



# Yapay Sinir Ağları ile Sıvı Ham Demir Tahmini ve 5.Yüksek Fırın Uygulaması

Caner Özcan<sup>1\*</sup>, Ertan Yavuz Köprü<sup>2</sup>

<sup>1</sup> Karabük Üniversitesi, Karabük, Türkiye (ORCID: 0000-0002-2854-4005)

<sup>2</sup> Karabük Üniversitesi, Karabük, Türkiye (ORCID: 0000-0002-8453-0011)

(International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT) 2020 – 22-24 Ekim 2020)

(DOI: 10.31590/ejosat.820018)

**ATIF/REFERENCE:** Özcan, C. & Köprü, E. Y. (2020). Yapay Sinir Ağları ile Sıvı Ham Demir Tahmini ve 5.Yüksek Fırın Uygulaması. *Avrupa Bilim ve Teknoloji Dergisi*, (Özel Sayı), 155-162.

## Öz

Demir cevherinden sıvı ham demir üretimi, yüksek fırın işletmesinde gerçekleşmektedir. Bu süreç, uzun ve karmaşık bir yapıya sahiptir. Bir dökümün tamamlanması, yüksek fırının üretim kapasitesine bağlı olarak, 6-8 saat sürmektedir. Bu çalışmada entegre demir-çelik fabrikasının yüksek fırınlarına ait hammadde verileri kullanılıp üretilen sıvı ham demir miktarı, yapay sinir ağları vasıtasıyla tahmin edilmesi amaçlanmıştır. Bu çalışmada yüksek fırının çalışma biçimi incelenerek giriş ve çıkış parametreleri belirlenmiştir. 2016 ve 2019 yıllarına ait 1000 adet üretim verisinin %70'i eğitim, geriye kalan %30'u test verisi olarak ayrılmıştır. Veriler ilk adımda normalize edilerek yapay sinir ağı için kullanılabilir duruma getirilmiştir. Test sürecinin ardından elde edilen sonuçlar, denormalize edilmiştir. Diğer taraftan yüksek fırının üretim yapmadığı zaman dilimleri veri setinden çıkarılmıştır. Yapay sinir ağı mimarisi için ara katmanda bulunan nöron sayıları üzerinde denemeler yapılmış ve en yüksek test başarısına sahip mimari seçilmiştir. İlk adım olarak veri setinin %70'lik kısmı yapay sinir ağına sonuçları ile beraber gösterilerek eğitim süreci tamamlanmıştır. Ardından girdi parametreleri verilen %30'luk kısım için, sonuçlar gösterilmeden, yapay sinir ağından tahmin edilmesi beklenmiştir. Eğitim sürecinde yapay sinir ağına Levenberg Marquardt, Bayesian ve Broyden-Fletcher-Golffarb-Shanno olmak üzere üç farklı öğrenme algoritması kullanılmıştır. Matlab R2016a platformunun kullanıldığı çalışmada eğitim algoritmalarına ait test sonuçları karşılaştırılmış ve %94'lük test başarı oranı ile Levenberg Marquardt Algoritması en iyi test sonucuna ulaşmıştır. İleri yönlü geri yayımlı yapının kullanıldığı yapay sinir ağında ortalama mutlak yüzde hata oranı %5,89 bulunmuştur. Son adımda, Matlab platformunda tasarlanan yapay sinir ağı Visual Studio platformuna alınmış ve tahmin sonuçları yine ortalama mutlak yüzde hata çerçevesinde karşılaştırılmıştır. Yapılan karşılaştırmada Matlab programının Visual Studio platformundan daha iyi performans gösterdiği tespit edilmiştir.

**Anahtar Kelimeler:** Yapay Sinir Ağı, Tahmin, Yüksek Fırın, Sıvı Hamdemir, Demir cevheri.

## Estimation of Pig Raw Iron with Artificial Neural Networks and 5th Blast Furnace Application

### Abstract

Liquid crude iron production from iron ore takes place in the blast furnace operation. This process has a long and complex nature. A casting takes 6-8 hours to complete, depending on the production capacity of the blast furnace. In this study, it is aimed to estimate the amount of liquid crude iron produced by using the raw material data of the blast furnaces of the integrated iron and steel factory through artificial neural networks. In this study, the working style of the blast furnace was examined and the input and output parameters were determined. 70% of 1000 production data belonging to 2016 and 2019 are reserved as training and the remaining 30% as test data. In the first step, the data are normalized and made available for the artificial neural network. The results obtained after the testing process were denormalized. On the other hand, the time periods in which the blast furnace is not producing were excluded from the data set. For artificial neural network architecture, experiments have been made on the number of neurons in the intermediate layer and the architecture with the highest test success has been selected. As the first step, the training process has been

