

## Esnek Geri Yayılımlı ve Geliştirilmiş Geri Yayılımlı Sinir Ağları Performanslarının Elektrikli Ark Ocaklarında Karşılaştırılması

Edip YILDIZ<sup>1\*</sup>, Ersin ÖZDEMİR<sup>2</sup>

<sup>1</sup>Elektrik-Elektronik Mühendisliği Bölümü, İskenderun Teknik Üniversitesi, Hatay, Türkiye

<sup>2</sup>Elektrik-Elektronik Mühendisliği Bölümü, İskenderun Teknik Üniversitesi, Hatay, Türkiye  
(\*edipyildiz186@hotmail.com)

**Özet** – Elektrikli ark ocakları, sıvı çelik üretimindeki süreçlerinin esnekliğinden, yatırım ve işletme maliyetlerinin diğer üretim ekipmanlarına göre daha düşük olması sebebi ile sıvı çelik üretiminde tercih edilmektedirler. Alternatif akımlı elektrikli ark ocaklarının çalışma prensibi, karbon elektrotlarının kontrol edilmesi ile elektrik akımını hurda üzerinden geçirerek ergitme esasına dayanır. Doğrusal olmayan, dinamik, birden fazla parametreye bağlı, karmaşık karakteristikte sisteme sahiptirler. Elektrikli ark ocağının rastlantı sonucu olmayan akım-gerilim dalgalanmalarını ve değişken parametrelerini, çalışma şekli ve operatörlerin sezgisel kullanımı daha da karmaşıktır. Buna benzer karmaşık sistemlerin kontrolü doğrusal olan sistemlere göre daha zordur. Elektrikli ark ocaklarında verimi ve güç transferini gerçekleştiren elektrotların hareket kontrolü de bu nedenle önemlidir. Bu çalışmada çok katmanlı ağ yapısına sahip olan ve esnek geri yayılım algoritmasına (RPROP) sahip yapay sinir ağı ile daha önceki çalışmalarda etkinliği ispatlanmış olan geliştirilmiş geri yayılım algoritması (BP) performansları karşılaştırılmıştır. Kararsız sistemler açısından her iki yöntemin başarılı sonuçlar gösterdiği görülmüş fakat aynı veri seti ile yapılan denemelerde esnek geri yayılım algoritmasının daha hızlı ve daha düşük hata ile öğrendiği tespit edilmiştir. Çalışma, Knime açık kaynak kodlu veri analizi aracı ile yapay sinir ağları kullanılarak gerçekleştirilmiş ve sonuçlar değerlendirilmiştir.

**Anahtar Kelimeler** – Elektrikli ark ocağı, Yapay sinir ağı, Geri yayılım, Esnek yayılım

**Abstract** – Electric arc furnaces are preferred for the production of liquid steel because of the flexibility of the processes in the production of liquid steel, investment and operating costs are lower than other production equipment. The principle of operation of electric arc furnaces with alternating current is based on melting the electric current through scrap by controlling the carbon electrodes. Nonlinear, dynamic, have more than one parameter, have a complex characteristic system. The current-voltage fluctuations and variable parameters of the electric arc furnace, as well as the operation mode and the intuitive operation of the operators, further complicate. Control of similar complex systems is more difficult than linear systems. It is therefore important to control the motion of the electrodes that perform efficiency and power transfer in electric arc furnaces. In this study, an artificial neural network with a multilayered network structure and a resilient back propagation algorithm (RPROP), as well as improved back propagation algorithm (BP) performances, which have proven effective in previous studies, were compared. Both methods have been found to be successful in terms of unstable systems, but it has been determined that resilient back propagation algorithm is learned with faster and lower error in the experiments with the same data set. The study was performed using Knime open source data analysis tool and artificial neural networks and the results were evaluated.

**Keywords** – Electrical arc furnace, Artificial neural network, Back propagation, Resilient propagation

### I. GİRİŞ

Elektrikli ark ocakları sıvı çelik üretiminde ve çelik üretimi sırasında kullanılmış olduğu elektrik enerjisi bakımından önemli bir yer tutmaktadır. Ayrıca elektrikli ark ocağının akım ve gerilim dengesinin düzensiz oluşu ise klasik algoritmalar ile modellenmesini oldukça zor hale getirmektedir. Bu sebeple elektrot pozisyon ve konum kontrolünün daha etkin bir şekilde yapılması sağlanarak gücün verimli ve kararlı olarak kullanımı için bu çalışmada olduğu gibi daha önce bir çok farklı çalışmalar yapılmıştır.

