



Yapay sinir ağı yaklaşımıyla çinko kalınlığının tahminlenmesi

Tuğçen Hatipoğlu^{1*}, Semra Boran², Burcu Özcan¹, Alpaslan Fıçlalı¹

¹Kocaeli Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği, Kocaeli

²Sakarya Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği, Sakarya

03.10.2012 Geliş/Received, 24.12.2012 Kabul/Accepted

ÖZET

İşletmeler arasında artan rekabet nedeniyle müşterinin istediği kalitede ürün üretmek ve maliyetlerin düşürülmesi öncelikli hedeflerdendir. Galvaniz sektöründe temel hammadde girdisi olan Çinko (Zn), en önemli maliyet kalemini oluşturmaktadır. Hem müşteri tekliflerinin hazırlanması aşamasında kullanılacak çinko miktarının tahmin edilmesi, hem de optimum kaplama kalınlığının elde edilebilmesi için uygun imalat koşullarının sağlanması gerekmektedir. Çalışmada galvaniz sektöründe faaliyet gösteren bir firmada Yapay Sinir Ağı (YSA) yardımıyla galvaniz işlemi sonucunda elde edilecek kaplama kalınlığı tahmin edilmeye çalışılmıştır. Tahmin edilen değerlerin gerçek verilerle uygunluğunu test etmek açısından hipotez testi uygulanmış; modelden elde edilen değerlerle gerçek değerlerin ortalaması arasında istatistiksel olarak anlamlı bir fark olmadığı görülmüştür.

Anahtar Kelimeler: Tahminleme, Metasezgisel, Yapay Sinir Ağları, Kaplama Kalınlığı

Forecasting of zinc coating thickness with artificial neural networks

ABSTRACT

Since the competition level among the companies is increasing day by day, meeting customer demands with qualified products and cost reduction are primary goals of each company. And zinc, the main raw material in galvanization sector, is the most important cost item. So it is required to forecast the amount of zinc to be spent. In this study it is tried to forecast the amount of zinc consumption using the artificial neural network (ANN) method. To evaluate the convenience of values hypothesis tests are done; and the results showed that there is no significant difference between the predicted and real outputs statistically.

Keywords: Forecasting, Metaheuristics, Artificial Neural Networks, Coating Thickness

* Sorumlu Yazar / Corresponding Author

1. GİRİŞ

İşletmelerde güvenilir maliyet verilerine ulaşmak, öncelikle yöneticilerin sağlıklı kararlar verebilmeleri için bilgi gereksinimlerini karşılamak amacıyla yapılır. Bu temel amacın dışında doğru verilerin elde edilmesi kısa dönemde ve uzun dönemde pek çok getiri sağlar. Yapılan yatırım sonucunda istenen oranda kar elde edilmesi, teklif fiyatlarının belirlenmesi, işletmede başarının değerlendirilmesi, maliyet kontrolü vb. çalışmalar bu getiriler arasında sayılabilir. Böylece her bir ürün için planlanan başarının sağlanıp sağlanmadığı, teklif fiyatlarından piyasa durumuna göre ne kadar indirim yapılabileceği belirsizlikten kurtarılmış olur.

Sipariş maliyet yöntemi farklı malzeme ve işçilik giderlerini ve farklı üretim yöntemlerini gerektiren birden çok ürünün üretildiği işletmelerde uygulanır. Uygulamanın gerçekleştirildiği işletmede bu yöntem kullanılmakta ve direkt malzeme giderlerinin doğru hesaplanmasına yönelik verilerin sağlanması çalışmanın temelini oluşturmaktadır. Bu süreç işletmedeki ilgili bilgilerin ham veri olarak toplanmasından başlayıp, yöneticilere nihai işlenmiş verilerin sunulmasıyla sona erer.

Çalışmada hedef üretim maliyetlerinden olan direkt çinko maliyetinin hesaplanması için gerekli kaplama kalınlığı bilgisinin tahmin edilmesidir. Bu maliyet üretim hacmi ile aynı yönde değişim gösterir, yani üretim miktarının bir fonksiyonudur. Maliyet fonksiyonlarının tahmin edilmesinde iş ölçümü yaklaşımı, en düşük ve en yüksek noktalar yöntemi, basit ya da çoklu regresyon yöntemleri kullanılırken, son dönemde yapay sinir ağları modeli de bu yöntemler arasına katılmıştır. Çoklu regresyon yöntemi ile yapılmış birçok tahmin etme çalışması vardır, ancak bu yöntemde bazı koşullar sağlanmazsa sağlıklı maliyet öngörüsü yapılamaz. Bu koşullardan bazıları bağımlı ve bağımsız değişkenler arasında ekonomik mantığı olan bir ilişkinin varlığı, bağımsız değişkenin bağımlı değişkende gözlemlenen değişimlerin önemli bir bölümünü açıklıyor olması, doğrusallık varsayımı, hata terimlerinin bağımsızlığı ve normal dağılıdır. Bu varsayımlar pratikte sağlanmıyorsa ve belirlenen probleme uymuyorsa bu yöntemi kullanmak yersiz olacaktır. Ancak yapay sinir ağları yönteminin bu dezavantajları bulunmamakta, değişkenler arasındaki belirsiz ilişkileri çözüp, güvenilir bir şekilde analiz ederek yorumlamaktadır.

Literatürde üretim alanında tahmin etme amacıyla YSA modeli kullanılan pek çok çalışmaya rastlamak mümkündür.