\* Sorumlu Yazar: Karabük Üniversitesi, Karabük, Türkiye, ORCID: 0000-0002-2854-4005, [canerozcan@karabuk.edu.tr](mailto:canerozcan@karabuk.edu.tr)

completed by showing 70% of the data set to the artificial neural network with its results. Then, for the 30% part whose input parameters were given, it was expected to be estimated from the artificial neural network without showing the results. During the training process, three different learning algorithms, Levenberg Marquardt, Bayesian and Broyden-Fletcher-Golffarb-Shanno, were used in the neural network. In the study where Matlab R2016a platform was used, the test results of the training algorithms were compared and the Levenberg Marquardt algorithm reached the best test result with a test success rate of 94%. The average absolute percentage error rate was found to be 5.89% in the artificial neural network where the forward backward propagation structure was used. In the last step, the artificial neural network designed on the Matlab platform was taken to the Visual Studio platform and the estimation results were compared within the mean absolute percentage error. In the comparison, it was determined that Matlab program performed better than the Visual Studio platform.

**Keywords:** Artificial Neural Network, Prediction, Blast Furnace, Pig Iron Ore.

## 1. Giriş

Sıvı pik demir, demir-çelik sektörünün en önemli işlenmiş hammaddesidir. Sıvı ham demir üretimi birden fazla yöntemle gerçekleştirilebilmektedir. Elde edilen sıvı ham demir torpedo veya pota vasıtasıyla çelikhane işletmesine gönderilmektedir (Özlem, 2005). Her ne kadar sıvı ham demir üretimi, birden fazla yöntem ile gerçekleştirilse de ilgili süreç uzun ve zor bir yapıya sahiptir. İnsan bünyesinin dayanamayacağı yüksek sıcaklıkta, devreye otomasyon sistemleri girmektedir. Gelişen teknoloji ile birlikte otomasyon sistemlerinden alınan üretim verileri çeşitli yapay sinir ağı mimarisinde kullanılmıştır. Fırın giriş parametreleri değiştirilerek eğitilen yapay sinir ağının gerçekleştirdiği tahminlerle, sıvı ham demir içerisindeki silisyum yüzdesi kestirilmeye çalışılmıştır (Radhakrishnan & Mohamed, 2000). Bu tahmin işleminin bir benzeri olarak yapılan çalışmada sıvı ham demire ait kütle-ısı dengesini hesaplayan bir model tasarlanmıştır (Peacey & Davenport, 1979). Üretilen sıvı ham demirin sahip olduğu sıcaklığın tahmin edilebilmesi için NOE ve NARX olmak üzere iki farklı model kullanılarak elde edilen sonuçlar birbirleri ile karşılaştırılmıştır. Yapılan karşılaştırmada NOE modelinin simülasyonda, NARX modelinin kontrol sistemlerinde daha faydalı olacağı tespit edilmiştir (Jimenez, Mochon, Ayala, & Obeso, 2004). Finlandiya, Koverbarda bulunan bir yüksek fırın işletmesinde fırın içi sıcaklığı tahmin etmek amacıyla tek gizli katmana sahip yapay sinir ağı kullanılmıştır (Nikus & Saxen, 1996).

Sıvı ham çeliğin kimyasal analiz sonuçlarının önceden öngörülebilmesi işletme ünitesine büyük kolaylıklar sağlamaktadır. İstenilen çelik kalitesi elde edilirken diğer taraftan üretim maliyetlerinin de düşürülmesine yardımcı olacaktır. Bu amaçla yapılan çalışmada yapay sinir ağından faydalanılmıştır (Bozkurt, 2007). Yüksek fırın, üretim aşamaları sebebiyle karmaşık bir yapıya sahiptir. Bu karmaşıklığın önüne geçebilmek ve sıvı ham çelik üretiminde optimum değerler yakalayabilmek için parametreler üzerinde uzun süren çalışmalar gerçekleştirilmiştir. Yapay sinir ağlarından önce kullanılan klasik, matematiksel hesaplamalarda istenilen çelik kalitesi elde edilememiştir (GE, 1999). Sıvı ham demir üretiminde kullanılan ham maddelerin maliyeti, üretim miktarına paralel olarak artmaktadır. Üretim sürecinin kontrolü ve sürdürülebilirliği sağlamak büyük önem arz etmektedir. Bu sebeple yüksek fırınlarda yakıt olarak kullanılan kok miktarı üzerine yapılan çalışmada yapay sinir ağı kullanılmıştır. Yapılan çalışmada kullanılan kok miktarının, üretilecek sıvı ham demir miktarı ile ilişkisi modellenmiştir. Bu modellemede yakıt miktarı ve sıcak metal içerisindeki kükürt oranları baz alınmıştır. Elde edilen sonuçlar ise modelin üretim sürecinde tesise yardımcı olabileceği yönündedir (Assis, Carvalho, & Ansarbay, 2019).

