

YAPAY SINİR AĞLARI VE DESTEK VEKTÖR MAKİNELERİ İLE DEPREM TAHMİNİNDE SİSMİK DARBELERİN KULLANILMASI

EARTHQUAKE PREDICTION USING SEISMIC BUMPS WITH ARTIFICIAL NEURAL NETWORKS AND SUPPORT VECTOR MACHINES

Enes ÇELİK, Muhammet ATALAY, Harun BAYER

Bilgisayar Programcılığı, Kırklareli Üniversitesi
{enes.celik, atalay, harunbayer}@klu.edu.tr

ÖZETÇE

Yer kabuğunda oluşan kırılmalar sonucu aniden ortaya çıkan titreşimlerin dalgalar halinde yayılarak yer yüzeyini sarsmaya devam etmesiyle depremler oluşur. Deprem oluşumu, bu dalgaların yer kabuğunda yayılım biçimine, bunların ölçülmesine ve ölçüm yöntemlerine, ölçümlerden elde edilen kayıtların değerlendirilmesi gibi birçok değişkene bağlıdır. Olası depremlerin tahmin edilmesi ve zararlarının en aza indirilmesi önemli unsurlardan birisidir. Burada sadece sismik darbe verileri kullanılarak depremin önceden tahmin edilmesi için karar sistemleri oluşturulabilir. Bu noktada sismik darbe verileri önce sınıflandırılacak sonra test aşamasında karşılaşmalıdır sonuçları irdeleneciktir. Çalışmamızda maden ocağından elde edilen hazır sismik darbe verileri kullanılarak sınıflandırma algoritmaları ile sınıflandırmaya tabi tutulur. Sınıflandırmada Yapay Sinir Ağları ve Destek Vektör Makineleri kullanılmıştır. Yapay Sinir Ağları ile sınıflandırma sonucunda %83 oranında erken tespit saptanmıştır. Destek Vektör Makineleri ile yapılan sınıflandırmada %91 oranında erken tespit saptanmıştır.

ABSTRACT

Earthquakes are what happens when immediate vibrations which shake earth surface, spread as waves as a result of earth crust cracks. Earthquakes depend on variables such as the way of spreading of these waves, calculation of these waves and calculating methods, evaluations of these recorded data sets. Predicting probable earthquakes and minimizing the damages are the important factors. Decision systems can be developed only through using seismic bump data. At this point, seismic data will be classified first and then comparative results will be analyzed at the test stage. We use end seismic data obtained from mine pit which are classified through classification algorithms. Artificial Neural Networks and Support Vector Machine are used in the classification. Early detection rate is calculated as 83% with the classification through Artificial Neural Network. Early detection rate is calculated as 91% with the classification through Support Vector Machine.

1. GİRİŞ

Deprem, yer derinliklerinde biriken enerjinin bir anda boşalması sonucu oluşan elastik dalgaların, zemin yüzeyinde meydana getirdiği titreşimlerin hareketleridir. Depremler, çoğunlukla yerkabuğunda ve daha az sayıda üst mantoda

oluşurlar ve büyük faylara bağlı olarak, onlarla birlikte meydana gelirler. Birçok büyük depremin aktif faylara bağlı oldukları saptanmış veya gözlenmiştir. Fay doğrultusunun her iki yanında meydana gelmekte olan elastik deformasyon nedeni ile kayaç kütlesi içinde deformasyon enerjisi birikmektedir. Bu enerji kayaç kütlesinin elastik kırılma direncini aşınca kırılma veya eskiden var olan bir kırık boyunca kayma meydana gelmekte, bu sırada boşalan elastik deformasyon enerjisi sismik dalgalar şeklinde yayılarak depremi oluşturmaktadır. Fay oluşumuna ve dolayısıyla depreme sebep olan enerji, fayın her iki tarafında zamanla toplanan deformasyon enerjisidir. Büyük bir depremde bu enerjinin değeri 10^{24} erg mertebesinde olabilir [1]. Depremler karmaşık olaylar sonucu gelişen jeolojik afetlerdir. Bu nedenle depremlerin davranışlarını doğru şekilde anlamak, onu tahmin etmek, modellemek yüksek bilgi düzeyi ve teknolojik imkân gerektirir. Depremin önceden bilinmesi depremin; zamanın, yerinin ve büyülüğünün kestirilmesi demektir. Bu üç birim, manto ve yer kabuğunun bir parçasının diğer parçasına göre yer değiştirmesinin, ortam içerisindeki gerilim yüklenme hızının ve ortamda kayaçların kırılma dirençlerinin bir değişkenidir. Ne var ki bir bölgedeki erg toplamını ya da boşalımını denetleyen öğe ve işleyiş bilinse bile, başlangıç ve sınır koşullarının ve ortamda yer alan kayaçların özelliklerinin çok iyi bilinmemesi herhangi bir sarsıntıının önceden bilinmesini güçleştirir [2].