Zhang ve Fuh (1998) ürün maliyetlerinin tasarım aşaması boyunca etkin bir şekilde kontrol edilmesine odaklanmıştır. Bu da üretimin proses planları tam olarak netleşmeden ürünün maliyetinin tahmin edilmesini gerektirir. Bu makalede geri yayımlı yapay sinir ağı kullanarak maliyet tahmini amaçlanmış ve yalnızca tasarım bilgisinden yola çıkılarak ürün maliyetinin tahmini için bir prototip geliştirilmiştir. Ürün tasarımında maliyete ilişkin bütün unsurlar belirlenerek, bu maliyete ilişkin unsurlar arasındaki korelasyon ve ürünün nihai maliyeti geri yayımlı sinir ağı eğitilerek belirlenmiştir. Test örnekleri kullanarak sistemin performansı da çalışmada verilmiştir[1]. Kermanshahi ve Iwamiya (2002) Japonya'da 2020 yılına kadar olan elektrik yükünün tahmin edilmesi için 10 faktör ele almıştır. (yerli ürünler, nüfus, hissedar sayısı, hava koşulları, CO2 miktarı, endüstri üretim indeksi, benzin fiyatları, enerji tüketimi ve elektrik fiyatları). Yapay sinir ağı yaklaşımını kullanarak elektrik yükünü tahmin etmişlerdir[2]. Benzer bir çalışmada yeni tipte fren diski üretmeye başlayacak olan bir firmada üretim maliyetlerinin tahmin edilmesini için yapay sinir ağları kullanılmış ve yapay sinir ağları teorisinin geçerliliğini göstermiştir[3]. Qing Wang'ta makalesinde yapay sinir ağı kullanarak bir maliyet modeli geliştirmiştir[4]. Günaydın ve Doğan (2004) inşaat sektöründe maliyetlerin tahmin edilmesinde yapay sinir ağları yönteminden faydalanmışlar ve çalışma sonucunda % 93 başarıya ulaşmışlardır[5]. Pendharkar (2006) kaynak kod dökümantasyonunu etkileyen faktörleri yapay sinir ağı tahminleme modeli ve lineer regresyon modeliyle araştırmıştır. Doğrusal olmayan değişkenlerin çoklu girdileri ve çoklu çıktıları arasında ölçek ekonomisinin var olduğu durumlarda yapay sinir ağlarının daha iyi performans gösterdiği görülmüştür[6]. Bir diğer uygulama alanı ise İspanya'daki elektrik üretim piyasasında enerji fiyatlarının tahmini için Box-Jenkins, ARIMA ve ANN modeli kullanılmıştır. Bu makalede ANN modelinde hem çok katmanlı algılayıcı kullanılmıştır[7]. Caputo ve Pelagagge (2008) 'nin araştırmalarında karmaşık tasarımlı ve büyük ölçekli basınçlı kazan üretim maliyetlerinin tahmin edilmesi için YSA ile parametrik yöntemler karşılaştırılmıştır. Kazanın ölçü değişkenliğinin ve konfigürasyonun çok olması, önceki siparişlere benzer özellikteki siparişlere nadir rastlanması imalat maliyetlerinin tahmin edilmesini zorlaştırmaktadır. Parametrik yöntemlerle bulunan hata tahmini %12 iken, YSA yaklaşımı ile bulunan hata yüzdesi %9 olarak bulunmuştur. YSA, parametrik yaklaşıma göre daha iyi sonuçlar vermiştir[8]. Artan rekabet koşulları, şirketleri metal levha sektöründe kısa sürede doğru maliyet tahmini yapacak yeni araçlar bulmaya zorlamıştır. Verinden ve diğerlerinin (2008) çalışmasında regresyon teknikleri ile yapay sinir ağları teknikleri karşılaştırılmış, gözlemlenen sonuçlar YSA'nın daha iyi sonuçlar

verdiğini göstermiştir[9]. Çinko kaplama ile ilgili Rešković ve Glavaš bir çalışma yapmış ve YSA yöntemini tercih etmişlerdir. Girdi faktörleri olarak ise çinko havuz sıcaklığı, bekleme süresi ve et kalınlığını almışlardır[10].


2. YAPAY SİNİR AĞLARI

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri, herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir[11].

Yapay sinir ağı, basit işlem hücrelerinden oluşan, bilgileri depolama ve kullanabilme yeteneğine sahip yoğun paralellikte dağılmış yapıdaki bir işlemcidir. Bu işlemci iki yönden beyin ile benzer özellik gösterir.

1) Bilgi, öğrenme yoluyla çevreden elde edilir.
2) Bilgi depolamak için, sinaptik ağırlıklar olarak ta bilinen nöronlar arasındaki bağlantılar kullanılır[12].
Yapay sinir ağı, biyolojik sinir hücreleri ile ortak performans özelliklerine sahip bir bilgi işleme sistemidir[13,14].

Tipik olarak, Şekil 1’de görüldüğü üzere bir YSA’nın mimarisi (veya yapısı) oluşturulur ve çeşitli transfer fonksiyonları (doğrusal, sigmoid gibi) kullanılarak üretilen çıktılarının doğruluk seviyesinin artırılması için gerekli olan ağırlık değerleri belirlenir. YSA’nın eğitimi sayesinde önceki örnekleri kullanarak ağırlıklar belirlenir, giriş değişkenleri ile tahmin edilen değişkenler arasındaki ilişki ortaya çıkartılır. Ağ eğitildikten sonra, YSA yeni verilerle çalıştırılabilir ve tahminler üretilebilir. Bir ağın performansı, amaçlanan sinyal ve hata kriteri ile ölçülür. Ağın çıktısı, amaçlanan çıktı ile karşılaştırılarak hata payı elde edilir. Geri Yayılma algoritması ile hata payı azaltılması amaçlanır. Bu işlem defalarca tekrar edilerek ağ eğitilir. Eğitime işleminin amacı performans ölçümleri bazında optimum çözüme ulaşmaktır.