Yapay sinir ağlarının güçlü olduğu özelliklerinden birisi tesise bağlı kalmamasıdır. Diğer bir ifade ile tasarlanan yapay sinir ağı, bir tesiste aktif olarak kullanılıp başka bir tesiste de kullanılabilir. Önemli olan nokta ise giriş ve çıkış parametrelerinin doğru bir şekilde analiz edilmesidir. Yüksek fırınlar işletmesinden bir önceki ünite olan sinter tesislerinde gerçekleştirilen çalışmada, yüksek fırınlara şarj edilen demir cevheri verimini arttırmak amacıyla yapay sinir ağlarından faydalanılmıştır (Beşkardeş & Özdemir, Sinter Makinesinin Örüntü Tanıma Tabanlı Otomatik Hız Kontrolü, 2017). Yapay sinir ağları farklı tesislerde olduğu gibi farklı sektör ve alanlarda da kullanılabilir. Sağlık sektörü için yapılan çalışmada son yıllarda azalan doğurganlık oranları üzerinde çalışma yapılmıştır. Laboratuvar ortamında alınan veriler, makine öğrenmesi algoritmaları kullanılarak tahmin modeli oluşturulmuştur. Doğrusal Ayırt Edici, K en yakın Komşuluk ve Lojistik Rerasyon yöntemlerinin kullanıldığı çalışmada başarı oranları karşılaştırılmıştır (Karadağ, 2020). Jelatin çözeltilerinin dinamik viskozitesini tahmin edebilmek için yapılan çalışmada ileri beslemeli yapay sinir ağı modeli kullanılmıştır. Oluşturulan model karesel hata, ortalama mutlak hata gibi birden fazla değerlendirme kriterine tabii tutulmuştur. İstatistiksel veriler neticesinde modelin tahmin için kullanılabilir olduğuna karar verilmiştir (Demirbay, Karakullukçu, & Acar, 2020).


Günümüzde teknolojik gelişmelerin insan hayatına etkisi daha yoğun olarak hissedilmektedir “Akıllı Ev” adı verilen ve otomasyon sistemlerine bağlı olarak tasarlanan yeni evler günümüzün bir parçası olmuştur. Akıllı ev uzmanları ve yapılan literatür çalışmaları neticesinde oluşturulan veriler, SWOT metodu çerçevesinde değerlendirilip etkileri araştırılmıştır (Tomaş & Dostoğlu, 2020). Farklı sıcaklıklara sahip birden fazla akışkanlar arasında gerçekleşen ısı değişimi mühendislik alanında büyük bir problem teşkil etmektedir. Bu noktada kullanılan ısı eşanjörleri akışkanlar arasındaki enerji farkını ortadan kaldırmaktadır. Bu çalışma için tasarlanan modellemede, birbirinden farklı algoritmaların kullanıldığı yapay sinir ağlarından faydalanılmıştır (Demir, 2020). Gelişen teknoloji ile beraber haberleşme sistemlerindeki alt yapılar da güncellenmektedir. Fakat bu değişimlerin, özellikle 5G gibi yeni haberleşme teknolojilerinde, matematiksel olarak modellenmesi oldukça zordur 5G'nin yeni bir iletişim teknolojisi olması, araştırma ve geliştirmede kaynak yetersizliğini de beraberinde getirmiştir. Derin öğrenme tabanlı gerçekleştirilen çalışmada yeni nesil teknoloji için çalışma alanları araştırılmıştır (Yıldırım, Sokullu, & Pehlivan, 2020). Sağlık sorunlarının en büyük sebepleri arasında hava kirliliği gelmektedir. Bu durumun önüne geçilmesi için hava kirliliği model çerçevesinde değerlendirilmiştir. Kastamonu iline ait meteorolojik veriler yapay sinir ağına kullanılmıştır. Çeşitli normalizasyon tekniklerinin kullanıldığı çalışmada problemin çözümüne en uygun sınıflandırma algoritması tespit edilmeye çalışılmıştır (Gültepe, 2019).

