

Zamansal Veri Madenciliği ve Anomali Tespiti için Bir Uygulama

Mehmet Yavuz Onat¹, Engin Yıldıztepe¹

¹Dokuz Eylül Üniversitesi, İstatistik Bölümü, İzmir
yavuz.onat@gmail.com , engin.yildiztepe@deu.edu.tr

Özet: Zamansal veri madenciliği, veri madenciliği temelleri içerisinde zaman serilerinin karakterlerine uygun yöntemleri kullanır. Zaman serisi analizi yöntemleri, genellikle bir zaman serisini modellemeye ve sonraki adımı tahminlemeye çalışırlar. Zamansal veri madenciliği ise zaman serilerinden oluşan bir veri tabanında benzer zaman serilerini bulmayı veya bir zaman serisi içerisinde gerçekleşen olağan dışı desenleri belirlemeyi hedefler. Bu çalışmada, zamansal veri madenciliği incelenmiş, R istatistiksel programlama dili kullanılarak zamana bağlı verilerde anomali tespiti için yapılan bir uygulama tartışılmıştır.

Anahtar Sözcükler: Zamansal Veri Madenciliği, Anomali Tespiti, SAX, PAA

Temporal Data Mining and an Application for Anomaly Detection

Abstract: Temporal data mining is a data mining techniques executed over temporal data. Temporal data have different characteristics than other data sources. Classic time series analysis methods concentrate to model and forecast the series. Temporal data mining is generally interested in finding similar time series in a database of time series or detecting the novelties in a time series. In this study, temporal data mining is examined and an application for anomaly detection in temporal data is discussed. Statistical programming language R is used for analysis.

Keywords: Temporal Data Mining, Anomaly Detection, SAX, PAA

1.Giriş

Zamana bağlı değerlerin madenciliği güncel ve gelişen bir çalışma alanıdır. Zaman serileri, sürekli veri yapısı ve çok fazla veri içermesi nedeni ile istatistik ve bilgisayar bilimlerinde farklı bir alan olarak incelenmektedir. Veri madenciliği alanında zamana bağlı değerlerin analizi zamansal veri madenciliği olarak nitelendirilmektedir. Zamansal veri madenciliği kavramı ve kullanılan yöntemlerin gelişimi [4,6,19]'da verilen çalışmalarda detaylı olarak ele alınmıştır.

Zamansal veri madenciliği; istatistiksel yöntemlerdeki varsayımlara gerek duymadan zamana bağlı veriler içerisinde anlamlı bilgiler çıkarmayı amaçlar. Zaman serisi analizi yöntemleri, genellikle bir zaman serisini modellemeye ve sonraki adımı tahminlemeye çalışırlar. Zamansal veri madenciliği ise zaman serilerinden oluşan bir veri tabanında benzer zaman serilerini bulmayı veya bir zaman serisi içerisinde gerçekleşen olağan dışı desenleri belirlemeyi hedefler.

Zaman serilerinin çok boyutlu olması, bağımlı yapısı ve gürültü içermesi nedeni ile veri madenciliği yöntemleri ve benzerlik ölçümleri yetersiz kalabilmektedir [19]. Zamansal veri madenciliği yöntemlerinde benzerlik ölçümü için zaman ser-

ilerine daha uygun yaklaşımlar geliştirilmiştir. Örneğin, Berndt ve Clifford tarafından önerilen “Dynamic Time Warping” doğrusal olmayan eşleşmeleri de göz önünde bulundurarak uzaklık ölçümü yapan bir algoritmadır [2].

Zaman serilerinde benzerlik ölçmek için önerilen yöntemler ve karşılaştırmaları detaylı olarak [1,12]'de verilen çalışmalarda incelenmiştir.

Bu çalışmada bir finansal zaman serisi üzerinde “Heuristically Ordered Time series using Symbolic Aggregate Approximation” (HOT-SAX) algoritması ile anomali tespiti yapılmıştır. Uygulamada R istatistiksel programlama dili kullanılmıştır. İkinci bölümde zamansal veri madenciliği yöntemlerinden bahsedilmiştir. Zaman serisinin temsil edilmesi üçüncü bölümde incelenmiştir. Dördüncü bölümde HOT-SAX anomali tespiti yöntemi anlatılmıştır. Beşinci bölümde yapılan uygulama ve sonuçları verilmiştir.