Şekil 1. Yapay sinir ağı modeli

Böylece, örnekler geliştirilerek daha önceden görülmemiş örnekler için sonuç üretilmiş olur[15]. Ek olarak matematiksel modele ihtiyaç duyulmaması en

önemli avantajlarından, kendi kendine öğrenme yeteneğine sahiptir[16].

Yapay sinir ağları, tahmin etme[17-19], sınıflama[20-22], görüntü tanıma[23] gibi çok çeşitli alanlarda uygulama olanağı bulmuştur. Bu çalışmada yapay sinir ağı tahmin etme alanında kullanılmıştır.

3. YAPAY SİNİR AĞI KULLANARAK ÇİNKO MİKTARININ BELİRLENMESİ

Ürün kalitesinden ödün vermeden galvanizleme prosesinin en büyük maliyet kalemini oluşturan çinkonun kaplama kalınlığının tahminine yönelik bir model kurulmuş ve elde edilen değerler sonuç kısmında yorumlanmıştır. Sıcak daldırma galvaniz basit anlamda tasarımı ve kimyasal kompozisyonu galvanizlemeye uygun demir ve çelik ürünlerinin ergimiş çinko banyosuna daldırılmasıyla oluşan difüzyon sonucu meydana gelen metalik tepkimeyle oluşan kaplama yöntemidir. Bu kaplama yöntemine olan talep her yıl biraz daha artmaktadır.

Galvanizleme prosesinin adımları özet olarak şu şekilde açıklanabilir.

a-İlk olarak galvanizlemeye uygun olan ya da galvanizleme öncesi hazırlık işlemine tabi tutulan ürünler dik, yatay veya açılı olmak üzere 3 tipte askılama işlemi uygulanabilir.

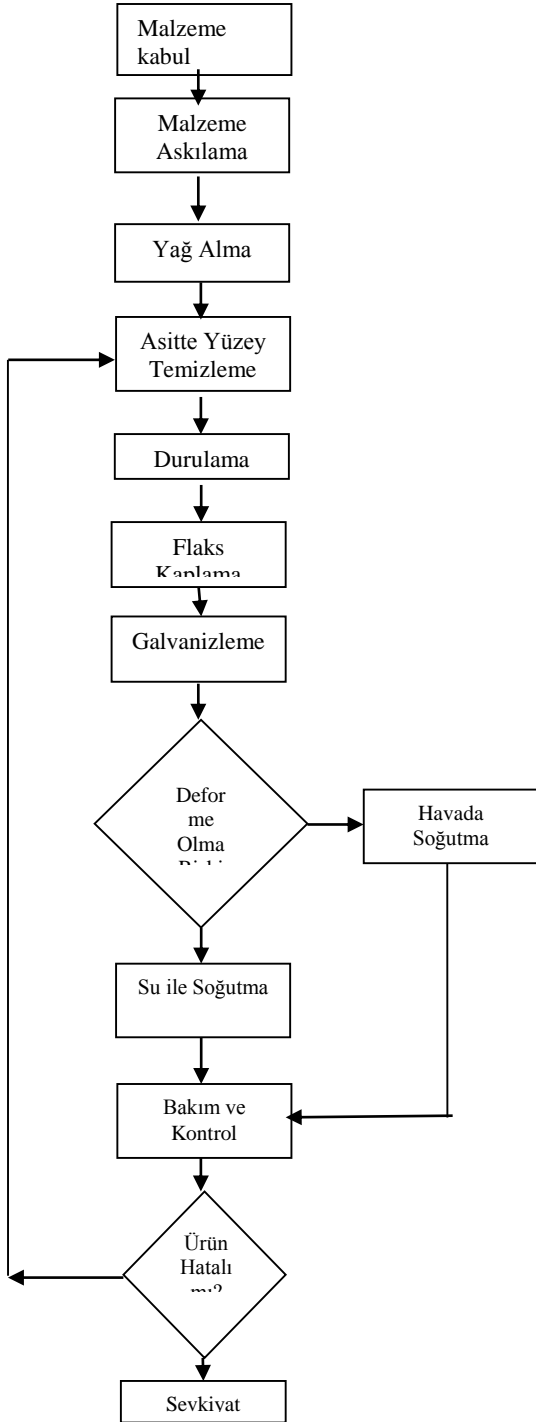
b-Askılanan ürünler üzerlerindeki kirlilik, yağ ve kimyasal artıkların temizlenmesi için alkali havuzuna daldırılır. Banyoda tutma süresi ortalama olarak 3-7 dakikadır ve bu süre malzeme yüzeyinin temizliğine bağlı olarak değişir.

c-Yağ alma havuzlarında ürünlerin sadece yüzeyindeki kolay lekeler temizlenir, ancak ürünlerdeki pası temizlemek için asit havuzlarında işlem görmeleri gereklidir. Bu yüzden %18’lik konsantrasyona sahip HCL asit banyolarına daldırılarak malzeme üzerindeki pas temizleninceye kadar bekletilir. Ürün yüzeyinde pas olmasa bile yüzeyin galvaniz için aktifleşmesi için asit banyolarında tutulur.