Yüksek fırınlarda bir dökümün tamamlanması, fırının üretim kapasitesine bağlı olarak, 6-8 saat sürmektedir. Çalışmada entegre demir-çelik fabrikasının yüksek fırınlarına ait hammadde verileri kullanılıp üretilen sıvı ham demir miktarı, yapay sinir ağları vasıtasıyla tahmin edilmesi amaçlanmıştır. Bu sayede üretim için gerekli olan bekleme süresi ortadan kaldırılacak ve işletme ünitesine yardımcı olunacaktır.

## 2. Materyal ve Metot

### 2.1. Giriş ve Çıkış Parametrelerinin Belirlenmesi

Yüksek fırın, demir cevherinden sıvı ham demir üretildiği tesislerdir. Bu üretim yüksek sıcaklık ve basınç altında birtakım fiziksel, kimyasal reaksiyonların gerçekleşmesi neticesinde meydana gelir. Üretim sürecinin tamamlanmasının akabinde sıvı ham demir, torpedo veya pota yardımıyla bir sonraki tesis olan çelikhaneye gönderilir. Çelikhane işletmesinin son ünitesi olan sürekli dökümler biriminde kütük, yuvarlak kütük gibi yarı mamul üretilir. Yarı mamulün katma değeri yüksek ürünlere dönüştürülebilmesi amacıyla entegre tesislerin son işletmesi olan haddehanelere gönderilmekte ve nihai ürün satışa hazır hâle getirilmektedir.



Şekil 1. Yüksek fırında sıvı ham demir üretimi

Demir cevherinin indirgenme ve karburizasyon reaksiyonları 1200-1600 °C aralığında gerçekleşir. Bu ortam, refrakter adı verilen yüksek sıcaklıklara dayanıklı özel tuğlalar ile sağlanır. Fırının dış yapısı ise çelik zırh ile çevrilidir ve bu zırh yüksek fırını ayakta tutar. Fırının üst kısmından şarj edilen kok, demir cevheri ve fluks karışımı tabana doğru ilerlemeye başlar. Bu süreçte karışım sıcak hava ile karşılaşır. Artan sıcaklık ile birlikte demir cevheri ergime durumuna geçer ve yüksek fırının alt kısmında birikmeye başlar. Tepkimeler tamamlandığında fırının alt kısmında sıvı ham demir ve cüruf olmak üzere iki çeşit ürün elde edilir. Cüruf, yoğunluğu düşük olması sebebi ile sıvı ham demirin üzerinde kalır. İşletme tarafından gerçekleştirilen müdahale ile sıvı ham demirin üzerinden alınır ve bu sayede haznede sadece sıvı ham demir kalır. Geriye kalan sıvı ham demir torpedo veya pota ile bir sonraki işletme ünitesi olan çelikhaneye gönderilir.

Yapılan çalışmada, demir-çelik entegre tesisinde bulunan yüksek fırının, 2016 ve 2019 yılları arasına ait 1000 adet üretim verisi kullanılmıştır. Bu veri kümesinin %70'i eğitim, geriye kalan %30'u test verisi olarak kullanılmak üzere ayrılmıştır. Tasarlanan yapay sinir ağı ile üretime başlayan yüksek fırının sekiz saat sonra alacağı döküm miktarını tahmin etmesi hedeflenmiştir.

Sıvı ham demir üretiminde çok çeşitli ham madde kullanılmaktadır. Bu durumun sebebi sıvı ham demir üretiminin karışık bir yapıya sahip olmasıdır. Daha önce yapılan çalışmalar incelenip Tablo 1'de verilen üretimde hangi giriş ve çıkış parametrelerinin kullanıldığı tespit edilmiştir (Beşkardeş, Türkoğlu, & Acı, Prediction of the hot metal silicon content in the Blast Furnace, 2016).

Tablo 1. Yüksek fırın giriş parametreleri

Parametre Adı	Ölçü Birimi	Açıklama
Kok	ton	Yakıt
Cevher	ton	Demir Cevheri
Fluks	ton	Cüruf Yapıcı Malzeme
Sıcak Hava	°C	Tüyerden üflenen sıcak hava

Kok, yüksek fırınların yakıtı olarak adlandırılmaktadır. Girdi parametrelerinin yaklaşık %50-%60'ını oluşturmaktadır. Demir cevherinin sıvı ham demire dönüşümü sırasında gerçekleşen reaksiyonlar için gereken yüksek sıcaklık, kok sayesinde sağlanır. Fakat kok, direkt olarak yüksek fırınlara şarj edilemez. Bunun için kok bataryaları adı verilen tesiste önhazırlık işlemlerine tabii tutulur. Kok malzemesinde aranılan fiziksel boyut 6-8 mm çapa sahip olmasıdır.

