

TERMOPLASTİK ÜRÜNLERİN YENİ ÜRÜN DEVREYE ALMA SÜRECİNDE BİR YAPAY ZEKA YAKLAŞIMI

*Ahmet AKYÜREK**

*Akın KEÇE***

*Aslı AKSOY**

*Nursel ÖZTÜRK**

Özet: Plastik ürünlerin imalatında çok değişik yöntemler kullanılmakla birlikte en yaygın yöntem enjeksiyonla kalıplama yöntemidir. Enjeksiyonla kalıplama sürecinde çok sayıda ve aralarında karmaşık ilişkilerin olduğu parametrelerle performans göstergesinin olması, sürecin karmaşıklığını arttırmakta ve bu parametreler çıkan ürünün kalitesini önemli derecede etkilemektedir. Bundan dolayı plastik enjeksiyonda çıkan ürünün kalitesi için uygun proses parametrelerinin seçimi çok önemlidir. Bu nedenle plastik enjeksiyon yeni ürün devreye alma sürecinde ileri tekniklere gereksinim vardır. Bu çalışmada, uzman insana bağımlılığı ve maliyetleri azaltarak yeni ürün devreye alma sürecinde yüksek kalitede termoplastik ürünlerin üretilebilmesi amacıyla bir yapay zeka yaklaşımı kullanılmıştır.

Anahtar Kelimeler: Plastik enjeksiyon yöntemi, Yeni ürün devreye alma süreci, Yapay zeka.

An Artificial Intelligence Approach at the First Approval Process of Thermoplastics

Abstract: Although there are several methods in the manufacture of plastic products, injection molding is the most widespread method. There are many process parameters that increase the complexity of the molding process and the quality of molded parts are mostly influenced by these process parameters during molding process. The selection of appropriate process parameters for the injection molding operation is becoming more important to produce high quality products due to complexity of the molding process. Therefore, advanced approaches are required to model the injection molding at first approval process. In this research, artificial intelligence approach is presented to model the injection molding process with the goal of manufacturing high quality plastic parts through a cost effective approach by reducing dependency on human expertise.

Key Words: Plastic injection method, First part approval process, Artificial intelligence.

1. GİRİŞ

Son yıllarda, otomotiv, mikro-elektro-mekanik sistemler, bilgi işlem, medikal, optik ve telekomünikasyon gibi çeşitli endüstrilerde termoplastik ürünlerin kullanımındaki artış, bu endüstrilerde kaliteli ürünlerin hızlı üretim gereksinimini de beraberinde getirmiştir (Chen ve diğ. 2005, Pramujati ve diğ. 2006).

Termoplastikler, belirli bir sıcaklık ve basınç altında akışkan hale gelebilen, soğutulduğunda sertleşip içinde bulunduğu kalıbın şeklini alabilen polimer yapılarıdır. Termoplastiklere sıcaklık ve basınç altında defalarca şekil vermek mümkün olduğundan, geri dönüşüm yoluyla tekrar tekrar kullanılmak da mümkün olabilmektedir. Şekil alıp sertleştikten sonra, tekrar ısıtıldığında yeniden yumuşamayan plastiklerden olan termosetlere karşı, termoplastiklerin birçok endüstride önemli bir yeri vardır. Termoplastiklerin biçimlendirilmesinde enjeksiyonla kalıplama tercih edilir (Chang ve diğ. 2007, Kalima ve diğ. 2007, Saleem ve diğ. 2008).

* Uludağ Üniversitesi, Mühendislik-Mimarlık Fakültesi, Endüstri Mühendisliği Bölümü, 16059, Görükle, Bursa.

** Plaskar Plastik Enjeksiyon Oto. Ltd. Şti. Kayapa Sanayi Bölgesi, Bursa.

Plastik enjeksiyon, termoplastik malzemenin belirli bir ısı altında ve sürtünme vasıtasıyla akışkan hale getirilip, basınç uygulanarak kalıp içinde şekillendirilmesi ile olur. Hammaddenin tek bir işlemle istenen şekilde kalıplanabilmesini sağlaması ve birçok durumda imal edilen ürün için son işlem uygulamaları gerektirmemesi bu yöntemi, diğer plastik malzeme biçimlendirme tekniklerine (basınçlı kalıplama, döner kalıplama, basınçta ısı ile biçimlendirme, şişirme) göre seri üretim için oldukça uygun hale getirmiştir (Akyüz, 2001).