Günümüzde depremlerin tahmini konusunda yoğun çalışmalar ve bazı tespitler olmasına rağmen bugüne dekin depremlerin net olarak tam yerini zamanını ve büyülüğünü belirleyeceğ bir teknik geliştirilememiştir. Depremin oluşumundan kısa süre önce tahmin edilebilmesi, can kayıplarını en aza indirilmesi bakımından önemlilik arz eder. Deprem tahmini konusunda birçok veriden yararlanılmaktadır. Bunlar arasında kabuktaki yamulmalar, kayaçlardaki jeokimyasal değişimler, yer altı sularındaki değişimler, su kaynaklarının kuruması veya artıp azalması, manyetik, elektrik, deformasyon değişimleri, bölgedeki fiziksel, kimyasal ve biyolojik olaylarda meydana gelen değişiklikler, canlılardaki davranış değişimleri, kaynak sularındaki radon gazı değişimleri takip edilmesi de sayılabilir [3].

Doğrusal olmayan sistemlerin davranışında başarıyla kullanılabilen yapay sinir ağları, destek vektör makineleri böylesine karmaşık değişimlerin tahmininde başarıyla kullanılmaktadır. Sınıflandırma aşamasında tahmindeki başarıyı artırmak için yardımcı olarak bazı istatistiksel özellikler kullanılmıştır [4].

Literatürde; Nöro-Bulanık sınıflandırıcı bir uygulama ile kaydedilen sismogramların verileri kullanarak kısa-süreli deprem tahmininde doğruluk %82 ile beş dakika önce

depremler tahmin edebilir. Yardımcı olarak istatistiksel, entropi, Ayrık Dalgacık Dönüşümü, Hızlı Fourier Dönüşümü, Chaotic Özellikleri (Maksimum Lyapunov Üssü), Güç Spektral Yoğunluğu kullanılmıştır [5].

DEMETER uydusu ve geri beslemeli Yapay Sinir Ağı kullanılmıştır. Bu çalışmada sismik bant bilgi elektron yoğunluğu, elektron sıcaklığı, iyon sıcaklığı ve oksijen iyon yoğunluğu da dahil olmak üzere DEMETER uydusu tarafından ölçülen fizikal büyüklüklerin bir dizi geri yayılım sinir ağı için örnek setleri oluşturmak için kullanılır. Sinir ağı modeli daha sonra tahmini yapmak için de kullanılmıştır [6].

ANFIS yerine GONFIS (Genetik optimizasyon neural network inference system) önerilmiştir [7].

Chebyshev polinom çekirdeği unified adlı yeni bir çekirdek, Sistemik Vasküler Rezistans için önerilmiştir. Simülasyon sonuçları Chebyshev polinom çekirdeği birçok kriter veri setleri üzerinde diğer ortak çekirdekler ile karşılaştırıldığında daha iyi genellemeye performansı göstermiştir [8].

Veri noktalarının hareket kalıplarını deprem tahmininde Geriye Yayımlı Sinir Ağı yöntemi ile analiz ederek sismik veri hareket modeli ile formül bulmaya çalışmışlar [9].

Radyal temel fonksiyonu yapay sinir ağı modellerine dayanan deprem oluşumu tahmini için yeni bir öneri sunar. Yapay sinir ağı leave-one-out eğitim prosedürü dahil etmek üzere modifiye edilen güçlü bulanık aracı ile gerçekleştirilir. Buna ek olarak, önerilen eğitim algoritması veri işleme için veri setinden artçı depremleri kaldırma için kullanılan Reasenberg kümeleme teknigi ile birleştirilmiştir [10].

2. MATERİYAL ve YÖNTEM

Madencilik faaliyetleri genelde tehlikeli durumların ortaya çıkmasına sebep olur. Sismik tehlikeler zor saptanabilir ve bu açıdan bir deprem ile karşılaşılabilir. Sismik süreçler ve düşük enerjili sismik olayların sayısı ve yüksek enerjili olayların sayısı arasında büyük bir orantısızlık karmaşıklığı oluşturur. Bu durumda sismik tehlikelerin tahmin edilmesinde yetersiz kalır. Bu nedenle, makine öğrenmesi yöntemleri kullanılarak daha iyi tehlike tahmini aranabilir. [11].