2. Zamansal Veri Madenciliği Yöntemleri

Zamansal veri madenciliğinde farklı yöntemler bulunmaktadır. Aggrawal zaman serilerinden oluşan veritabanında benzer zaman serilerinin bulunmasını incelemiştir [1]. Faloutsos ve Keogh zaman serisinin alt kesitlerinin incelenmesi

ve boyut indirgeme konularını araştırmışlardır [5,10]. En çok kullanılan zamansal veri madenciliği yöntemleri şunlardır;

- Endeksleme (Indexing): Literatürde “Query by Content” olarak da isimlendirilen endeksleme, zaman serisinde önceden bilinen desenleri bulmak için kullanılır [9,19]. Birçok zamansal veri madenciliği yöntemi endekslemeyi bir alt rutin olarak kullanır.
- Sınıflama (Classification): Zaman serisini daha önceden belirlenen iki veya daha fazla farklı sınıfa ayırma yöntemidir.
- Kümeleme (Clustering): Zaman serilerinden oluşan bir veri tabanındaki grupların bulunması veya tek bir zaman serisi içerisindeki kesitlerin gruplara atanması yöntemidir.
- Anomali tespiti (Anomaly-Novelty Detection): Zaman serisinin içerisinde herhangi bir zaman aralığında gerçekleşen ve zaman serisinin diğer alt kesitleri ile uyuşmayan-benzemeyen kesitin tespit edilmesini amaçlar [13,17].

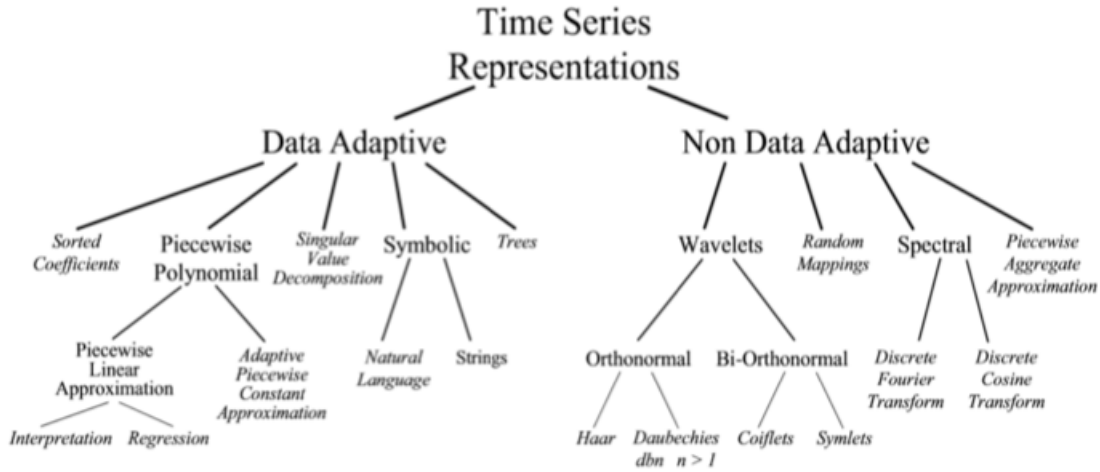
Zaman serileri, özellikle kısa zaman aralıkları ile veri toplandığı durumlarda, çok büyük miktarda veri içerebilir. Verilerin hazırlanması aşamasında kullanılacak yöntem uygun olarak zamana

bağlılığı kaybetmeden çok boyutluluktan kurtulmak gerekebilir. Bu işlem için zaman serisine uygun bir temsil yöntemi uygulanır. Çalışmanın amacına uygun olarak, temsil yöntemi ve veri madenciliği yönteminin belirlenmesi, zamansal veri madenciliği uygulamalarında en önemli adımdır.

Zaman serisi veri madenciliğinde en çok kullanılan yöntemlerden biri de anomali tespitidir. Bu alanda yapılan çalışmalar zaman serisinin içerisindeki uyumsuz-farklı kesitlerin tespiti üzerine yoğunlaşmıştır. Seçilen veri temsil edilme yöntemine göre farklı anomali tespiti algoritmaları geliştirilmiştir [4]. Anomali tespitinin detaylı olarak ele alındığı bir çalışma için [3] incelenebilir.