d-Asit banyosundan çıkan ürünler su banyosuna daldırılarak durulanır ve ergimiş çinkonun ürün yüzeyine yapışması için 50-70 °C sıcaklıkta %30 NH4Cl-Zn Cl2’den oluşan flaks banyosuna daldırılır.

e-Son olarak ise yüzeyi temizlenmiş ve flaks kaplanmış ürünler 445-465 °C sıcaklıkta “Ocak” denilen ergimiş çinko banyosuna daldırılarak kaplanır. Galvaniz ocağından çıkarılan deforme olabilecek ürünler havada soğutulur, diğer ürünler su banyosunda soğutulur. Proses sonucu galvaniz kaplanan ürünlerin kaplama kalınlıkları dijital mikrometre ile ölçülür. Ölçüm sonuçlarına göre kaplama hataları olan ürünler tamir

edilir veya yeniden işlenir. Varsa çinko akıntıları bir eğe yardımıyla temizlenir. (Şekil 2)



Şekil 2 Proses Akış Diyagramı

Çalışmada yöntem olarak YSA tercih edilmiştir. Bunun en önemli sebebi YSA'ların genelleştirme yeteneklerinin bulunmasıdır. İşletme çok geniş bir ürün

yelpazesine sahiptir ve her ürün için ayrı bir model kurulması imkânsızdır. Çünkü gerekli verilerin toplanması hem zahmetli olacaktır, hem de daha sonra aynı ürünün siparişinin gelmemesi durumu söz konusudur. Bu nedenle gelen herhangi bir çelik malzemenin kaplama kalınlığını verecek bir sisteme ihtiyaç duyulmaktadır. YSA tanımadığı örnekler için de çözüm üretebilme yeteneğine sahiptirler ve bu nedenle bu yöntem tercih edilmiştir. Bunun dışında tahmin etme çalışmalarındaki yüksek başarısı, veriler arasında ki karmaşık ilişkilere cevap verebilmesi, kullanım kolaylığı ve hızı da bu yöntemin kullanılmasının diğer sebepleridir.

a. Kaplama Kalınlığına Etki Eden Faktörler

Bu çalışmada kullanılan ve ürün kaplama kalınlığına etki eden parametreler konuyla ilgili uzmanlar tarafından beyin fırtınası yöntemiyle belirlenmiştir. Bu parametrelerin anlamları ve kurulacak yapay sinir ağı modeline etkisi sırasıyla açıklanmıştır.

1.Ortalama et kalınlığı (OEK): Ortalama et kalınlığı çinko sarfiyatını doğrudan etkileyen faktörlerden ilkidir. Ortalama et kalınlığı artıkça diğer bütün parametrelerin sabit tutulması durumunda kaplama kalınlığı artarken, % Zn sarfiyatı düşmektedir. Ortalama et kalınlığı azaldıkça ise kaplama kalınlığı azalır ve %Zn sarfiyatı artar. Ancak bu artış ve azalışlar sabit bir oranda olmayıp çeliğin cinsine göre değişmektedir.

2.Parça geometrisi: Bu parametrede ölçülmeye çalışılan faktör parçanın sıcak daldırma galvaniz için uygunluk derecesidir. Parça geometrisi toplanan bütün verilerde aynı uzman kişi tarafından 1-10 ölçeğinde takdir edilmiştir. Böylece farklı kişilerin farklı değerlendirmeler yaparak çalışmanın objektifliğini etkilemesinin önüne geçilmiştir. Parça geometrisi değerlendirilirken dikkate alınması gereken alt başlıklar havuza dalış sayısı, patlama riski, parçanın havuzda yüzme durumu ve süzülme kolaylığıdır ve açıklamaları aşağıda yer almaktadır:

- Havuza dalış sayısı: Küçük hacimli sac malzemeler, boyu çok uzun olmayan borular gibi kimi parçalar havuza tek dalış ile kaplanabilirken, hacmi çok büyük profiller gibi kimi malzemeler ise çift dalış gerektirmektedir. Bu ise hem operatörün işini zorlaştırmakta hem de malzemenin askıda geçirdiği süreyi iki katına çıkarmaktadır.

- Patlama riski olan malzemeler: Bu madde sıralanan parametreler içinde en önemliler arasındadır. Doğrudan geometriyle ilişkisiz gibi görünse de galvaniz sektöründe parçanın geometrisinden kaynaklanan sebepler iş güvenliği açısından tehlike yaratmaktadır.

Örneğin birbirine kaynak ile birleştirilmiş 2 sac malzemeyi ele alalım. Birleşim yerlerinde boşluk olması durumunda havuza dalış esnasında patlama riski çok yüksektir. Bu şekilde kapalı hacimli parçalarda kaza riskini sıfırlamak için muhakkak çapraz konumlu “akar delik” denilen delikler açılmalıdır. Bu sayede hava tahliyesi ve çinko akışı sağlanabilir. Alınması gereken diğer bir önlem olarak da vincin havuza dalış hızının ayarlanmasıdır. Bu gruptaki parçaların dalışı esnasında vinç minimum hızına ayarlanmalıdır.

- Parçanın havuz içinde yüzme durumu: Diğer bir zorluk ise radyatör gibi dar hacimli ve yoğunluğu düşük olan, havuza daldırıldığında batmak yerine yüzme eğiliminde olan parçalarda görülmektedir. 2.2 maddesindeki durumun aksine burada deformasyonu önlemek için yapılması gereken vincin hızlı hareket ettirilerek havuza dalış yapılmasıdır. İhtiyaç duyulması halinde parçanın yüzmesinin önüne geçebilmek için daha ağır malzemeler ile birlikte askılama işlemi gerçekleştirilebilir, askılanan parçaların havuzda kalış sürelerinin yakın olması ve hacimlerinin havuza tek seferde sığabilecek büyüklükte olması yeterlidir. Yüzme dışında değerlendirmede dikkat edilmesi gereken diğer bir husus da geniş yüzeyli metallerdeki çarpılma, burulma riskidir.