Plastik enjeksiyon süreci ile ilgili makine parametreleri, makine karakteristikleri, ortam sıcaklığı ve malzeme özelliklerinde yaşanan değişimler, çıkan ürünün kalitesini etkilemektedir (Keçe, 2006). Plastik enjeksiyon yöntemi ile ilgili olarak karşılaşılan en önemli problemlerden biri yeni ürün devreye alma sürecinin oldukça uzun olması ve tamamen ilgili operatör veya formenin bilgi, tecrübe ve yeteneğine göre değişmesidir. Yani bu süreç direkt olarak insana bağımlı bir süreçtir. Yeni ürün devreye alma sürecinin uzunluğu, iş gücü, makine ve malzeme maliyetlerinden dolayı ciddi bir maliyet kalemi olarak toplam üretim maliyetlerini etkilemektedir. Plastik enjeksiyon yöntemi ile üretim yapan bir çok işletme, bu süreci en kısa hale getirmek ve katlanılan maliyetleri en düşük seviyeye çekmek amacıyla, ürünün makinedeki ilk üretimlerini tecrübeli operatörler kullanarak gerçekleştirmek istemektedirler. Operatörün makineye girdiği ilgili parametre değerleri, uygun parça üretimi için gerekli değerlere ne kadar yakın olursa bu süreç de o kadar kısalmaktadır. Optimum değerlere, makineden ürün alınmaya başlandıktan sonra deneme yanılma yolu kullanılarak ulaşılmaya çalışılmaktadır.

Bu çalışmada, termoplastik ürünlerin yeni ürün devreye alma sürecinde, insan unsuru ve deneme yanılmaları optimum değerlere ulaşma çabaları yerine, zaman, malzeme, makine kullanım ve işgücü maliyetlerinde önemli azalmalar elde etme amacıyla Yapay Zeka tekniklerinden Yapay Sinir Ağları (YSA) ve Uzman Sistem (US) kullanılmıştır. Yapay sinir ağının tasarımında, makine ve ürüne ait olan 9 adet parametre girdi değişkenleri olarak, üründen elde edilen 8 adet gösterge de çıktı değişkenleri olarak tespit edilmiştir. Yapay sinir ağı, otomotiv yan sanayi firmasından toplanan 100 adet eğitim ve 60 adet doğrulama verisiyle eğitilmiş ve test edilmiştir. Oluşturulan ağ yapısı ve ilgili parametrelerin ne olması gerektiğine karar verebilmek için (gizli katman sayısı, her bir katmandaki nöron sayısı, öğrenme oranı ve momentum) 175 adet deney yapılmıştır. Ağ yapısının tespit edilmesi çalışmasında hedef hata değeri 0,001 olarak öngörülmüştür ve her bir deney için hata değeri gözlenmiştir. Deneyler sonucunda, birinci gizli katmanında 6, ikinci gizli katmanında 5 nöron bulunan iki gizli katmanlı ağ yapısına ulaşılmıştır. Çalışmanın ikinci kısmında YSA'dan alınan çıktı değerlerine göre kullanıcıya öneriler sunabilme yeteneğine sahip uzman sistem tasarımı yapılmıştır. Sistem, otomotiv yan sanayinden alınan örnek parçalarla test edilmiştir. Çalışmada kullanılan yapay zeka yaklaşımı ile, termoplastik ürünlerin yeni ürün devreye alma sürecinde, zamanda ve toplam maliyetlerde elde edilecek önemli azalmalarla rekabet üstünlüğünün de artacağı düşünülmektedir.

2. PLASTİK ENJEKSİYON SÜRECİNDE YAPAY ZEKA TEKNİKLERİNİN KULLANIMI

Son yıllarda, çeşitli endüstrilerde önemli malzeme haline gelen termoplastikler ile plastik enjeksiyon sürecine oluşan ilgi, bu alanda yapay zeka tekniklerinin kullanımını da gündeme getirmiştir.