3. Zaman Serisinin Temsil Edilmesi

Zaman serilerinin çok boyutlu olması ve gürültü içermesi zamansal veri madenciliği uygulamalarındaki en büyük problemlerdendir. Bu nedenle zamana bağlı değerlerde, işlem yapmadan önce veri sayısını azaltmak gerekebilir. Literatürde boyut indirgeme (dimension reduction) olarak da isimlendirilen bu adım zamansal veri madenciliği için ayrı bir çalışma alanı oluşturur. Verilerin temsil edilmesi adımından sonra zaman serisinin temel özelliklerini kaybetmeden boyutunun azalması ve gürültüden arınmış olması gerekir.



Şekil-1 Zaman serisi temsil yöntemleri

Temsil etme metodunun doğru seçimi, yapılacak olan uygulamanın etkinliğinde ve kullanılabilirliğinde büyük rol oynar. Keogh ve arkadaşları zaman serilerinde kullanılan veri temsil etme yöntemlerini Şekil-1’deki gibi özetlemişlerdir [19]. Non Data Adaptive başlığı altında bulunan yöntemler, temsil edilecek bütün zaman seril-

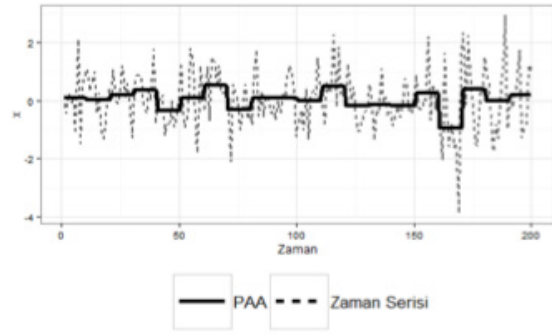
eri için aynı parametreleri kullanır. Data Adaptive başlığı altında ise işlem yapılan veriye göre değişen parametrelere sahip yöntemlere yer verilmiştir [4]. Bu çalışmada “Piecewise Aggregate Approximation” (PAA) ve “Symbolic Aggregate approximation”(SAX) yöntemleri incelenmiştir.

1997 yılında Keogh tarafından geliştirilen “Piecewise Linear Approximation” (PLA) yöntemi zaman serisini alt kesitleri içerisinde doğrular oluşturarak temsil etmeye çalışır [8]. PLA yönteminde kesitlerin her biri için başlangıç ve bitiş noktaları arasında oluşturulan doğrular yardımı ile her bir kesit temsil edilmiş olur. Bu yöntemin anomali tespiti algoritmalarında kullanımı güncel bir çalışmada önerilmiştir [14]. 2000 yılında Keogh ve arkadaşları tarafından önerilen PAA yöntemi ise zaman serisini kesitlere ayırarak, her bir kesitin ortalamasını kullanır [10]. Anomali tespiti veya benzerlik ölçümü çalışmalarında kullanılan PAA, 2001 yılında “Adaptive Piecewise Constant Approximation” (APCA) olarak geliştirilmiştir [11]. Önerilen geliştirilmiş algoritmada kesitlerin büyüklüğü değişken ve zaman serisinin şekli ile uyumludur.

Zaman serilerinin temsil edilmesinde yaygın olarak kullanılan bir diğer yöntem ise sembolik veri temsildir. Lin ve arkadaşlarının 2003 yılında önerdiği SAX yönteminde PAA ile her bir kesitten elde edilen sonuç bir sembol ile ifade edilir [15]. SAX yöntemi ile verilerin temsil edilmesinden alınan başarılı sonuçlar ve az parametre gereksinimi bu yönetime olan ilgiyi arttırmıştır. SAX yönteminin finansal zaman serileri için geliştirilmiş hali olan “Extended-SAX” (ESAX) yöntemi 2009 yılında önerilmiştir [7]. Yukarıda bahsedilen veri temsil yöntemleri trendi dikkate almamaktadır. Trendi göz önünde bulunduran bazı güncel çalışmaların trend içeren zaman serilerinde daha başarılı sonuçlar verdiği belirtilmiştir [14,18]. Bütün zaman serileri için başarılı sonuçlar veren bir temsil etme yöntemi bulunmamaktadır. Zaman serisinin karakterine göre en uygun temsil yöntemi tercih edilmelidir.