- Süzülme kolaylığı: Çinko havuzundan çıkan parça askıda bir süre bekletilerek çinkonun akışı, süzülmesi beklenir. Ek işlem (eğe ile çinko akıntılarının temizlenmesi) gerektiren süzülmenin zor gerçekleştiği parçaların geometrisini karmaşık yapıya sayabiliriz. Bu dört faktörün de birlikte değerlendirilmesi sonucu ölçekte 1 numara en basit geometriye sahip ürünü gösterirken, 10 numara ile geometrisi en karmaşık olan ürün ifade edilmektedir.

Bu skalada:

1-3: Düzgün yüzeye sahip, açık ve küçük hacimli, hafif, tek parçalı, girinti çıkıntısı olmayan, hazırlık süresi sıfır ya da çok düşük olan, hiçbir şekilde zarar verilemeyecek parçalardır. Örnek olarak şase, ızgara, profil, tek sac parçalar, kolon, çöp konteynırı, köşebent, kazan vb parçaları gösterebiliriz.

4-7: Üzerinde akar delik bulunmayan ancak kısa sürede ve kolaylıkla delik açılacak, orta hacimde ve ağırlıkta, çok fazla dikkat gerektirmeyen patlamadan ziyade sadece çarpma ve burulma riskine göre askılama işlemi gerektiren parçalardır. Örnek: filtre, korkuluk, boru, metal kasa, beton kalıbı vb.

8-10: Büyük hacimli ve ağır, düzensiz yapı, patlama riski yüksek olan, hazırlık süresi oldukça uzun, çok fazla dikkat gerektiren, üzerinde akar delik açılması zor olan ve uzun süren parçalardır. Bu parçalara radyatörleri, kaynakla birleştirilmiş sac malzemeleri ve kapalı büyük hacimli parçaları örnek verebiliriz.

Bu parametredeki farklılıklar nihai ürün kalitesini direkt olarak etkilediğinden ve eğer arzulanan kalite elde

edilemezse yeniden işlemeye gerek duyulacağından ve bu da çinko sarfını arttıracığından modelde yer almıştır.

3.Parçanın pürüzlülük derecesi: Malzeme yüzeyindeki pasın neden olduğu girinti çıkıntı durumunun derecesidir. Yüzey pürüzlülüğü asit havuzunda giderilmeye çalışılan bir faktördür. Ancak parçanın asitte deforme olmaması için havuz içerisinde sadece belirli bir süre tutulabilir. Bu nedenle bazı malzemeler asit havuzundan çıktıktan sonra bile pürüzlü kalabilir. Bu parametre de nihai ürünün kalitesini etkiler. Yüzeydeki pürüzlülük arttıkça çinko parçaya daha kolay tutunabileceğinden % Zn sarfiyatı da artacaktır. Derecelendirme için kirlilik parametresi ile aynı olan 1-3 skalası yeterli görülmüştür.

1: Hiç pürüzsüz yüzeyler

2: Pürüzlü ancak asit havuzunda bu problemin giderilebileceği yüzeyler

3: Çok pürüzlü, paslı parçalar. Bu probleme malzemenin kendi yapısının sebep olabileceği gibi imalat sırasında oluşan hadde bozuklukları, çizilmeler vb. de sebep olabilir.

Yüzey durumunun derecelendirilmesi işleminin malzeme kabulünden hemen sonra yapılması sağlıklı olmayacağından flaks banyosunun hemen ardından yüzey pürüzlülük derecesinin belirlenmesi istenmiştir. Çünkü çıplak gözle yüzeyinin kusursuz olduğunu düşündüğümüz bir parçanın asit havuzundan çıktığında aslında kusurlu olan yapısı ortaya çıkabilir. Gerçekten yüzeyi pürüzsüz olan bir parça da asit ya da flaks havuzunda deforme olup yüzeyi bozulabilir ve çinko sarfı artar. Aksi durum da mümkündür. Yani çok pürüzlü bir parça asit havuzu çıkışında pürüzsüz hale gelebilir.

4.Asit banyosu sıcaklığı: Asit banyosunda kimyasal açıdan en önemli olan faktör sıcaklıktır.

5.Malzemenin asitte bekleme süresi: Asitte bekleme süresi ise malzeme pürüzlülüğü derecesinin bir fonksiyonu olarak düşünülebilir ve bu değere göre değişkenlik gösterir.

6.Flaks banyosu değerleri: Asit banyosunda sadece sıcaklık değerleri ölçülürken, flaks banyosunda ise pH değeri ölçülmektedir.


7.Çinko banyosunun sıcaklığı: Çinko banyosunda çeliğin türüne göre belirli bir değere kadar sıcaklık arttıkça kaplama kalınlığı da artmakta; o değere ulaştıktan sonra azalmaya başlamaktadır.

8.Çinko banyosunda bekleme süresi: Çinko havuzunda bekleme süresi kalınlığa etki eden en önemli faktörlerden biridir.