Plastik enjeksiyon sürecinde çok sayıda parametre ve performans göstergesinin rol almasından ve bunlar arasında bulunan karmaşık ilişkilerden dolayı sürecin klasik matematiksel optimizasyon teknikleri ile modellenmesi oldukça zordur. Modelleme ancak bazı parametreler göz ardı edilerek ve mevcut olan kısıtların bir kısmı dikkate alınmayarak mümkün olmaktadır. Dolayısıyla bu esneklik ile oluşturulan modellerden elde edilen sonuçlar yeterince gerçekçi olmamaktadır.

Lau ve diğ. (2001), enjeksiyonla şekil verilmiş parçaların ölçüsel kalitesinin geliştirilmesi için şekil verme parametrelerinin değişiminde ters süreç modelleme konseptine dayanan sinirsel ağ kullanımını önermişlerdir. Sinirsel ağın giriş ve çıkış değerlerinin haritalanması ile ağ, ölçüsel sonuç değerleri ile buna karşılık gelen şekil verme parametreleri arasındaki korelasyonu öğrenmiştir. Oluşturulan model, enjeksiyon süresi ve soğuma sıcaklığı gibi proses parametrelerini belirleyerek, enjeksiyon ile şekil verilecek olan parçaların ölçüsel olarak iyileşmesine katkı sağlamıştır.

Shi ve diğ. (2003), plastik enjeksiyon şekil verme prosesinin optimizasyonu için hibrit bir strateji geliştirmişlerdir. Optimizasyon için kullandıkları hibrit strateji, nümerik simülasyon yazılımını, genetik algoritmayı ve çok katmanlı sinirsel ağı içermektedir.

Kurtaran ve diğ. (2005), çalışmalarında otobüs tavan lambaları için minimum eğriliğe ulaşılabilmesi amacıyla, enjeksiyonla kalıplama proses parametrelerinin optimum değerlerini belirlemişlerdir. Oluşturdukları eğrilik önleyici model, sonlu eleman analizi sonuçlarına dayanarak oluşturulan ileri beslemeli yapay sinir ağı ile yaratılmıştır. Sinirsel ağ modeli, genetik algoritma ile etkili bir arayüz oluşturarak optimum proses parametre değerlerinin bulunmasını sağlamıştır.

Changyu ve diğ. (2006), çalışmalarında plastik ürün üretiminde enjeksiyonla şekil vermenin en yaygın kullanılan proses olduğunu ifade etmişlerdir ve enjeksiyon ile şekil verilen parçaların kalitesinin proses koşullarından etkilendiğini vurgulamışlardır. Parça kalitesini geliştirmek için optimum proses koşullarına erişmenin anahtar olduğunu kabul etmişlerdir. Enjeksiyonla şekil verme prosesinin optimize edilmesi için yapay sinir ağları/genetik algoritma kombinasyonundan oluşan bir yöntem kullanmışlardır. Bu yöntemde, geriye yayımlı yapay sinir ağı modeli parçaların kalite indeksleri ve proses koşulları arasındaki doğrusal olmayan karmaşık ilişkileri haritalamak için geliştirilmiştir. Genetik algoritma ise proses koşullarının optimizasyonu için uygun bir fonksiyon elde edilmesinde kullanılmıştır. Sonuçlar YSA/GA yönteminin enjeksiyon sürecinin optimizasyonunda etkili bir araç olduğunu göstermiştir.

Öktem ve diğ. (2006), çalışmalarında, minimum yüzey sertliğine ulaşabilmek için kesme hızı, besleme miktarı, aksenal ve radyal kesme derinlikleri ve makine toleransından oluşan kesme parametrelerinin tespiti için sinirsel ağlar ve genetik algoritma kullanmışlardır. Genetik algoritma ve sinir ağı hiçbir kısıt olmaksızın minimum yüzey sertliğinin elde edilmesi için optimum kesme parametrelerini tespit edebilmiştir. Yöntemden elde edilen değerler ile deneylerden alınan ölçümlerin birbirine çok yakın olduğu görülmüştür.

Özçelik ve Erzurumlu (2006), plastik enjeksiyon şekil verme endüstrisi için günümüzün rekabetçi şartlarında minimum eğrilik ve leke gibi yüksek kalite özellikleriyle daha hızlı ve ucuz üretim yapmanın zorunlu hale geldiğini belirtmektedirler. Çalışmada, ANOVA, genetik algoritma ve sinirsel ağlar kullanılmıştır.