3.1 Piecewise Aggregate Approximation

Zaman serisini sabit uzunluktaki kesitlere ayırarak, her bir kesitin ortalaması ile temsil etmeyi amaçlar. Şekil-2’de PAA temsil yöntemi ile eşit parçalara bölünen ve yeni değerlerle temsil edilen bir zaman serisi görülmektedir.



Şekil-2 Bir zaman serisinin PAA ile temsil edilmesi

PAA için kesitlerin ortalaması aşağıdaki gibi bulunur.

1. C , n boyutunda bir zaman serisi olsun. C , w boyutunda bir vektör ile temsil edilebilir.
2. n/w boyutundaki w kesit C zaman serisinden elde edilir.
3. $\bar{C} = \bar{c}_1, \bar{c}_2, \dots, \bar{c}_w$ vektöründeki kesit ortalamaları aşağıdaki gibi bulunur.

$$\bar{c}_i = \frac{w}{n} \sum_{j=\frac{n}{w}(i-1)+1}^{\frac{n}{w}} C_j \quad i = 1, \dots, w \quad (1)$$

Kesit boyutu (n/w) PAA için gerekli olan tek parametredir. Seçilen kesit boyutunun zaman serisini eşit olarak bölemediği durum Lin ve arkadaşları tarafından incelenmiştir ve bu durumda kesitlerin başlangıç ve bitiş noktalarını ardışık kesitlerde ortak kullanmayı önermişlerdir [16].

3.2 Symbolic Aggregate Approximation

SAX yöntemi sembolik veri temsili yöntemleri içerisinde en çok kullanılan yöntemdir. Yukarıda bahsedildiği gibi farklı karakterdeki zaman serileri için başarılı sonuçlar alınmıştır. PAA üzerinden geliştirilen SAX, vektör halindeki temsil edilmiş veriyi sembollere dönüştürmeyi amaçlar. n boyutunda zaman serisi C için, SAX temsil yöntemi alttaki üç adımı izler;


1. Normalleştirme: Zaman serisi C için z-skorları bulunur.

$$c'_i = \frac{c_i - \bar{x}}{s} \quad i = 1, \dots, n \quad (2)$$

2. PAA ile boyut indirgeme: C_{\wedge} zaman serisi w boyutundaki vektör olarak temsil edilir.
3. Sembolik Dönüşüm: Standart normal dağılımdan yararlanarak belirlenen kesme noktalarına

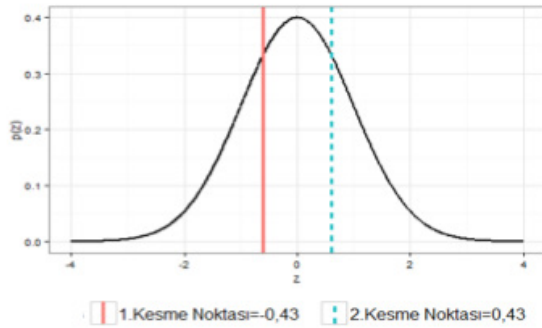
göre sembolik dönüşüm yapılır.

Keogh ve arkadaşları tarafından Şekil-3'te bir zaman serisinin her bir kesitinin kesme noktalarına göre düştüğü aralığa dayanarak yapılan sembol dönüşümü gösterilmiştir [13].



Şekil-3: PAA yaklaşımı ile SAX temsil yönteminin kullanılması.

SAX temsil yöntemi için gereken tek parametre sembolik gösterim için kullanılacak karakter sayısıdır. Seçilen karakter sayısına dayanarak kesme noktaları belirlenir, k tane karakter dönüşümü yapmak için Standart Normal dağılımı (1/k) olasılıkla eşit aralıklara bölerek k-1 tane kesme noktası hesaplanır. Örneğin, zaman serisi üç karakter ile temsil edilmek istendiğinde iki adet kesme noktası hesaplanmalıdır. Şekil-4'te gösterildiği gibi standart normal dağılımı üç eşit parçaya böldüğümüzde -0.43 ve 0.43 kesme noktaları elde edilir. Burada kesme noktaları standart normal dağılımda (1/3)'lük ve (2/3)'lük alanlara karşılık gelen Z değerleridir.