9. Askılama tipi: Askılama işlemi ürün üzerine delik açılarak ya da mapa kaynatılarak yapılır. Ürünler ağırlık merkezine göre 3 tipte askılama işlemine tabi tutulur. Aksi takdirde ürün kendi ağırlığından dolayı deforme olabilir. Askılama tipinde etkili olan diğer faktörler de havuz boyutları ve süzülme kolaylığıdır.

a) Dik askılama işlemi: Parçalar askıya dik şekilde yerleştirilir. Çinko akışının en kolay olduğu askılama tipidir. Havuzdan çıkan parça üzerinden çinko kolaylıkla ve kısa sürede süzülür. Bu nedenle bu tipte askılama işlemi modelde 1 değeri ile ifade edilir.

b) Açılı askılama işlemi: Şekil 3'de görüldüğü üzere parçalar askıyla belirli bir açı yapacak şekilde yerleştirilirler. Modelde süzülme kolaylığına bakılarak 2 değeri ile ifade edilir.



Şekil 3. Açılı askılama işlemi

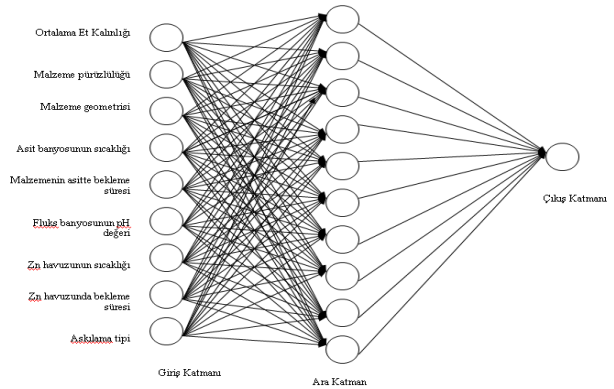
c) Yan askılama işlemi: Parçalar askıya paralel şekilde yerleştirilir. Süzülmenin en zor olduğu ve en fazla zaman aldığı göz önünde bulundurularak modelde 3 değeri ile temsil edilmiştir.

Kaplama kalınlığı 45 ile 288 mikron arasında değişen farklı numunelerden veriler rassal zaman aralıklarında işletmeye gidilerek işletme şefi ile birlikte sistematik şekilde toplanmıştır. Bu verileri toplamak üzere işletmede yeni bir veri takip formu oluşturulmuştur. Toplamda doldurulan form sayısı 230'dur. Verileri en genel şekilde 2 grupta toplayabiliriz: sayısal ve sözel veriler. Sayısal olan veriler direk ölçüm yoluyla elde ettiğimiz nicel değerlerdir. Sayısal veri grubu OEK, banyo sıcaklığı, banyolarda bekleme süreleri, banyo bileşimleri(pH, demir oranı, bome değeri) ve kaplama kalınlığıdır. Sözel veriler ise uzman görüşü yardımıyla sınıflara ayrılmış ve her grubu temsil eden bir sayısal değer belirlenerek bu verilerin nicel hale gelmesi sağlanmıştır. Her vardiyada aynı uzman tarafından veriler yorumlanarak çalışmada objektif bir değerlendirme sağlanmıştır. Bu veriler ise fiziksel kalite derecesi, parça geometrisi ve yüzey durumu, çinko havuzunun kirlilik derecesi, askılama açısıdır.

b. YSA Mimarisinin Kurulması

Modelde değişken sayısının çok olması, değişkenlerin birbirleriyle olan ilişkileri, bu ilişkilerin hangi dağılıma ve fonksiyona uygunluk gösterdiği gibi sebepler çoklu doğrusal regresyon modelinin sağlıklı sonuçlar vermesine engel teşkil ettiğinden çözümde YSA yöntemi kullanılmıştır. Uygulamada kullanılan bağımsız değişkenler OEK, askılama tipi, parça geometrisi, kirlilik derecesi, pürüzlülük derecesi, yağ banyosunun sıcaklığı, pH'ı ve süresi, asit banyosunun sıcaklığı, bomesi (gr/lt) ve süresi, flaksın sıcaklığı, pH'ı, bomesi, demir oranı(gr/lt) ve süresi, çinko banyosu sıcaklığı, süresi ve havuz kirlilik derecesidir. Toplanan diğer beş veri türü ise tamamlayıcı bilgi niteliğindeki ölçüm numarası, tarih, parti numarası, müşteri firma ve malzeme cinsi olup sayısal modelde yer almamıştır.

Modelleme yapısı geri yayılım ileri beslemeli (Back-Propagation) yapay sinir ağıdır. Bu ağın tercih edilme sebebi kullanımının kolay olması, üretimde tahmin çalışmalarında en çok kullanılan model olması ve doğrusal olmayan modellerdeki yüksek tahmin etme başarısıdır. Verilerin program tarafından işleme girmeden önce normalizasyonu gerçekleştirilmiş, veriler [0,1] aralığına indirgenmiştir. Daha sonra verilerin eğitimi ve testi için veriler ikiye bölünmüştür. 230 verinin 43'ü test verisi olarak belirlenmiştir. Uygulamadaki bağımlı değişken ürünün kaplama kalınlığıdır ve ağ mimarileri Şekil 4'de gösterilmiştir.




Şekil 4. YSA mimarisi

Kaplama kalınlığı için kurulan model; 9 girdi değişkenli, tek ara katmanı olan, tek çıktıya sahip ileri beslemeli geri yayılım ağıdır (Şekil 5). Ara katmandaki işlemci eleman sayısı için çok sayıda deneme yapılarak en uygun değer 10 olarak belirlenmiştir.