Demir cevher, yüksek fırının ana girdi malzemeleri arasındadır. Tıpkı kok malzemesinde olduğu gibi demir cevheri de direkt olarak yüksek fırınlara şarj edilemez. Yüksek fırınlarda kullanılabilmesi için eleme, kırma gibi önhazırlıktan geçirilir. Demir cevherinin ideal çapı 6-8 mmdir. Bu değer aralıklarında demir cevheri, reaksiyonlarda katı-sıvı dengesini çok iyi yakalamaktadır. Demir cevherinin yapısında Silika ve Alimuna gibi istenmeyen bileşenler bulunmaktadır. Bu bileşenler sıvı ham demir içerisinde yoğun olarak bulunduğu takdirde çelik kalitesini düşürecektir. Ayrıca yarı mamul aşamasında kanamalara, kırılmalara sebebiyet verebilmektedir.

Fluks adı verilen dolomit, kireçtaşı gibi malzemeler yapısı gereği istenmeyen bileşenlere yapışarak sıvı ham demirin içerisinde ayrışmasını sağlar. Fırının alt bölümünde bulunan ve tüyer adı verilen özel hava kanallarından üflenen sıcak hava reaksiyonların gerçekleşmesinde önemli rol oynar. Demir cevherinin sıvı forma geçebilmesi için 1500 °C dolaylarındaki sıcaklık bu şekilde sağlanır.

Tablo 2. Yüksek fırın çıkış parametresi

Parametre Adı	Ölçü Birimi	Açıklama
Sıvı Ham Demir	ton	Yüksek fırından alınan sıvı ham demir

Sıvı ham demir, demir-çelik sektörünün ana ürünüdür. Hem demir cevherinden hem de hurda malzemesinden üretilmektedir. Yüksek fırınlarda demir cevheri yüksek sıcaklık ve basınç altında ergiyik duruma geçmesi sonucunda sıvı ham demir oluşmaktadır. Çalışmada kullanılan üretim verileri, yüksek fırın otomasyon sisteminden alınmıştır. Bir sonraki adım olarak veriler, yapay sinir ağına kullanılabilmek için normalize edilmiştir.


$$x' = 0.8 * \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0.1 \quad (1)$$

Burada  $x'$  normalizasyonu yapılmış veriyi,  $x_i$  iterasyondaki veriyi,  $x_{max}$  ve  $x_{min}$  değerleri ise veri setindeki minimum ve maksimum değerleri ifade etmektedir.

## 2.2. Yapay Sinir Ağı Mimarisi

Yapay sinir ağına; insan beyninin gerçekleştirebildiği öğrenme, düşünme, karar verebilme gibi niteliklere sahip olduğu ve tasarım olarak insan beynini andırdığı için bu isim verilmiştir. Yapay sinir ağının çalışma prensibi beyin ile hemen hemen aynıdır. Duyu organlarından beyne gelen sinyaller ara katmanda bulunan nöronlara aktarılır. Bu değerler matematiksel hesaplaması ağırlık değerlerinin, kendi değerleri ile çarpılması sonucunda bulunur ve bir sonraki katmana iletilirler. Ara katmanda toplanan sinyaller bir sonraki katmana iletilir. Yapay sinir ağına ise bu sistem, aktivasyon fonksiyonu ile sağlanmaktadır (Şahin, 2018).

İleri yönlü geri beslemeli ağ modeli başarılarından ötürü uygulamalarda sıklıkla kullanılmaktadır. Çok katmanlı yapının tercih edildiği modelde girdi, ara ve çıktı katmanları bulunmaktadır (Aksu, 2019). Model, iki aşamalı olarak tasarlanmıştır. İlk aşamada veri akışı girdi katmanından çıktı katmanına doğru ilerler ve sinir ağı bir tahmin üretir. İkinci aşamada ise tahmini değer ile gerçek değer arasındaki fark kadar yapay sinir ağındaki nöronların ağırlıkları güncellenir. Güncelleme işlemindeki amaç çıktı değerlerinin arasındaki farkı her adımda azaltmak ve tahmini değerleri gerçek değerlere yaklaştırmaktır (Keleşoğlu, 2006).



Şekil 2. Geri beslemeli yapay sinir ağı mimarisi

Yapay sinir ağındaki nöronların çıkış değerleri şu şekilde hesaplanmaktadır. İlk adım olarak iterasyondaki nörona gelen bağlantıya ait ağırlık ile komşu nöronun ağırlığı çarpılarak toplanır.

$$y_i = \sum_{i=1}^n w_i x_i \quad (2)$$

İterasyon sayısı  $i$ ,  $w_i$  nöronun bağlı bulunduğu ağırlık,  $x_i$  komşu nöronun sahip olduğu ağırlığı,  $n$  iterasyondaki son adımı ifade etmektedir.