Hazır veri seti kümelerindeki her bir vardiya (8 saat) içinde kaya kütlesi sismik aktivitesi hakkında bilgi içerir. Karar nitelik değeri yüksek olan bir enerji ile daha sonraki vardiyyada herhangi bir sismik darbe varsa kaydedilir. Tehlikeli tahminlerde kaydedilen titreşimli enerji ve sismo akustik faaliyet ile ilişkilidir. Artan sismik aktivite büyük bir öneme sahiptir [12].

Kaliforniya Üniversitesi Enformasyon ve Bilgisayar bilimleri bölümde online Sismik Darbe veri seti kullanılmıştır. Sismik darbe veri setleri Polonya'daki bir kömür madeninden elde edilmiştir. 2584 adet veri bulunur. Buların 170 adedi tehlikeli durum, 2414 adedi tehlikesiz durum içindir [13].

Her saturday, vardiya sonundaki sismik durum, sismo akustik durum, vardiya türü, jeofonlar üzerinde kaydedilen sismik enerji, önceki vardiyyadan jeofonlar üzerinden kaydedilen darbe sayısı, sekiz önceki vardiyyada kaydedilen ortalama enerji, sekiz önceki vardiyyada kaydedilen ortalama darbe, sismo akustik yöntem ile vardiya sonucu, önceki vardiya içinde kaydedilen darbe sayısı, önceki vardiya içinde kayıtlı sismik darbe sayısı enerji aralıkları, önceki vardiyyadaki toplam sismik enerji, önceki vardiyyadaki sismik darbe maksimum enerjisi, karar sınıfı (tehlikeli, tehlikesiz) ölçüm sonuçları kullanılmıştır [14].

2.1. Yapay Sinir Ağları

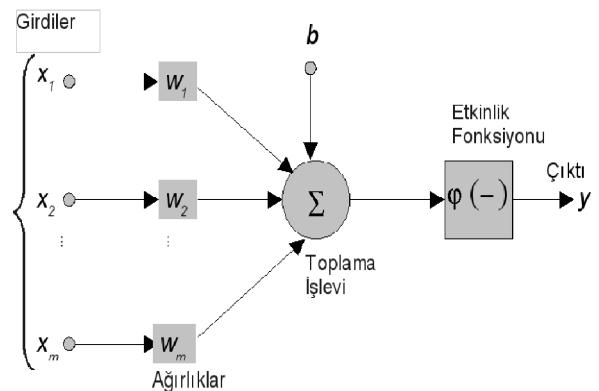
Yapay sinir ağları, biyolojik sinir sisteminin simülasyonu olarak ortaya çıkmıştır. Bir bilgisayarın çalışma şekli beyin çalışmasına benzetilerek yapay sinir ağları modeli geliştirilmiştir. Yapay sinir ağları algoritmalarında öğrenme, daha önce edinilen tecrübelere bağlıdır. Bir sistemin özelliklerinin çıkarıldıkten sonra sistemin çözümüne dayalı bir algoritma olmasa veya karmaşık bir çözüm algoritması olsa da, yapay sinir ağları bu sisteme uygulanabilir. Yapay sinir ağları nöronlardan oluşmaktadır. Bu nöronlar gerçek sinir sistemindeki gibi bir birlerine çok karmaşık bir şekilde dahil bağlanabilmektedirler. Her bir nöronun farklı ağırlıkta girişleri ve bir tane çıkışı bulunmaktadır. Bu amaçla farklı ağırlıktaki girişlerin toplamı şu şekilde ifade edilir [15].

$$n = \sum_{i=1}^P W_i X_i + b \quad (1)$$

Burada P giriş sayısı, w giriş ağırlığı, x giriş, b bias ve neural network'ün değeridir. Ağırlıklandırılmış girişler ve her nöronun biasıyla beraber toplamları, aktivasyon fonksiyonundan geçirilir ve bunun sonucunda o nörona bağlı çıkış elde edilir. Aktivasyon fonksiyonunu " f " ile gösterirsek:

$$f(n) = f\left(\sum_{i=1}^P W_i X_i + b\right) \quad (2)$$

Şeklinde ifade edilir. Aktivasyon fonksiyonu (etkinlik fonksiyonu, ϕ) sistemin yapısına uygun olarak sigmoid fonksiyonu, eşik fonksiyonu veya hiperbolik tanjant fonksiyonu olabilir. Çıkış elde edildikten sonra eğer sistem çok katmanlıysa, bir nöronun çıkışı (y) diğer bir nöronun girişi (x) olabilir. Bu şekilde çok katmanlı bir yapay sinir ağı modeli oluşturulur [16].