Staib W. ve Staib R. tarafından yapılan çalışmalarda 80 tonluk elektrikli ark ocağında yapay sinir ağı kontrol sisteminin elektrot konumu ve fırın operasyonunun kararlılığı arasındaki ilişkileri tahmin etmeyi öğrenebileceğini göstermişlerdir. Bu sayede fırın içerisinde değişken koşullardaki operasyonlara gerçek zamanlı adaptasyonun,

elektrot aşınmasını, fırın aşınmasını ve güç tüketimini azalttığını savunmuşlardır. Yapay Sinir Ağı kontrolünün sonucu, fırın başına yılda milyonlarca dolar tasarruf sağlayacağı yapılan test ve denemeler ile doğrulanmıştır [1].

Hong, Sheng ve Li bulanık sinir ağına dayalı AC (Alternatif Akım) elektrik ark ocağı kontrol sistemini geliştirmişlerdir. Pratik çalışma sonuçları, bu sistemin yüksek kontrol hassasiyetine ve iyi güvenilirliğe sahip olduğunu, elektrotların aşağı yukarı hareket hızını ve pozisyon hassasiyetini artırıp elektrotların yumuşak bir şekilde regülasyonu sağladığını, üç faz için akım dengesini sağladığını ve EAF sıcaklığının kararlılığını göstermektedir [2].

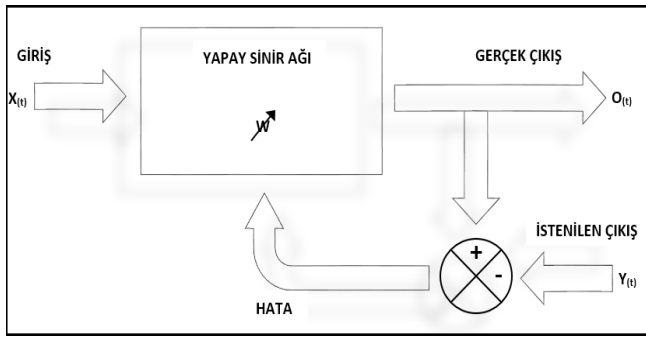
Zhang ve Zheng, elektrik ark ocağının elektrot sisteminde RBF ters kimliklendirme tabanlı çift model kontrol uygulamasını gerçekleştirmişler ve Ma'anshan demir çelik fabrikasında başarı ile uygulanmıştır [3].

Hui ve Wang geliştirilmiş BP (Back Propagation) sinir ağı ile elektrik ark fırını akım tahmin modelini Matlab ile test edip sonuç olarak elektrotların etkili bir şekilde kontrol edildiğini göstermişlerdir [4].

Bu çalışma ile demir çelik sektörü içerisinde önemli yer tutan elektrikli ark ocaklı hurda ergitme tesisinde bulunan ekipmanlarda daha kararlı şartların sağlanması ve daha etkin elektrot kontrolünün yapılabilmesi amacıyla daha önce performansını test edilmiş olan geliştirilmiş Geri Yayılım algoritması (BP) ile Esnek Geri Yayılım (RPROP) algoritmalarına sahip çok katmanlı yapay sinir ağlarının aynı veri setleri ile eğitilmesi, test edilmesi ve sonuçlarının karşılaştırılarak yapay sinir ağlarının elektrot kontrol sistemi tahmin özellikleri üzerinde durulmuştur.

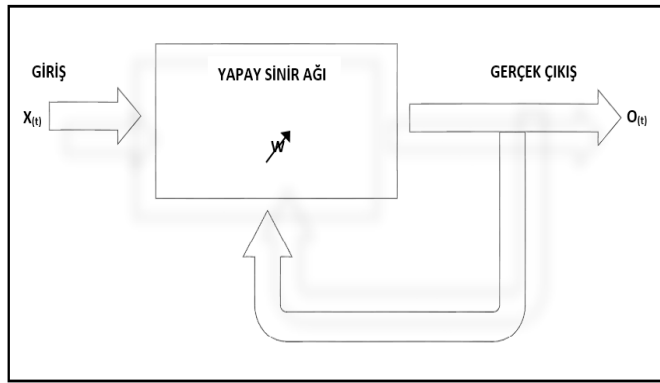
## II. SİNİR AĞI YAPISI VE ÖĞRENME ALGORİTMALARI

Literatürde iki tip öğrenme stratejisinden bahsedilmektedir. İki sınıf arasındaki temel farklılık istenen çıkış değerinin mevcut olup olmamasıdır.