Yapay sinir ağına gerçekleştirildiği tahmin ile gerçek değer arasındaki fark bulunur.

$$E = \frac{1}{2} \sum (d_i - y_i)^2 \quad (3)$$

$d_i$  gerçek değer ve  $y_i$  yapay sinir ağına ait tahmini değerdir.

$$\Delta w_i = \eta \delta_i y_i \quad (4)$$

$\Delta$  değişim miktarını,  $\eta$  öğrenme katsayısını,  $\delta_i$  azalma miktarını göstermektedir. Son adımda ise mevcut ağırlıklar güncellenir.

$$w_i^{yeni} = w_i^{eski} + \Delta w_i \quad (5)$$

Hata miktarı istenilen seviyeye yaklaşıncaya kadar bu döngü devam eder.

### 3. Araştırma Sonuçları ve Tartışma


Çalışmada, yüksek fırının üretimde kullandığı ham maddeler giriş parametreleri, sıvı ham demir ise çıktı parametresi olarak belirlenmiştir. Fırının diğer çıktıları olan cüruf ve yüksek fırın gazı çalışma dışında tutulmuştur. Bu sebeple, başlangıç aşamasında dört adet giriş ve bir adet çıkışa sahip ileri yönlü geri yayımlı yapay sinir ağı mimarisi tasarlanmıştır. Tek gizli katmanın bulunduğu tasarımda, ara katmandaki nöron sayısının belirlenmesi için denemeler yapılmıştır. Matlab R2016a platformunun kullanıldığı çalışmada, ara katmandaki nöron sayısı değiştirilerek elde edilen test sonuçlarına istinaden en iyi mimari belirlenmiştir. Ara katmanda sırası ile bir, iki, üç ve dört adet nöron kullanılıp sonuçlar kayıt altına alınmıştır.

Model karşılaştırılmasında Matlab platformunun kullanıcılarına sunduğu varsayılan ayarları tercih edilmiştir. Aktivasyon fonksiyonu *logsig*, öğrenme fonksiyonu *trainlm*, çıkış fonksiyonu olarak *linear* fonksiyonu kullanılmıştır.

Tablo 3. Modellerin karşılaştırılması ve test sonuçları

Model Adı	Eğitim Başarı Oranı (%)	Test Başarı Oranı (%)
Model 1	98,94	94,20
Model 2	99,42	94,03
Model 3	99,56	94,45
Model 4	99,50	93,88

Tüm modellerde eğitim başarı oranı %98'in üzerinde olduğu görülmüştür. Bu yüksek başarının sebebi veriler arasında salınımın olmamasıdır. Test başarı oranları ise %93'ün üzerindedir. Modellere ait sonuçlar incelendiğinde ilk sırada Model 3, ikinci sırada Model 2, üçüncü sırada Model 1 ve dördüncü sırada Model 4 yer almaktadır. Ara katmanda bulunan nöron sayısının artması, her zaman test başarı oranını arttırmamaktadır. Model 3 ve Model 4 karşılaştırıldığında ara katmanda üç nöronu bulunan modelin, ara katmanında dört nöronu bulunan modelden daha yüksek test başarı oranına sahip olduğu görülmektedir. Şekil 2'de Model 3'e ait eğitim ve test sonuçlarının grafikleri gösterilmiştir.



Şekil 3. Model 3'e ait eğitim ve test sonuçları

Grafiklerdeki fit doğrusu, YSA'nın eğitim ve test süreci boyunca gerçekleştirdiği yönelimleri ifade etmektedir.  $Y=T$  doğrusunda ise  $Y$ , YSA'nın vermiş olduğu çıktıları temsil ederken  $T$  test çıktılarını göstermektedir. Bir YSA'nın fit ile  $Y=T$  doğrusu birbirine ne kadar yakın ise sonuç o kadar yüksek olacak ve ilgili süreç o kadar başarılı sayılacaktır. Grafiklerdeki yuvarlak noktalar, eğitim ve test için ayrılan verileridir. Daha önce eğitim ve test için ayrılan veriler, YSA'ya normalize edilerek gösterildiği için değer aralıkları 0.1-0.9 arasındadır. Ara katmanda üç nöronu bulunan YSA mimarisi, eğitim aşamasını yaklaşık %99 gibi çok yüksek bir başarı oranı, test aşamasını %94'lük bir başarı oranı ile tamamlamıştır. Yapılan ilk iki denemelerden farklı olarak  $Y=T$  doğrusuna en yakın oranı bu mimari yakalamıştır. Test aşamasında, Matlab programının varsayılan ayarları tercih edilmiştir. Aktivasyon fonksiyonu olarak  $\log_{sig}$ , öğrenme fonksiyonu  $trainlm$ , çıkış fonksiyonu ise lineer fonksiyonu kullanılmıştır.