Şekil 1: Yapay Sinir Ağı Genel Yapısı [17]

Yapay sinir ağları modeli genelde üç kısımdan oluşur: giriş katmanı, saklı katman ve çıkış katmanı. Her katman çok fazla nöronundan oluşabilir. Bilgi giriş katmanından yapıldıktan sonra aktivasyon fonksiyonlarından geçer. Giriş katmanın çıkışları saklı katmanın girişleri olarak devam eder. Bu aşamadan sonra sonuç katmanında son bir defa daha aktivasyon fonksiyonları saklı katman çıkışlarını değerlendirerek nihai çıkış elde edilir. Yapay sinir ağlarında öğrenmenin ilk adımı aktivasyon olarak

nitelendirilebilir. Sinir hücresına giren sinyallerin toplamı o hücreyi aktif hale getirebilecek bir değere sahip olup olmamasına göre çıkış değeri değişmektedir. Eğer toplam sinyal hücreyi ateşleyebilecek, eşik değerini atlatabilecek kadar yüksek ise o hücre aktiftir, aksi durumda ise o hücre pasiftir. Sinir hücresinin aktif veya pasif durumda olmasına göre sınıflandırma yapıp yapamadığı sonucuna ulaşmaktadır. Örneğin, girdi örüntülerine 1 ya da 0 cevabını vererek sınıflandırma yapabilen bir yapay sinir ağının, örüntüye 1 veya 0 değerini atayarak karar vermiş sayılmaktadır. "Karar vermek" ve "sınıflandırmak", öğrenme sürecinin temel yapıtaşlarını oluşturmaktadır [18].

2.2. Destek Vektör Makineleri

Çalışmamızda yanlış sınıflandırma riskini minimize etmek amacıyla ikinci olarak Destek Vektör Makineleri ile sınıflandırma yöntemini denedik. Tek sınıf Destek Vektör Makineleri durumunda veri öncelikle uygun bir çekirdek fonksiyon kullanılarak öznitelik uzayına taşınır ve daha sonra bir hiperdüzlem vasıtasyyla iki sınıf birbirinden ayrılır. Bu hiperdüzlem parametreleri normal Destek Vektör Makinelerindekine benzer bir kuadratik problemin çözülmesi ile elde edilir [19].

Çalışmamızda tehlikeli durum koşulları etiketi +1, tehlikesiz durum koşulları etiketi -1 ile gösterilmiştir. Test kümelerindeki veriler için karar çıktıları şu şekilde hesaplanmaktadır.

$$\min \left(\frac{1}{2} \|w\|^2 + \frac{1}{v_l} \sum_{i=1}^l \xi_i - p \right) \quad (3)$$

$$(w\phi(x_i)) \geq p - \xi_i = 1, 2, \dots, l, \xi_i \geq 0 \quad (4)$$

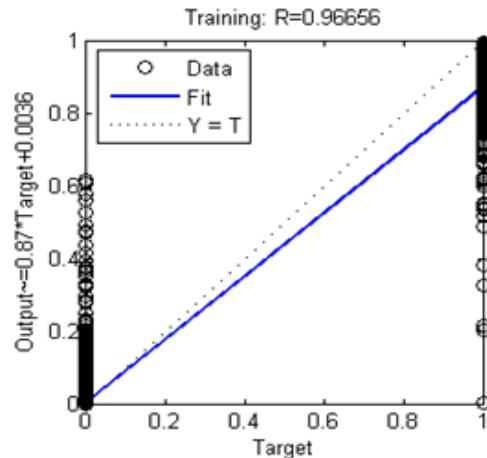
$$f(x) = \text{sgn}(w\phi_x - p) \quad (5)$$

Burada w ve p hiperdüzlem parametreleri, ϕ çekirdek fonksiyon, x giriş parametresi, v yanlış sınıflandırılan değerlerin (outlier) izin verilen oranı, l eğitim kümelerindeki nesnelerin sayısı ve ξ ise hata parametresidir [19].