Toplama fonksiyonu modelde de işlemci elemanların birleştirme fonksiyonu, ara katmandaki ve çıktı katmanındaki transfer fonksiyonları hiperbolik tanjant ve performans fonksiyonu da Hataların Kareli

Ortalaması (Mean Squared Errors, MSE) olarak belirlenmiştir.

Modelde kullanılacak fonksiyonlar seçildikten sonra model eğitilmiştir. Bunun için başlangıç ağırlık değerleri program tarafından rassal olarak atanmıştır. Eğitim için 100 iterasyon kullanılmıştır.



Şekil 5 Kaplama kalınlığı için ağ yapısı

c. Modelin Sonuçları

Tahmin edilen değerlerin gerçekleşen değerlere ne kadar yaklaştığını ölçmek için, aralarındaki sapma $e(t) = x(t) - f(t)$ şeklinde hesaplanır. Kullanılabilecek diğer bir ölçüt ise hata yüzdesi $p(t) = e(t) / x(t)$ 'dir. Doğruluk ölçütleri ve formülleri Tablo 1'de gösterilmiştir.

Tablo 1. Doğruluk ölçütleri ve formülleri


$ME = \frac{1}{n} \sum e(t)$	Ortalama Hata
$MSE = \frac{1}{n} \sum [e(t)]^2$	Hataların Kareli Ortalaması (MSE),
$RMSE = \sqrt{\frac{1}{n} \sum [e(t)]^2}$	Hataların Kareli Ortalaması Karekökü (RMSE)
$MAE = \frac{1}{n} \sum e(t) $	Ortalama Mutlak Hata (MAE)
$MPE = \frac{1}{n} \sum p(t)$	Ortalama Yüzde Hata (MPE),
$MSPE = \frac{1}{n} \sum [p(t)]^2$	Ortalama Yüzde Hata Kareleri (MSPE)
$RMSPE = \sqrt{\frac{1}{n} \sum [p(t)]^2}$	Ortalama Yüzde Hata Kareleri Kökü (RMSPE)
$MAPE = \frac{1}{n} \sum p(t) $	Ortalama Mutlak Yüzde Hata (MAPE)

Önerilen model için hesaplanan yüzde doğruluk değerleri aşağıdaki gibidir. (Tablo 2)

Tablo 2. Yüzde Doğruluk Ölçüt Değerleri

	MPE	MSPE	RMSPE	MAPE
Kaplama Kalınlığı Modeli	-0,0827	0,059544	0,244017	0,170922

Alınan örneklerin her biri için gerçek ve tahmin değerleri arasındaki sapma grafik üzerinde gözlemlenebilmektedir. (Şekil 6)



Şekil 6. Gerçek değerlerle tahmin değerlerinin karşılaştırılması

d. İstatistiksel Analiz

Yapay sinir ağından elde edilen değerler ile gerçek değerler arasında anlamlı fark bulunup bulunmadığını ölçmek için hipotez testi yapılmıştır. Bu karşılaştırmayı yapabilmek için gerekli formüller ve elde edilen değerler sırasıyla Tablo 3 ve Tablo 4'de verilmiştir.

Tablo 3. Büyük örnekler için Z testi

Boş Hipotez	$H_0: \mu_1 - \mu_2 = \text{Boş Hipotez}$
Test İstatistiği	$z = \frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$
Alternatif Hipotez	Red Alanı
$H_a: \mu_1 - \mu_2 > \text{Boş Hipotez}$	eğer $z > z$ kritik değer H_0 red (sağ kuyruk testi)
$H_a: \mu_1 - \mu_2 < \text{Boş Hipotez}$	eğer $-z < -z$ kritik değer H_0 red (sol kuyruk testi)
$H_a: \mu_1 - \mu_2 \neq \text{Boş Hipotez}$	Eğer $z > z$ kritik değer veya $-z < -z$ kritik değer H_0 red

Tablo 4. Kaplama kalınlığı için örnek değerleri

	Ortalama değer	Standart sapma
Gerçek değerler	85,458	40,16832
Tahmin değerleri	84,81288	23,61217

Kaplama için test istatistiğinin hesaplaması;

$$H_0 = \mu_1 - \mu_2 = 0$$

$$H_a = \mu_1 - \mu_2 \neq 0$$

$$z = ((\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)) / \sqrt{(s_1^2/n_1) + (s_2^2/n_2)} = 0,097902$$

%95 Güven aralığında H_0 kabul edilir. Bu durum, istatistiksel anlamda gerçek verilerin ve tahmin edilen verilerin arasında anlamlı bir fark olmadığını, her iki örnek grubunun aynı yığından geldiğini; dolayısıyla tahmin edilen verilerin gerçek verileri temsil edebilecek yeterlilikte olduğunu göstermektedir.

4. SONUÇ

Yapay sinir ağları yöntemi günümüzde pek çok alanda uygulanmakta ve tahmin modellerinde de başarılı sonuçlar elde edilmektedir. YSA kullanımının kolay olması, esnekliği, hızlı ve başarılı sonuçlar elde etme yeteneğinden dolayı çalışmada bu yöntem tercih edilmiştir.