Zhu ve Chen (2006), çalışmalarında enjeksiyon hızı, erime sıcaklığı ve tutma basıncı parametrelerini kullanarak enjeksiyon şekil verme operasyonlarındaki parlamaı önceden görebilmek için bulanık sinir ağı kullanmışlardır. Veriler bulanık sinir ağı algoritması ile analiz edilmiş ve çoklu regresyon modeli oluşturulmuştur.

Karataş ve diğ. (2007), yaygın olarak kullanılan ticari plastiklerin plastik şekil verme prosesindeki akış uzunluğunun belirlenebilmesi için yapay sinir ağları ile çeşitli enjeksiyon parametrelerini esas alan yeni bir formül geliştirmişlerdir. Yaptıkları çalışmada öncelikle çeşitli enjeksiyon parametrelerinde plastiklerin akış özelliklerini araştırmışlardır. Daha sonra ise, ticari plastiklerin çeşitli enjeksiyon parametrelerine dayanan kalıpta akış uzunluklarını deneysel veriler kullanılarak yapay sinir ağları ile tanımlamış ve incelemişlerdir. Yaptıkları çalışma ile optimum çözüme ve basit modelleme programlarından kolaylıkla elde edilemeyecek bazı sonuçlara ulaşmak için gerekli zaman ihtiyacının önemli ölçüde azaldığını tespit etmişlerdir.

3. TERMOPLASTİK ÜRÜNLERİN YENİ ÜRÜN DEVREYE ALMA SÜRECİNDE BİR YAPAY ZEKA YAKLAŞIMI

Bu çalışmada oluşturulan yapay zeka yaklaşımı, termoplastik ürünlerin üretiminde yeni ürün devreye alma süresini kısaltmak, operatör veya usta bağımlı durumdan kurtulmak, toplam maliyetlerini azaltmak isteyen işletmeler için uygun bir çözüm olacaktır.

Çalışmanın ilk kısmı olan plastik enjeksiyon sürecinde uygun olmayan parçaların yapay sinir ağları ile tespiti işleminde aşağıdaki adımlar izlenmiştir:

- Adım 1: Sinirsel ağın tasarımı
- Adım 2: Sinirsel ağın eğitilmesi
- Adım 3: Sinirsel ağın test edilmesi

Yapay Sinir Ağının Tasarımı

Bu çalışmada yapay sinir ağının tasarımında kullanılacak, literatürde tanımlanmış kriterler incelenmiş ve plastik enjeksiyon yöntemi ile parçalar üreten otomotiv yan sanayii firması ile yapılan görüşmeler sonucunda dokuz adet girdi belirlenmiştir. Ayrıca girdiler belirlenirken, bu girdilerin, hem parçanın hammadde ile ilgili özellikleri hem de parçanın işlendiği makinenin parametrelerini yansıtmasına ve temsil etmesine dikkat edilmiştir. Yapay sinir ağında kullanılan girdiler;

1. Parça gramajı
2. Yoğunluk
3. Hammadde erime sıcaklığı
4. Parça et kalınlığı
5. Enjeksiyon süresi
6. Ütuleme mesafesi
7. Ütuleme süresi
8. Soğuma zamanı
9. Mal alma mesafesi

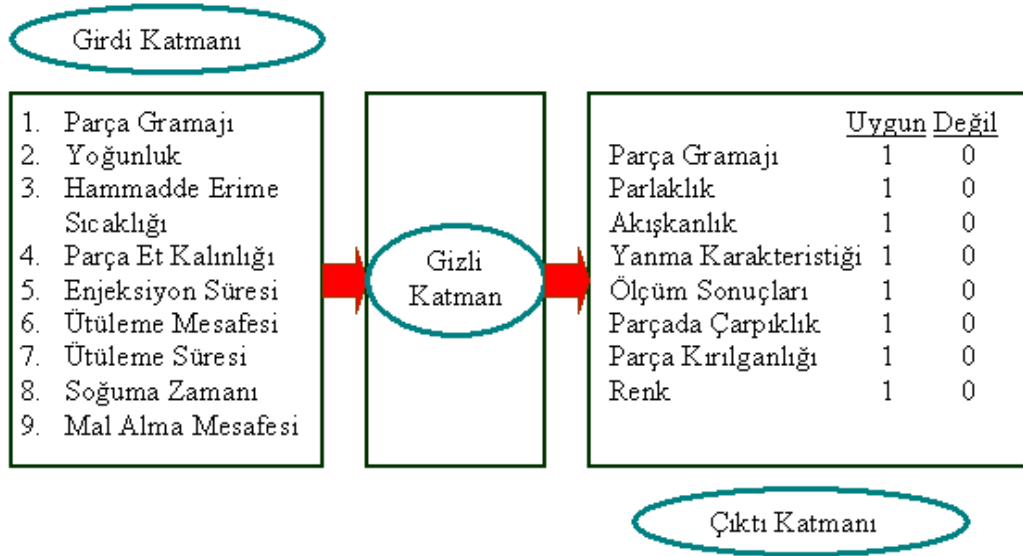
Çalışmada kullanılan parça gramajı, yoğunluk, hammadde erime sıcaklığı ve parça et kalınlığı girdileri, doğrudan üretilen ürünün kendisi ile ilgiliyken; enjeksiyon süresi, ütuleme mesafesi, ütuleme süresi, soğuma zamanı ve mal alma mesafesi girdileri ise plastik enjeksiyon makinesini temsil etmektedir.