Şekil 1. Öğreticili (Danışmanlı) öğrenme

Eğer bir eğitici, sistem çıkışlarının istenen değerini temin ediyorsa bu tip öğrenme Şekil 1’de gösterilen akış şeması ile tanımlanabilir. Bu sınıftaki öğrenmede, ağa örnek olarak setten bir çıkış verilir. İstenilen değer ile ağ çıktısı arasındaki hataya göre katmanlar arası ağırlık bilgileri istenilen çıkışa uygun olacak şekilde yeniden düzenlenerek güncellenir. Bu sınıftaki algoritmalarda ağın danışmana veya öğretmene ihtiyaç duymasının nedeni de budur. BP (Back Propagation) algoritması, delta kuralı danışmanlı öğrenmeye örnek olarak gösterilebilir.



Şekil 2. Öğreticisiz (Danışmansız) öğrenme

Şekil 2’de akış şeması verilen öğreticisiz öğrenme algoritmaları daha çok, sistemin geçmişte karşı karşıya kaldığı veri kümesinin içerdiği istatistiksel bilgilerin çıkarımını amaçlar. Böylelikle çok elemanlı veri kümeleri içerisinde deneyim yoluyla bilgi genelleştirmeleri yapılabilir [5].

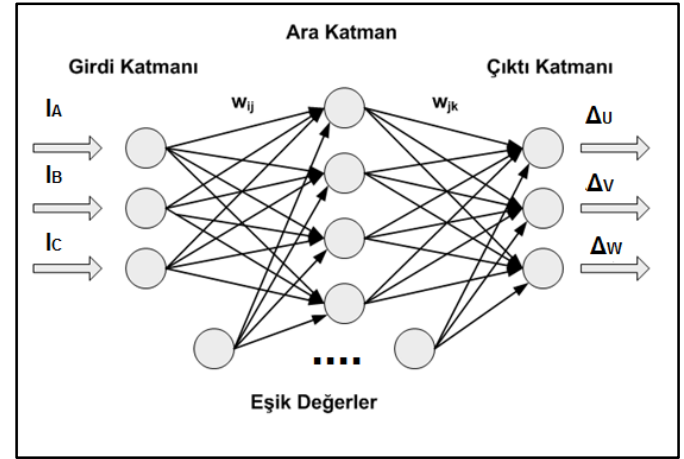
### A. Esnek Yayılım Ve Geri Yayılım Algoritmaları

Geril yayılım algoritmasının katmanlar arası ağırlıkları güncelleyerek ağ çıktısındaki hatayı ağ işlemcileri üzerine dağıtması, uzun iterasyona ihtiyaç duymalarına neden olmakla beraber uygulanacak probleme özgü olan öğrenme ve momentum katsayıları gibi parametre güncellemelerine ihtiyaç duymaktadırlar [6].

Esnek yayılım algoritmasında öğrenme ve uyarılma sadece kısmi türevlerin işaretinden etkilendiği için kısmi türevlerin olumsuz etkilerini öğrenme sürecinden uzaklaştırmıştır. Ön parametre ayarı gerektirmeyip öğrenme ağ üzerinden eşit olarak yayılır ve hızlı bir şekilde gerçekleşir [6-7].

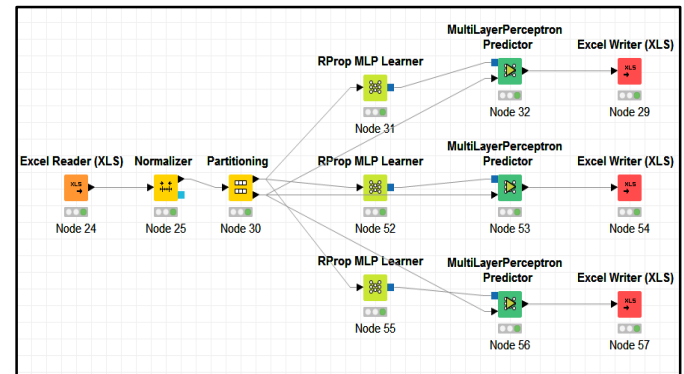
### B. Sinir Ağı Mimarisi

Çalışmada Şekil 3’te görülen Çok Katmanlı Ağ mimarisi seçilmiş olup Esnek Yayılım (RPROP) öğrenme algoritması kullanılmıştır. Figures and tables must be centered in the column. Large figures and tables may span across both columns. Any table or figure that takes up more than 1 column width must be positioned either at the top or at the bottom of the page.