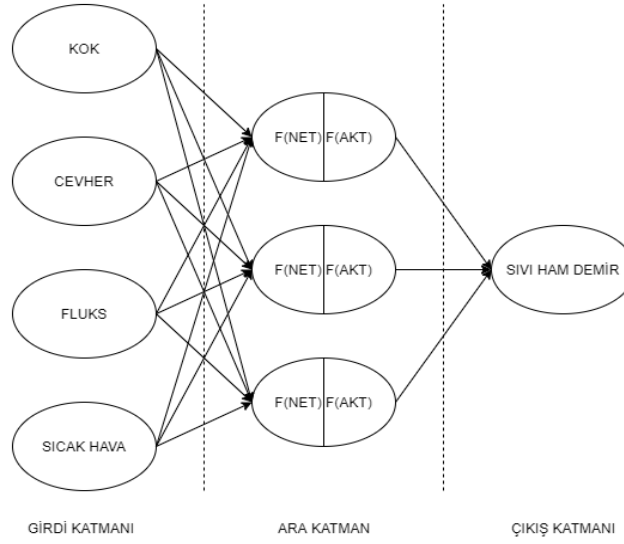
Yapay sinir ağı mimarisinin belirlenmesinin ardından, yapay sinir ağların eğitiminde sıklıkla kullanılan Levenberg Marquardt Algoritması (LM), Bayesian Algoritması (BR) ve Broyden-Fletcher-Golgarb-Shanno Algoritması (BFGS) ile eğitim ve test denemeleri yapılmıştır (Toraman, 2019).

Tablo 4. Algoritmaların eğitim ve test sonuçları

Algoritma/Kriter	LM	BR	BFGS
Eğitim	%99,56	%99,47	%99,39
Test	%94,45	%94,21	%90,29
İterasyon Sayısı	53	78	71

Eğitim aşamasını her üç algoritma da yüksek başarı oranı ile tamamlamıştır. Her ne kadar test başarı oranları yakın olsa da Levenberg Marquardt algoritması, Bayesian ve Broyden-Fletcher-Golgarb-Shanno algoritmasından daha yüksek bir oran elde etmiştir. İterasyon sayısı incelendiğinde Bayesian algoritmasının daha yavaş çalıştığı tespit edilmiştir. Çalışmanın son adımında platform değişikliği yapılmış ve aynı mimari Visual Studio ortamına alınmıştır. Şekil 4'te yapay sinir ağının son hali gösterilmiştir.





Şekil 4. Yapay sinir ağı mimarisi

Matlab platformunda en yüksek test başarısına ulaşan Model 3, Visual Studio 2017 platformunda da kullanılmıştır. İki farklı platforma ait tahminler ortalama mutlak yüzde hata çerçevesinde değerlendirilmiştir.

$$MAPE = \frac{100}{n} \sum_{n=1}^n \frac{|y_g - y_t|}{y_g} \quad (6)$$

Eşitlikte  $n$  tahmin yapılan iterasyonu,  $y_g$  iterasyondaki gerçek değer,  $y_t$  iterasyona ait yapay sinir ağının gerçekleştirdiği tahmini değeri ifade etmektedir.

Tablo 5. Platform değişikliğinin analizi

Kriter/Platform	Matlab Platformu	Visual Studio Platformu
Eğitim	%99,56	%99,83
MAPE	%5,89	%7,83
İterasyon Sayısı	78	153

İki farklı platformda da eğitim başarı oranı %99'un üzerinde olduğu görülmektedir. MAPE oranları incelendiğinde sıfıra yakın olan taraf %5,89 ile Matlab platformu olmuştur. Visual Studio platformu ise %7,83 ile onu takip etmektedir. İterasyon sayısına bakıldığında Matlab platformunun Visual Studio platformundan daha az iterasyona ihtiyaç duyduğu görülmektedir. Bu duruma paralel olarak Matlab'ın çalışma süresi Visual Studio'dan daha kısa olduğu söylenebilir.

## 4. Sonuç

Yapılan çalışma sonucunda, yüksek fırınlardan alınan veriler Levenberg Marquardt algoritması kullanılarak daha başarılı test sonuçları vermiş ve üretilecek sıvı ham demir miktarı, 8 saat beklemeden öngörülebilir hale gelmiştir. Kullanılan yapay sinir ağının daha doğru tahminler yapabilmesi için parametreler artırılabilir. Başlangıçta, teorik üretimde ihmal edilen cüruf ve yüksek fırın gazı hesaplamalara dahil edilerek işletme ünitesi için daha kullanışlı bir model ortaya konulabilir.