Şekil-4: Standart Normal dağılımdan k=3 için elde edilen kesme noktaları

Karakter dönüşümü 3 karakter için (3) deki gibi yapılır;

Kesme noktaları: β_1, β_2 olsun. PAA ile elde edilen kesitlerin ortalama değerleri kesme noktaları ile karşılaştırılır ve bulunduğu aralığa göre sembol belirlenir.

$$\text{Sembol} = \begin{cases} a; & \bar{c}_i < \beta_1 \\ b; & \beta_1 < \bar{c}_i < \beta_2 \\ c; & \bar{c}_i > \beta_2 \end{cases} \quad (3)$$

4. Anomali Tespiti

Zaman serilerinde anomali tespiti istatistik ve bilgisayar bilimleri alanında ilgi gören bir çalışma alanıdır. Zamansal veri madenciliğinde anomali tespiti yöntemleri, zaman serisi içerisindeki uyumsuz (farklı) kesitleri tespit etmeyi amaçlar.

SAX ile temsil edilen zaman serisi içerisindeki anomalileri tespit etmek için Keogh ve arkadaşları tarafından "Heuristically Ordered Time series using Symbolic Aggregate Approximation"(HOTSAX) algoritması geliştirilmiştir [13]. Bu algorithmada ihtiyaç duyulan tek parametre kesitin boyutudur. HOTSAX, zaman serisinin içerisindeki tüm kesitlerin benzerlik ölçümlerini yaparak anomali tespiti yapmaya çalışır.


HOTSAX algoritması aşağıdaki adımları izler;

- 1.Zaman serisi SAX yöntemi ile temsil edilir.
- 2.Kesitlere verilen sembollerden oluşan desenler elde edilir.
- 3.Oluşan desenlerden en az sayıda olanlar anomali adayı olarak seçilir.
- 4.Seçilen adayların diğer bütün kesitlere olan uzaklığı hesaplanır.
- 5.En yakın komşusuna olan uzaklığı en yüksek olan kesit anomali olarak belirlenir.

HOTSAX, "bruteforce" yöntemini kullanarak zaman serisi içerisinde gözlemlenen her kesiti, kendisi ile eşleşmeyen diğer tüm kesitlerle karşılaştırır. Kendisi ile eşleşmeyen kesitler (non-self match) tanımı şu şekilde yapılabilir; M ve K bir zaman serisinden seçilen m boyutunda kesitler ve bu kesitlerin başlangıç noktaları sırası ile p ve q olsun. M, K'nın kendisi ile eşleşmeyen bir kesiti ise $|p-q| \geq m$ koşulunu sağlaması beklenir. HOTSAX, seçilen anomali adaylarının bu koşulu sağlayan tüm eşleşmeleri ile uzaklıklarını ölçerek, en yakın komşusuna olan uzaklığı en yüksek olan deseni bulmaya çalışır.

5. Uygulama

Çalışmada, Aralık 2003 – Aralık 2014 tarihleri arasındaki Euro-Dolar parite değerleri incelenmiştir (Şekil-5). Zaman serisi "European Central Bank" internet sayfasından günlük (çalışma günleri) kaydedilmiş verilerden alınmıştır ve toplamda 2820 değerden oluşmaktadır [21].




Şekil-5 Aralık 2003 – Aralık 2014 tarihleri arasındaki Euro-Dolar paritesi

Zaman serisinin sembolik gösterimi için dört karakter (a,b,c,d) tercih edilmiştir. Zaman serisi kaydırmalı olarak belirlenen 10 genişliğinde alt kesitlerine ayrılarak analiz edilmiştir. Elde edilen her bir alt kesitin ortalamasına karşılık gelen değer bir sembol ile temsil edilmiştir.