Şekil 3. Çok katmanlı ağ mimarisi şematik gösterimi

Girdi katmanında bulunan IA, IB, IC, ark ocağı faz akımları bilgisi olup  $\Delta U$ ,  $\Delta V$ ,  $\Delta W$ , ark oluşturan elektrotların konum bilgileridir. Knime programı ağ mimarisi ise Şekil 4’te görülebilmektedir.



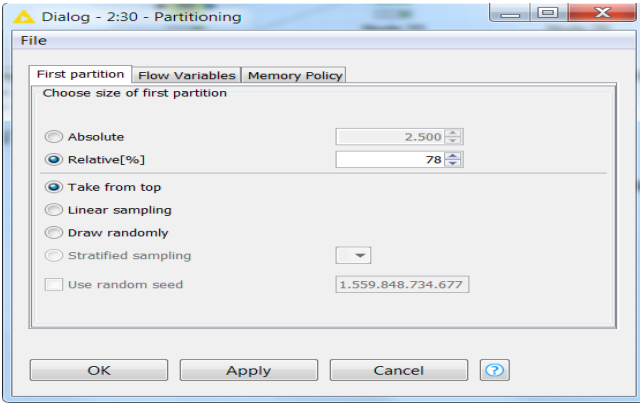
Şekil 4. Knime ile yapay sinir ağı mimarisi ile veri işleme nesneleri

Sinir ağına gösterilen üç faz akım ve buna karşılık gelen elektrot konum değişimi bilgileri ise Şekil 5’te görülebilmektedir.

Number	I <sub>A</sub>	I <sub>B</sub>	I <sub>C</sub>	$\Delta U$	$\Delta V$	$\Delta W$
1	10816,15	27234,71	26512,07	3,5001	3,0165	3,4981
2	28312,11	38463,32	32265,66	3,2443	3,2095	3,2435
3	21080,04	25195,57	25751,74	3,4629	3,2325	3,3355
4	21659,9	32322,96	28421,7	3,3062	3,1882	3,3443
5	19417,79	23073,75	27781,86	3,4015	3,316	3,4457
6	32774,22	17575,68	24772,22	3,6176	3,1392	3,6524
7	16762,33	37956,16	40035,25	3,2107	3,5698	3,1478
8	23824,56	23073,87	25614,35	3,1024	3,4571	3,2569
9	39173,65	22135,25	29654,32	3,5663	3,2561	3,1444
10	10026,35	29817,87	32654,25	3,2104	3,9535	3,2556
11	30080,55	29712,43	21000,75	3,5896	3,2108	3,5462
12	25609,55	32556,2	25647,35	3,1457	3,0258	3,2547
13	20498,72	32106,7	35642,25	3,2546	3,1453	3,3651
14	19756,28	27435,92	32625,45	3,1235	3,2569	3,7856
15	36215,46	27564,04	26704,35	3,2564	3,5472	3,4521

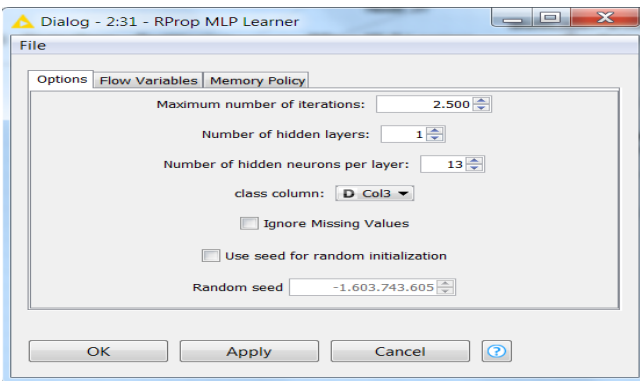
Şekil 5. Sinir ağını eğitime ve test etme işleminde kullanılan veri seti

Sinir ağı, 3 giriş, 3 çıkış ve 13 adet nörondan oluşturulan 1 ara katman olmak üzere üç katmandan oluşmaktadır. Daha önce yapılan çalışma ile aynı şartları sağlaması açısından ara katman 13 nörondan oluşmuştur [4]. Şekil 6'da görüldüğü gibi toplam veri setinin %78'ine denk gelen 11 adet veri seti ağı eğitime işleminde kullanılmış olup geriye kalan 4 veri seti performans testinde kullanılmıştır.



