıcı hücre küme ayırıştırma yöntemi için gerekli parametrelerin girildiği ekrana yönlendirilir (Şekil 6). Seçilen özniteligin tematik olarak gösterildiği bu ekranda kullanıcı sırasıyla en küçük hücre boyutunu, en büyük hücre boyutunu, bu iki değer arasında kaç hücre boyutu olacağını ve offset sayısını girer.



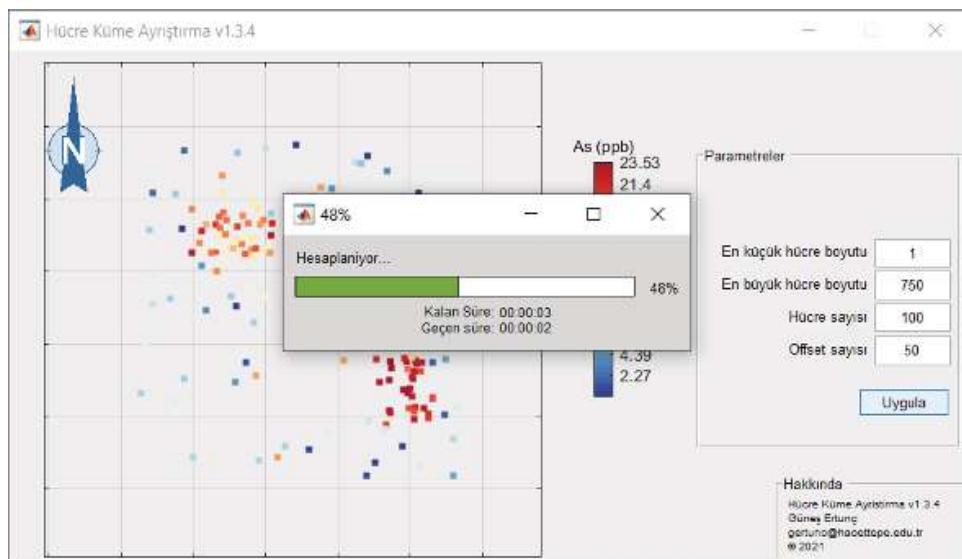
Şekil 6. Hücre küme ayrıştırma parametre ekranı

3.1 Durum Çalışması

Çalışmada kullanılan veri seti, $\mu\text{g/L}$ cinsinden ölçülen arsenik konsantrasyonlarını içeren iki boyutlu uzayda dağılmış 153 yeraltı suyu örneğinden oluşan sentetik bir arsenik değerlerinden oluşur (Şekil 6). Yaklaşık 1 km^2 'lik alana yayılan veri setinde örnekler arasındaki mesafeye ilişkin tanımlayıcı istatistikler Tablo 1'de yer almaktadır. Bu veri setine <http://yunus.hacettepe.edu.tr/~gertunc/decluster.rar> adresinden erişilebilir.

Tablo 1 Örnekler arasındaki mesafelere ilişkin tanımlayıcı istatistikler.

En küçük değer	2.3
En büyük değer	1278
Ortalama	459.5
Q1	249.52
Ortanca (Q2)	481
Q3	648
Varyans	58334



Şekil 7. Değişen hücre boyutlarına göre hücre küme ayırıştırma ortalamaları

Tablo 2 Arsenik verisi tanımlayıcı istatistikleri

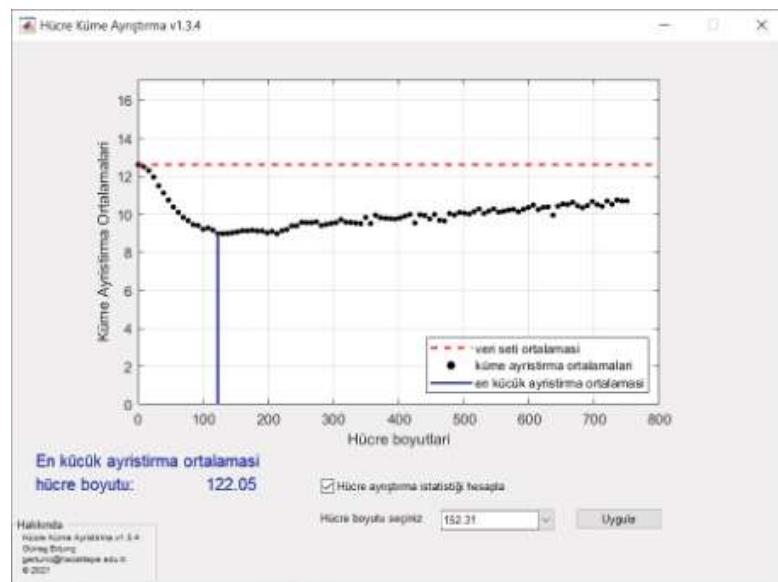
Veri sayısı	153
En küçük değer	0.148
En büyük değer	23.53
Ortalama	12.61
Q1	6.78
Ortanca (Q2)	12.76
Q3	19.36
Varyans	53.87

Bu veri seti için seçilen hücre küme ayırıştırma parametreleri aşağıda sıralanmıştır.