Bu çalışmada her üç alt kesitin bir dönemi temsil ettiğine karar verilmiştir. SAX temsil yöntemi sonrasında her 30 çalışma gününden oluşan 6 haftalık dönem 3 karakter ile temsil edilmiştir. Kullanılan zaman serisinden 8373 alt kesit elde edilmiş ve 2791 dönem HOT-SAX algoritması ile incelenmiştir. Dönemler içerisinde “aaa” deseni 546 kere gözlemlenerek en sık görülen desen olmuştur. “aaa” deseninin en fazla gözlemlenen desen olmasının sebebi normalleştirilen zaman serisinin büyük bir bölümünün, SAX yöntemi için belirlenen ilk kesme noktasının altında olmasıdır. “aac” ve “bac” desenleri ise sadece birer kere gözlemlenmiş ve anomali adayları olarak seçilmiştir. Aday desenlerin zaman serisi içerisinde bulunduğu aralıklar Tablo-1’de verilmiştir.

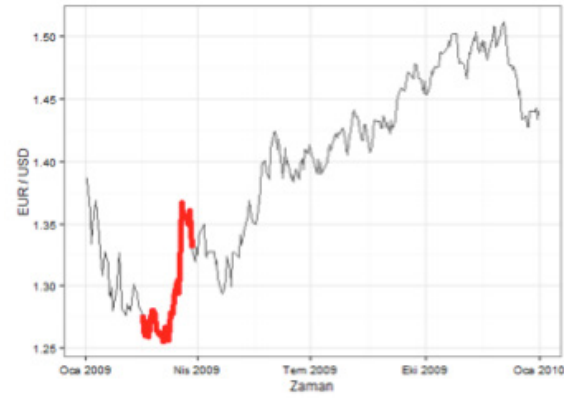
	Başlangıç	Bitiş
aac	16.02.2009	27.03.2009
bac	13.02.2009	26.03.2009

Tespit edilen anomali adayları zaman serisi içerisinde Şekil-6’da gösterilmiştir.




Şekil-6 Anomali adayları

Anomali adaylarının kendisi ile eşleşmeyen bütün kesitlere olan uzaklığı hesaplanmış ve en yakın komşuları belirlenmiştir. İçlerinden en yakın komşusuna en uzak olan desen “aac” anomali (en farklı desen) olarak seçilmiştir. 2009 yılı verilerinde, anomalinin gözlemlendiği aralık Şekil-7’de gösterilmiştir.



Şekil-7 2009 Yılına ait değerler ve anomalinin bulunduğu aralık

Oluşan desenin yakın görüntüsü Şekil-8’de verilmiştir. Bulunan “aac” deseni zaman serisinin geri kalanında gözlemlenmemiştir. Uygulamada belirlenen kesit genişliği ve zaman serisini temsil etmek için kullanılan sembol sayısının farklı seçilmesi sonuçları etkileyebilir.



Şekil-8 Tespit edilen anomali

6. Sonuç

Bu çalışmada zamansal veri madenciliği ve veri temsil yöntemleri incelenmiş, zamansal verilerde anomali tespiti için bir uygulama yapılmıştır. Veri temsil yöntemleri olarak PAA ve SAX, anomali tespiti algoritması olarak HOT-SAX kullanılmıştır. Uygulamada kullanılan zaman serisi desenler haline getirilmiş, oluşturulan 2791 desen içerisinde en az tekrarlayan anomali adayları desenler bulunmuştur. Bu adaylar arasından en yakın komşusuna en uzak olan anomali olarak tespit edilmiştir. Anomali olarak belirlenen desene göre, 16.02.2009 – 27.03.2009 tarihleri arasında Euro/Dolar paritesinin incelenen 10 yıllık sürecine göre farklı bir davranış sergilediği söylenebilir. Bulunan zaman aralığı 2009 yılında doların en yüksek olduğu dönemi içermektedir. Bu dönemde gerçekleşen ekonomik gelişmeler incelendiğinde, 2008 ekonomik krizi karşısında alınan finansal önlemler kapsamında Amerikan Merkez Bankası'nın (FED) 15 Mart 2009 haftasında beklenmeyen bir kararla 6 ay içinde hükümetten 300 milyar dolara kadar uzun dönemli borç tahvili alma kararı dikkat çekmektedir [20]. Bu karar, dolar fiyatlarındaki düşüşün dolayısıyla da bulunan anomali deseninin sebeplerinden biri olarak yorumlanabilir.

Bu çalışmada kullanılan yöntemler zaman serilerindeki trendi dikkate almamaktadır. Özellikle finansal zaman serilerinde trend görüldüğü için sonraki çalışmalarda, bu algoritmaların trendi dikkate alarak uygulanmaları denenebilir.