Giriş parametreleri PLC, SCADA, DCS gibi canlı sistemlerden alınarak yapılan tahminler anlık olarak takip edilebilir. Üretim süreci anlık olarak takip edildiği için çelikhane işletmesi ile daha kolay bir şekilde entegre olabilecektir. Diğer bir ifade ile tesisler arası haberleşmeye büyük katkı sağlayacaktır. Diğer taraftan, ham madde hazırlama ünitesine düşük maliyetli demir cevheri karışımını hazırlayabilmesi için yardımcı olabilir.

## Kaynakça

- Aksu, Y. (2019). İleri Beslemeli Geri Yayılımlı Yapay Sinir Ağlarının İncelenmesi. *Yüksek Lisans Tezi, Van Yüzüncü Yıl Üniversitesi, Sağlık Bilimleri Enstitüsü*, Van.
- Assis, P., Carvalho, L., & Ansarbay, I. (2019). Artificial Neural Network-Based Committee Machine for Predicting Fuel Rate and Sulfur Contents of a Coke Blast Furnace. *International Journal of Science and Research*, 1492-1495.
- Beşkardeş, A., & Özdemir, M. E. (2017). Sinter Makinesinin Örüntü Tanıma Tabanlı Otomatik Hız Kontrolü. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 808-820.
- Beşkardeş, A., Türkoğlu, S., & Acı, Ç. (2016). Prediction of the hot metal silicon content in the Blast Furnace. *24th Signal Processing and Communication Application Conference (SIU)*, (s. 709-712). Zonguldak.
- Bozkurt, E. (2007). Yüksek Fırın Analizi ve Yapay Sinir Ağları ile Modellenmesi. *Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü*, Sakarya.
- Demir, M. H. (2020). Thermal Modeling and Performance Analysis for a Chevron Type. *European Journal of Science and Technology*, 779-789.
- Demirbay, B., Karakullukçu, B., & Acar, F. G. (2020). Artificial Neural Network (ANN) Approach for Dynamic Viscosity of Aqueous Gelatin Solutions: A Soft Computing Study. *Avrupa Bilim ve Teknoloji Dergisi*, 465-475.
- GE, A. X. (1999). A Neural Network Approach To The Modeling of Blast Furnace. *MEng Thesis, MIT Department of Electrical Engineering and Computer Science*.
- Gültepe, Y. (2019). Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme . *Avrupa Bilim ve Teknoloji Dergisi*, 8-15.
- Jimenez, J., Mochon, J., Ayala, J. S., & Obeso, F. (2004). Blast Furnace Hot Metal Temperature Prediction Through Neural Networks-Based Models. *ISIJ Journal*, 573-580.
- Karadağ, K. (2020). Makine Öğren Yöntemleri ile Semen Kalitesi Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, 306-311.
- Keleşoğlu, Ö. (2006). Yapay Sinir Ağları ile Betonarme Kiriş Kesitleri Analizi. *İMO Teknik Dergi*, 3935-3942.
- Nikus, M., & Saxen, H. (1996). Prediction of A Blast Furnace Burden Distribution Variable. *ISIJ International*, 1142-1150.
- Özlem, A. (2005). Yüksek Fırın İşletmeciliğinde Optimizasyon. *Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü*, İstanbul.
- Peacey, J. G., & Davenport, W. G. (1979). *The Iron Blast Furnace: Theory and Practice*. Pergamon Yayınları.
- Radhakrishnan, V. R., & Mohamed, A. (2000). Neural networks for the identification and control of blast furnace hot metal quality. *Journal of Process Control*, (s. 509-524).
- Şahin, M. (2018). Karar Ağaçları ve Yapay Sinir Ağları Kullanılarak Kasko Sigortalarında Risk Değerlendirme. *Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi İstatistik Bölümü Anabilim Dalı*, İstanbul.
- Tomaş, M., & Dostoğlu, N. (2020). Smart House with Artificial Intelligence. *Avrupa Bilim ve Teknoloji Dergisi*, 486-493.
- Toraman, M. (2019). Uçakların İtici Kuvvetinin Yapay Sinir Ağları ile Tahmini. *Yüksek Lisans Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü*, Kayseri.
- Yıldırım, M., Sokullu, R., & Pehlivan, S. (2020). Deep Learning for Communication Systems. *European Journal of Science and Technology*, 1012-1025.