Tablo 3. Hücre Küme Ayırıştırma Parametreleri

En küçük hücre boyutu	1 m
En büyük hücre boyutu	750 m
Hücre sayısı	100
Offset sayısı	50

Seçilen hücre sayısı 100 olduğundan, hücre boyutu 1 m'den başlayarak 7.56 m'lik artışlar ile 750 m'ye kadar ayrıstırılmış ortalamalar hesaplanmıştır ((750-1)/99). Parametrelere göre çözüm sonuçları Şekil 8'de verilmektedir. Şekil 8'de kesikli kırmızı çizgi orijinal verinin ortalama değeridir (12.61).



Şekil 8. Değişen hücre boyutlarına göre hücre küme ayırıştırma ortalamaları

En küçük ayırıştırma ortalaması, hücre boyutu 122.05 m olduğu durumda hesaplanmıştır. Bu durumda, hücre ayırıştırma istatistikleri bu boyut seçilerek yapılmıştır. Seçilen boyuta göre ortaya çıkan histogram ve istatistikler Şekil 9'da verilmektedir. Normal dağılım göstermeyen veri setinin, hücre ayırıştırma sonrasında uniform dağılıma yakın bir davranış gösterdiği görülmektedir.



Şekil 9. Değişen hücre boyutlarına göre hücre küme ayırıştırma ortalamaları

4 Sonuç

DSÖ (Dünya Sağlık Örgütü), içme suyu arsenik içeriği yönergusonune (WHO, 2021) göre içme suyunun arsenik içeriğinin $10 \mu\text{g/L}$ geçmemesi gerektiğini belirtmektedir ve orijinal veri setinin arsenik ortalaması $12.60 \mu\text{g/L}$, bu sınırın üzerindedir. Yüksek değerlerin olduğu bölgelerden fazla örnek toplama, başka bir deyişle tercihli örnek toplama stratejisi gereği çıkan bu sonucun yanlış ve dahası, yaniltıcı bir sonuçtur.

Orijinal veri histogramı ile hücre küme ayırıştırma ile elde edilen histogram karşılaştırıldığında,

orijinal verinin yüksek değerlerinin daha sık olduğu görülmektedir. Veri seti incelendiğinde, yüksek değerlerin daha sıklıkla örneklentiği ve hücre kümeleme ayırıştırma yönteminin bu değerlerin ağırlıklarını düşürerek yanlı istatistikleri düzeltken nitelikte sonuçlar ortaya koyduğu anlaşılmaktadır. Düzeltilen istatistikler sonucunda saha genelindeki ortalamanın 9.03 ug/L olduğu ve kabul edilebilir sınırlar içerisinde kaldığı ortaya konmuştur.

Dikkat edilmesi gereken diğer bir bulgu ise, örnek değerlerinin değişmemesidir. Hücre küme ayırıştırma yönteminde verinin kendisi değil, onu karakterize eden istatistiklerin -varsayı tercihli örneklem stratejisi yüzünden yanlı istatistiklerin- düzeltilememesidir. Düzeltilen istatistikleri oluşturan temel unsur, örnek değerlerlerinin birbirlerine yakınlığı esas alınarak atanmış ağırlıklarıdır. Bu nedenle en küçük ve en büyük değerler hücre küme ayırıştırması yöntemi uygulamasından etkilenmezler (Şekil 9).

Kaynaklar

Deutsch, C.V., Journel, A.G., 1998. GSLIB: Geostatistical Software Library: and User's Guide, 2nd Ed. New York: Oxford University Press.

Deutsch, C.V., Frykman, P., Xie, Y.L., 1999. Declustering with Seismic or “soft” Geologic Data, Centre for Computational Geostatistics Report One 1998/1999, University of Alberta.

Pyrcz, M.J., Deutsch, C.V., 2002. Declustering and Debiasing. In Centre for Computational Geostatistics, Paper 62, Annual Report 4.

Renard, D., Bez, N., Desassis, N., Beucher, H., Ors, F., Laporte, F., 2020, RGeostats: The Geostatistical package. MINES ParisTech

WHO, 2021, <https://www.who.int/news-room/fact-sheets/detail/arsenic>, (Erişim tarihi: 25/03/2021)