Çıktı özellikleri Yapay Sinir Ağlarının amacına ve girdilere uygun olarak tanımlanmalıdır. Bu çalışmada, tanımlanmış dokuz girdiye karşılık, sekiz adet çıktı özelliği belirlenmiştir. Bu çıktılar ağa sunulan girdilere göre “1” ya da “0” değerini almaktadır. Eğer çıktı “1” değerini alırsa bu, parçanın o çıktı özelliği bakımından uygun olduğunu, eğer çıktı “0” değerini alırsa bu da parçanın o çıktı özelliği bakımından uygun olmadığını göstermektedir. Yapay sinir ağında kullanılan girdiler için oluşturulan çıktılar;

1. Parça gramajı
2. Parlaklık
3. Akışkanlık
4. Yanma karakteristiği
5. Ölçüm sonuçları
6. Parçada çarpıklık
7. Parça kırılabilirliği
8. Renk

olarak belirlenmiştir. Termoplastik ürünler üreten otomotiv yan sanayi firmasında yapılan çalışmalara göre, üretilen bir ürünün ana sanayideki müşteriye gidebilmesi için tüm bu çıktılar için “1” değeri alınmalıdır. Herhangi bir çıktı değerinin “0” olması durumunda ürünün o özellik bakımından geliştirilmesi gerekliliği ortaya çıkmaktadır. Ürünün tüm özellikleri istenen aralıklar içerisinde olduğunda, ürünün tüm kalite problemlerinin giderildiği söylenebilmektedir.

Bu çalışmada oluşturulan Yapay Sinir Ağının genel yapısı Şekil 1’de görülmektedir.



Şekil 1:
Yapay sinir ağının genel yapısı

Oluşturulan YSA, parçalara ait geçmiş veriler (9 adet girdi değerine karşılık 8 adet parametre bazında uygunluk değerleri) ile eğitilmiştir. Bundan dolayı otomotiv yan sanayi firmasında üretilen ürünlere ait geçmiş performans bilgileri elde edilmiştir. Bu sistemde eğitici yani sistem tasarımcısı sistem çıkışlarının istenen değerini tespit edebildiğinden, eğitici öğrenme yöntemi kullanılmıştır. Ağ tasarımında geri besleme bağlantıları olmadığı için ve veri tabanındaki bilgilerle eğitim yapıldığı için ileri sürümlü ağlar kullanılmıştır. YSA'nın istenen çıktıları üretebilmesi için katmanlar arasında yer alan ağırlıkların ayarlanması ve güncellenmesi gerektiğinden dolayı, geri yayılma algoritması kullanılmıştır.

Yapay sinir ağında, gizli katman tasarımı için önce tek gizli katman ve gizli katmandaki düğüm sayıları değiştirilerek, daha sonra hata miktarına bağlı olarak gizli katman sayısı ve her bir gizli katmandaki düğüm sayıları değiştirilerek deneyler yapılmıştır.