3. DENEYSEL ÇALIŞMALAR

Kaliforniya Üniversitesi Enformasyon ve Bilgisayar bilimleri bölümdeki online Sismik Darbe veri seti kullanılmıştır. 2584 adet veri bulunur. Buların 170 adedi tehlikeli durum, 2414 adedi tehlikesiz durum içindir. Rasgele seçilen 1808 adet veri Yapay Sinir Ağında eğitim aşamasında, 776 adet veri ise test aşamasında kullanılmıştır. Her satırındaki 19 adet öznitelikten; 19. olanı sınıf belirttiği için (tehlikeli-tehlikesiz) Yapay Sinir Ağı giriş olarak değil de Yapay Sinir Ağı hedefi olarak girilmiştir. İlk olarak özniteliklerimizi gizli katmanında 20 nöron yer alan İleri Beslemeli Geri Yayımlı Yapay Sinir Ağı ile sınıflandırılmıştır. Çıkışında tehlikeli ve tehlikesiz şeklinde sonuç aldığımız bu Yapay Sinir Ağı Şekil 2'de %96 başarıyla eğitim oranını tamamlamıştır. Yapay Sinir Ağı parametreleri Transfer fonksiyonu: Tansig, Purelin, Öğrenme oranı: 0.6 Max epochs: 500 Hedef hata: 1e-7 Eğitim algoritması: LM.

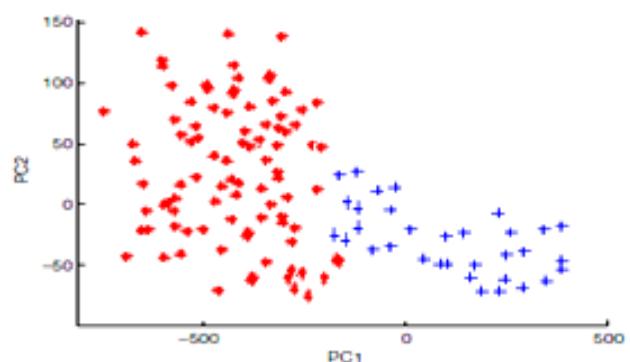
Eğitim ve test için seçilen değerler rastgele olduğu için sonuç her seferinde farklı ama Şekil 2'deki sonuca benzer çıkmaktadır.



Şekil 2: Yapay Sinir Ağı ile Eğitim Sonucu

Uygulamanın son adımı yapay sinirinin test edilmesi aşamasıdır. Burada kullanıcı isterse önce eğitim verisinde kullanmış olduğu verileri seçerek ağını doğru öğrenip öğrenmediğini doğrulayabilir. isterse eğitim esnasında göstermediği verileri seçip ağdan tanımmasını isteyebilir. Yeni ölçüm sonuçlarına da uygulanarak tahmin yapması istenebilir. Test sonuçlarında %17 hata ile %83 oranında başarılı tahmin gerçekleştirilmiştir.

Başarım oranını artırmak amacıyla farklı bir sınıflandırma yöntemi olarak Destek Vektör Makineleri kullanılmıştır. Ölçüm sonuçlarının fazla olması sebebiyle veri setinin boyutlarını azaltmak için temel bileşenler analizi kullanılmıştır. Dönüşüm sonucunda elde edilen değişkenler ilk değişkenlerin temel bileşenleri olarak adlandırılır. Çalışmamızdaki her bir ölçüm değerleri için temel bileşenler analizi uygulanarak öznitelik sayısı en aza indirgenir. Bu öznitelikler Destek Vektör Makineleri ile sınıflandırılır. Elde ettiğimiz sınıflandırmada %93'lük tanımlama ile başarım ölçülmüştür. Erken tespitin önemli olduğu tehlikeli durumlarda %91 doğrulukla tespit odaklı bir sonuç karşımıza çıkmaktadır. Destek vektör makineleri için elde edilen özniteliklerin dağılımı Şekil 3'te verilmiştir.