7. Kaynaklar

[1] Aggrawal, R., Faloutsos, C., Swami, A., "Efficient similarity search in sequence databases", In: Proceedings of 4th International Conference on Knowledge Discovery and Data Mining, 439:450(1993).

[2] Berndt, D., Clifford, J., "Using dynamic time warping to find patterns in time series", AAAI-94 workshop on knowledge discovery in databases, 359:370(1994).

[3] Chandola, V., Grumbach, A., Kumar, C., "Anomaly Detection: A survey", ACM Computing Surveys, 41(3), Article 15(2009).

[4] Esling, P., Agon, C., "Time-series data mining", ACM Computing Surveys, 45(1), Article 12(2012).

[5] Faloutsos, C., Ranganathan, M., Manolopoulos, Y., "Fast subsequence matching in time-series databases", In: Proceedings of the 1994 ACM SIGMOD International Conference on Management of Data, 417:429(1994).

[6] Fu, T., "A review on time series data mining", Engineering Applications of Artificial Intelligence 24, 164:181(2011).

[7] Jiang, Y., Lan, T., Zhang, D., "A New Representation and Similarity Measure of Time Series on Data Mining", Computational Intelligence and Software Engineering, 1:5(2009).

[8] Keogh, E., "Fast similarity search in the presence of longitudinal scaling in time series databases", In proceedings of the 9th IEEE International Conference on Tools with Artificial Intelligence, 578:584(1997).

[9] Keogh, E., "Indexing and mining time series data", Encyclopedia of GIS, 493:497(2008).

[10] Keogh, E., Chakrabarti, K., Pazzani, M., and Mehrotra, S., "Dimensionality reduction for fast similarity search in large time series databases", Knowledge and Information Systems, 3(3), 263:286(2001).

[11] Keogh, E., Chakrabarti, K., Pazzani, M., "Locally adaptive dimensionality reduction for indexing large time series databases", In Proceedings of the 2001 ACM SIGMOD International Conference on Management of Data, 151:163(2001).

[12] Keogh, E., Chu, S., Hart, D., Pazzani M., "An online algorithm for segmenting time series", Proceedings of the IEEE International Conference on Data Mining, 289:296(2001).

[13] Keogh, E., Lin, J., Lee, S.H., Herle, H.V., "Finding the most unusual time series subsequence: algorithms and applications", Knowledge and Information Systems, 11(1), 1:27(2006).

[14] Li, G., Zhang, L., Yang, L., "TSX: a novel symbolic representation for financial time series", PRICAI 2012: Trends in Artificial Intelligence Lecture Notes in Computer Science, Volume:7458, 262:273(2012).

[15] Lin, J., Keogh, E., Leonardi, S., and Chiu, B., "A symbolic representation of time series, with implications for streaming algorithms", In Proceedings of the 8th ACM SIGMOD Workshop on Research Issues in Data Mining and Knowledge Discovery, 2:11(2003).

[16] Lin, J., Keogh, E., Wei, L., Lonardi, S., “Experiencing SAX: a novel symbolic representation of time series”, *Data Mining and Knowledge Discovery*, 15(2), 107:144(2007).

[17] Ma, J., Perkins, S., “Online novelty detection on temporal sequences”, In *Proceedings of the 9th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 613:618(2003).

[18] Malinowski, S., Guyet, T., Quiniou, R., Tavenard, R., “1d-SAX : a Novel Symbolic Representation for Time Series”, *Advances in Intelligent Data Analysis XII, Lecture Notes in Computer Science*, Volume: 8207, 273:284(2013).

[19] Ratanamahatana, C. A., Lin, J., Gunopulos, D., Keogh, E., “Mining time series data”, *Data Mining and Knowledge Discovery Handbook*, 1069:1103(2005).

[20] Türkiye Bankalar Birliği, Bankacılık ve Araştırma Grubu, “Uluslararası Finansal Kriz Karşısında Ülkeler Tarafından Alınan Önlemler Kronolojisi”, *Bankacılar Dergisi*, 69, 86:93(2009).

[21] Web1, European Central Bank Web Site, <https://www.ecb.europa.eu/stats>, Erişim tarihi:10.12.2014.