Yapay Sinir Ağının Eğitimi ve Eğitim Parametrelerinin Belirlenmesi

Eğitim aşamasında YSA, eğitim kümesiyle, kullanıcı tarafından verilen bilgiyi cevaplamayı öğrenmektedir. Dolayısıyla eğitim kümesinin belirlenmesi, ağın doğru çalışması açısından çok önemlidir. Eğitim kümesinin yetersiz olması, ağın genelleme yeteneğinin başarısız olmasına sebep olabilir. Benzer girdilere karşı farklı çıktıların tanımlanması ise ağın cevabının güvenilirliğini olumsuz etkiler (Albino ve Garavelli, 1998). Doğru bir sinirsel ağ modeli elde etmek için YSA'nın eğitimi önemlidir.

Geri yayılma eğitim yöntemi üç parametre ile kontrol edilebilir. Bu parametreler; öğrenme oranı (η), momentum (μ) ve çıkış durumudur:

- Öğrenme Oranı (η): Öğrenme oranı, ağırlıkların zamanla değişimindeki hızı kontrol eder. Bu çalışmada, öğrenme oranının 0,1 ile 0,5 arasındaki değerlerinde daha iyi sonuçlar alınmıştır.
- Momentum (μ): Momentum teriminin hesaplamaya katılması iterasyon sayısında ve toplam ağ hatasında bir düşüş meydana getirmektedir. Bu çalışmada, momentum parametresinin 0,9 ile 0,5 arasındaki değerlerinde iyi sonuçlar alınmıştır.
- Çıkış durumu: Yapay sinir ağının eğitimi için "belirli sayıdaki iterasyondan sonra, istenen hataya ulaşılmadıysa dur" kuralı uygulanmıştır. Bu çalışmada, 10000 iterasyon sonucunda istenen hata seviyesine ulaşılmadıysa sinirsel ağ durdurulmuştur.

Çalışmada, ağın eğitilmesi için 100 adet eğitim verisi seçilmiştir. Eğitim verileri, ağın yeterli derecede öğrenebilmesi ve eğitimde kullanılmayan girdiler için de doğru çıktılar vermesini sağlayacak

şekilde seçilmiştir. Eğitim verileri, plastik enjeksiyon yöntemi ile otomotiv sektörüne termoplastik parçalar üreten bir firmada üretilen parçalardan yararlanılarak oluşturulmuştur.

Yapay Sinir Ağının Doğrulanması


Bu çalışmada, eğitimi yapılan ağın istenen düzeydeki güvenilirlikte sonuç üretebildiğinin doğrulanması için, otomotiv yan sanayi firmasında üretilen parçalardan 60 adet doğrulama verisi oluşturulmuştur. Doğrulama verileri eğitim verilerinden farklı olacak şekilde seçilmiştir.

Uygulama ve Ağın Testi

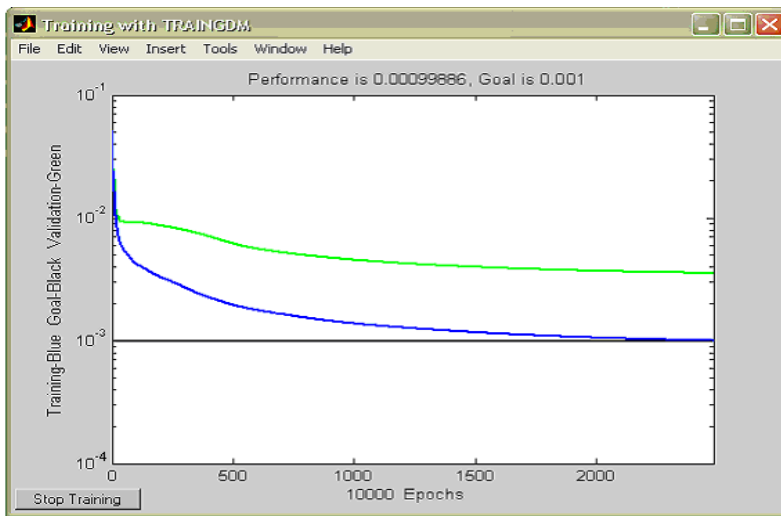
Yapay sinir ağının tasarımı ve eğitimi için MATLAB - Neural Network programı kullanılmıştır. Programda ileri beslemeli ağ oluşturulmuş, geri yayılma algoritması uygulanmıştır.

Hedef hata değeri olarak 0.001, maksimum iterasyon sayısı 10000 alınmıştır. Yapılan deneyler sonucunda, birinci gizli katmanında altı nöron, ikinci gizli katmanında beş nörona sahip olan iki gizli katmanlı ağda, momentumun 0,7 ve öğrenme oranının 0,3 olduğu durum için en iyi sonuç elde edilmiştir.