Şekil 3: Destek Vektör Makineleri ile Özniteliklerin Dağılımı

4. SONUÇLAR

Deprem oluşumu, dalgaların yer kabuğuında yayılım biçimine, bunların ölçülmesine ve ölçüm yöntemlerine, ölçümlerden elde edilen kayıtların değerlendirilmesi gibi birçok değişkene bağlıdır. Bu verilerin toplanmasının zorluğu da ayrıca çalışmanın genel uygulanabilirliğini kısıtlamaktadır. Burada sadece sismik darbe verileri kullanılarak depremin önceden tahmin edilmesi için karar sistemleri oluşturulmuştur. Kömür madeninden alınan sismik darbe verileri kullanılarak sınıflandırma algoritmaları ile sınıflandırmaya tabi tutulur. Yapay Sinir Ağları ile erken tespitte %83 oranında başarı saptanmıştır. Destek Vektör Makineleri ile erken tespitte %91 oranında erken tespit saptanmıştır. Hata paylarının yüksek çıkışında; başka veri setleri ile karşılaşmalar yapılamaması ve tehlikeli durum verilerinin az olması sebep olmuştur. Tahminlerin daha güvenilir ve kararlı olması için toprak yapısını da içine alan sistemler oluşturulabilir. Bunların yanında zaman ve yer tahmini de yapılarak yüksek başarılı sonuçlar için sistem geliştirilebilir.

KAYNAKÇA

- [1] Ketin, İ., *Genel Jeoloji Yer Bilimlerine Giriş*, İTÜ Vakfı, Ankara, 2005.
- [2] Ercan, A., *Deprem Olacağı Nasıl Bilinir*, TMMOB Jeofizik Mühendisleri Odası, Kozan Ofset, Ankara, 2001.
- [3] Karaman, E., *Yapısal Jeoloji ve Uygulamaları*, Ankara, 2006.
- [4] İstanbullu M., Aydin M., Benveniste R., Uçan O.N., Jennane R., "Yapay Sinir Ağları ve Destek Vektör Makineleri Kullanarak Kemik Erimesi Hastalığının Erken Teşhis", *20. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, Muğla, 2012.
- [5] Dehbozorgi, L., Farokhi, F., "Effective Feature Selection for Short-term Earthquake Prediction Using Neuro-Fuzzy Classifier", *II. International Conference on Geoscience and Remote Sensing, IEEE*, 2010.
- [6] Xu, F., Song, X., Wang, X., Su, J., "Neural Network Model for Earthquake Prediction using DEMETER Data and Seismic Belt Information", *II. WRI Global Congress on Intelligent Systems IEEE*, 2010.
- [7] B. Mehrkian, A. Bahar, A. Chaibakhsh., "Genetic-optimized neuro-fuzzy inference system (GONFIS) in nonlinear system identification", *IEEE, International Conference on Control System, Computing and Engineering*, 2011.
- [8] Zhao, J.W., Feng, B.Q., Yan, G.R., Mao, W.T., Zhang, I.S., The unified chebyshev polynomial kernel function for support vector regression machine.
- [9] Veri, J., Wah, T.Y., "Earthquake Prediction Based on the Pattern of Points Seismic Motion", *International Conference on Advanced Computer Science Applications and Technologies*, 2012.
- [10] Alexandridis, A., Chondrodima, E., Efthimiou, E., Papadakis, G., Vallianatos, F., Triantis, D., "Large Earthquake Occurrence Estimation Based on Radial Basis Function Neural Networks", *IEEE Transactions on geoscience and remote sensing*, 2013.
- [11] Kabiesz, J., "Effect of the form of data on the quality of mine tremors hazard forecasting using neural networks", *Geotechnical and Geological Engineering*, 2005.
- [12] Bukowska M., *The probability of rockburst occurrence in the Upper Silesian Coal Basin area dependent on natural mining conditions*, Journal of Mining Sciences, Vol 42, 2006.
- [13] Sikora M., Wrobel L., *Application of rule induction algorithms for analysis of data collected by seismic hazard monitoring systems in coal mines*, Archives of Mining Sciences, Vol 55, 2010.
- [14] Sikora M., Wrobel L., UCI Machine Learning Repository, Irvine, CA: University of California, School of Information and Computer Science, 2013.
- [15] Haykin, S., *Neural networks a comprehensive foundation*, 1994.
- [16] Ertunç, H.M., Ocak, H., Aliustaoglu, C., "ANN and ANFIS based multi-staged decision algorithm for the detection and diagnosis of bearing faults", *Neural Comput and Application*, 2012.
- [17] Uğur A., KINACI A.C., "Yapay Zeka Teknikleri ve Yapay Sinir Ağları Kullanılarak Web Sayfalarının Sınıflandırılması", *11. Internet Konferansları*, 2006.
- [18] Fausett L., "Fundamentals Of Neural Networks", 1994.
- [19] Gardner A.B., Krieger A.M., Vachtsevanos G., Litt B., "One-Class Novelty Detection for Seizure Analysis from Intracranial EEG", *Journal of Machine Learning Research*, vol. 7, 2006.