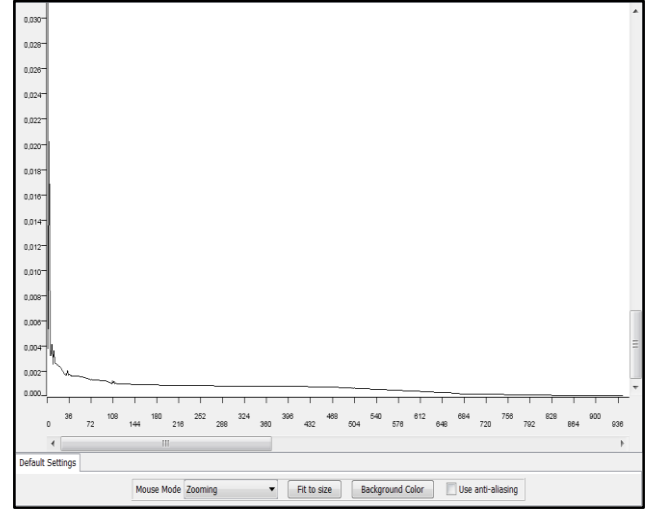
Şekil 6. Veri seti ön ayarı

Çok katmanlı ve esnek yayılım algoritmaya sahip ağı maksimum iterasyon sayısı 2500 olarak ayarlandı.



Şekil 7. RPROP Sinir ağı dizayn parametreleri

Esnek yayılım algoritmaya sahip yapay sinir ağı eğitimi Şekil 8'de görüldüğü gibi 794 iterasyon sonunda tamamlanmıştır.



Şekil 8. Hata karelerinin ortalamasının karekökü (RMSE) grafiği

### III. SONUÇLAR

Yapılan araştırmalar göz önünde bulundurulduğunda artan ihtiyaca cevap verebilmek adına sürekli artış gösteren elektrikli ark ocaklarında yapay sinir ağlarının bir çok farklı mimarisi ile farklı öğrenme algoritmaları çalışılmış olup genelde olumlu sonuçlar alınmıştır.

Bu çalışmada RPROP öğrenme algoritması ile tasarlanan ve geliştirilmiş BP algoritmasına sahip ağı ile aynı mimari tasarıma sahip olan yapay sinir ağına 1688 iterasyon önce eğitimi tamamladığı görülmüştür. RPROP ile tasarlanan sinir ağı, eğitimi yaklaşık %68 daha erken tamamlamasına rağmen geliştirilmiş geri yayılım kullanılan ağda, aynı veri seti ile yapılan performans testinde karşılaştırmalı hata çıktıları Şekil 9'da görüldüğü gibi beklen değere çok daha yakın sonuçlar üretmiştir. Genel olarak bakıldığında RPROP algoritmasının elektrikli ark ocaklarında elektrot optimizasyonunda hızlı ve verimli sonuçlar elde edilebileceği görülmüştür.



- [7] M. Ingvarsson, "The RPROP algorithm." [Online]. Available: [http://130.243.105.49/~lilien/ml/seminars/2007\\_03\\_12c-Markus\\_Ingvarsson-RPROP.pdf](http://130.243.105.49/~lilien/ml/seminars/2007_03_12c-Markus_Ingvarsson-RPROP.pdf). [Accessed: 05-Feb-2019].

Şekil 9. RPROP – Geliştirilmiş BP sonuçlarının karşılaştırılması

## KAYNAKLAR

- [1] W. E. Staib and R. B. Staib, "The intelligent arc furnace controller: a neural network electrode position optimization system for the electric arc furnace," *Neural Networks, 1992. IJCNN., Int. Jt. Conf.*, vol. 3, pp. 1–9, 1992.
- [2] Z. Hong, Y. Sheng, and J. Li, "Development of AC Electric Arc-Furnace Control System Based on Fuzzy Neural Network," pp. 2459–2464, 2006.
- [3] S. Zhang and X. Zheng, "Application of double model control scheme based on RBF inverse identification in electrode system of electrical arc furnace," *Proc. IEEE Int. Conf. Autom. Logist. ICAL 2007*, no. 5, pp. 485–489, 2007.
- [4] Z. Hui, X. Wang, and X. Wang, "Prediction Model of Arc Furnace Based on Improved BP Neural Network," *2009 Int. Conf. Environ. Sci. Inf. Appl. Technol.*, vol. 2, no. 2, pp. 664–669, 2009.
- [5] Ç. Elmas, *Yapay Zeka Uygulamaları*, 1st ed. Ankara: Seçkin Yayıncılık, 2007.
- [6] M. Riedmiller and H. Braun, "A direct adaptive method for faster backpropagation learning: The RPROP algorithm," *IEEE Int. Conf. Neural Networks - Conf. Proc.*, vol. 1993–Janua, pp. 586–591, 1993.