Galvaniz sektöründe çinko sarfıyatı en önemli maliyet kalemleri arasındadır. Bu yüzden bu sektörde kullanılacak çinko miktarının en az olması gerekmektedir, ancak kalite açısından bakıldığında belli bir değer altında olması durumunda galvaniz kaplamadan beklenen fonksiyonları sağlamadığı da görülmektedir. Bu hedef değer in özn el değ erlendirmeler yerine bilimsel bir yöntemle belirlenmesi gereklidir. Bu eksikliğin giderilmesi amacıyla birçok uygulama alanı olan YSA uygun bir yöntem olarak kullanılmıştır. YSA modelinin giriş parametrelerinin belirlenmesi amacıyla uzman kişilerin görüşlerinden yararlanılmıştır. Çinko kalınlığına etki eden dokuz parametre belirlenmiştir. Kalite ve maliyet açısından istenilen hedef değerler çoklu regresyon ve yapay sinir ağıyla tahmin edilmiştir. Çoklu regresyon modeliyle elde edilen sonuçlar çok düşük performansla çalıştığı, YSA modelinin ise işletme için kullanılabilir sonuçlar elde ettiği görülmüştür. YSA'dan elde edilen sonuçlara göre, gerçek değerler ve tahmini değerler arasındaki farklar hipotez testiyle istatistiksel olarak karşılaştırılmış ve %95 güven aralığında iki değer arasında anlamlı bir fark olmadığı ortaya konmuştur.

KAYNAKLAR

- [1] ZHANG, Y.F., Fuh, J.Y.H., A Neural Network Approach For Early Cost Estimation Of Packaging Products, Computers ind.Engng, 34(2), 433-450, 1998.
- [2] KERMANSHAHI, B., IWAMIYA, H., Up to year 2020 load forecasting using neural nets, Electrical power and energy systems, 24, 789-797, 2002.
- [3] CAVALIERI, S., MACCARRONE, P., PINTO, R., Parametric vs. neural network models for the estimation of production costs: A case study in the automotive industry, Int. J. Production Economics, 91, 165-177, 2004.
- [4] WANG, Q., Artificial neural networks as cost engineering methods in a collaborative manufacturing environment, Int. J. Production Economics, 109, 53-64, 2007.
- [5] GUNAYDIN, H.M., DOGAN, S.Z., A neural network approach for early cost estimation of structural systems of buildings, International Journal of Project Management, 22, 595-602, 2004.
- [6] PARAG C. PENDHARKAR, Scale economies and production function estimation for object-oriented software component and source code documentation size, European Journal of Operational Research, 172, 1040-1050, 2006.
- [7] PİNO, R., PARRENO, J., GOMEZ, A., Priore, P., Forecasting next-day price of electricity in the Spanish energy market using artificial neural Networks, Engineering Applications of Artificial Intelligence, 21, 53-62, 2008.
- [8] CAPUTO, A.C., PELAGAGGE, P.M., Parametric and neural methods for cost estimation of process vessels, Int. J. Production Economics, 112, 934-954, 2008.
- [9] VERLINDEN, B., Duflo, J.R., Collin, P., Cattrysse, D., Cost estimation for sheet metal parts using multiple regression and artificial neural networks: A case study, Int. J. Production Economics, 111, 484-492, 2008.
- [10] RESKOVIC S., GLAVAS Z., The Application Of An Artificial Neural Network For Determining The Influence Of The Parameters For The Deposition Of A Zinc Coating On Steel Tubes, Material In Tehnologije, 43(4), 201-205, 2009.
- [11] ÖZTEMEL, E., Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul, 2006.
- [12] HAYKIN, S., Neural Network a Comprehensive Foundation, MacMillan College Publishing, New Jersey, 1999.

- [13] FAUSETT, L., Fundamentals of Neural Networks Architectures, Algorithms, and Applications, Prentice-Hall, New Jersey, 1994.
- [14] NABIYEV, V., Yapay Zeka Problemler-Yöntemler-Algoritma, Seçkin Yayıncılık, Ankara, 2005.
- [15] TAEHO Jo, The effect of mid-term estimation on back propagation for time series prediction, Neural Computing and Applications, 19, 1237-1250, 2010.
- [16] GRAUPE, D., Principles of Artificial Neural Networks (2nd Edition), World Scientific, 2007.
- [17] BADRI, A., AMELI, Z., BIRJANDI, A.M., Application of Artificial Neural Networks and Fuzzy logic Methods for Short Term Load Forecasting, Energy Procedia, 14, 1883–1888, 2012.
- [18] GUO, Z., ZHAO, W., LU, H., WANG, J., Multi-step forecasting for wind speed using a modified EMD-based artificial neural network model, Renewable Energy, 37(1), 241–249, 2012.
- [19] ABHISHEK, K., SINGHA, M.P., GHOSH, S., ANAND, A., Weather forecasting model using Artificial Neural Network, Procedia Technology 4, 311 – 318, 2212-0173, 2012.
- [20] DEHURI, S., ROY, R., CHO, S., Ghosh, A., An improved swarm optimized functional link artificial neural network (ISO-FLANN) for classification, The Journal of Systems and Software, 85, 1333– 1345, 2012.
- [21] GHIASSI, M., OLSCHIMKE, M., MOON, B., ARNAUDO, P., Automated text classification using a dynamic artificial neural network model, Expert Systems with Applications, 39(12), 10967–10976, 2012.
- [22] RAEESI, M., MORADZADEH, A., ARDEJANI, F.D., RAHIMI, M., Classification and identification of hydrocarbon reservoir lithofacies and their heterogeneity using seismic attributes, logs data and artificial neural networks, Journal of Petroleum Science and Engineering, Volumes 82–83, 151–165, 2012.
- [23] EL-MiDANY, T.T., EL-BAZ, M.A., ABD-ELWAHED, M.S., A proposed framework for control chart pattern recognition in multivariate process using artificial neural networks Expert Systems with Applications, 37, 1035–104, 2010.