Deneyler sonucunda elde edilen ağ yapısı Şekil 2’de, eğitim ve doğrulama kümesi hatalarının değişimlerinin yer aldığı grafik Şekil 3’te verilmiştir.



Şekil 2:
Deneyler sonucu elde edilen yapay sinir ağı yapısı



Şekil 3:
Eğitim ve doğrulama kümesi hataları değişim grafiği

Örnek parça olarak otomotiv yan sanayi firmasında üretilmeye başlanacak olan motor üst kaplama ön ürünü seçilmiştir. Seçilen ürünün görüntüsü Şekil 4’te verilmektedir.



Şekil 4:
Motor üst kaplama ön parçasının görünümü

Motor üst kaplama ön parçası ve üretildiği makine için çalışmada kullanılacak olan parametreler, oluşturulan yapay sinir ağına girdi olarak verilmiştir. Ağdan elde edilen çıktı değerlerine göre bu ürünün tespit edilen kalite göstergeleri bazında uygun olup olmadığı incelenmiştir.

Örnek olarak incelenen motor üst kaplama ön parçası için elde edilen YSA çıktı değerleri Şekil 5’te görülmektedir.

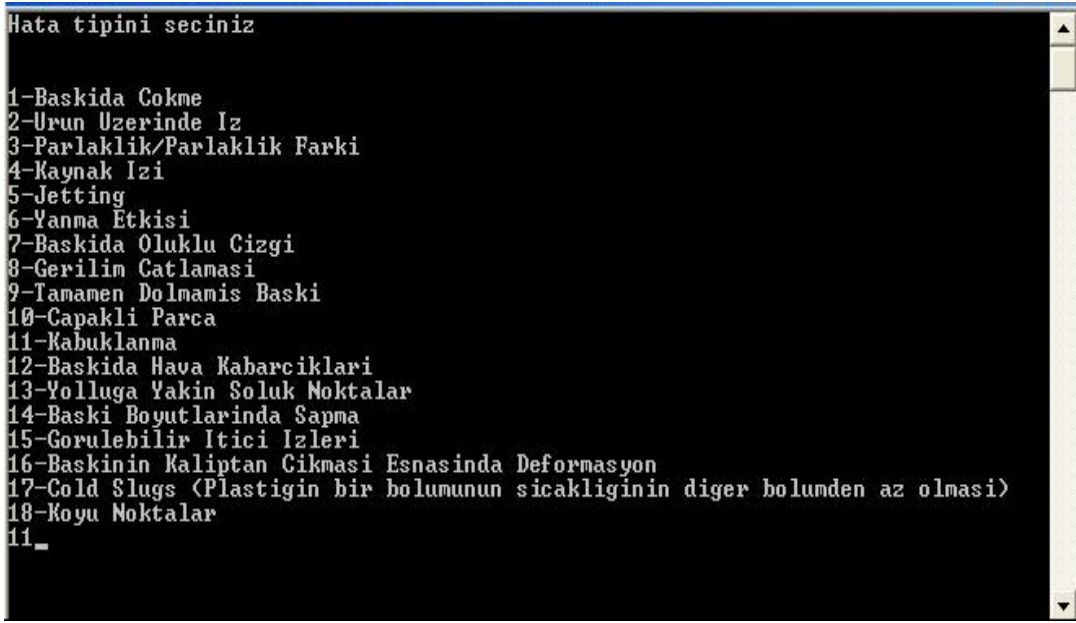
YSA çıktı değerlerine göre, üretilen ürünün parlaklık, çarpıklık, kırılma ve renk özellikleri bakımından uygun olmadığı ve bu şartlar altında kaliteli ürün olarak adlandırılmayacağı tespit edilmiştir. Tespit edilen problemlerin ise ilk etapta baskıda parlaklık, baskıda gerilim çatlaması ve kabuklanma hatalarını beraberinde getireceği söz konusudur.

```
Command Window
>>
>>
>> p=[550; 1.55; 250; 3.5; 5.20; 74; 6.0; 20; 165]
p =
550.0000
1.5500
250.0000
3.5000
5.2000
74.0000
6.0000
20.0000
165.0000
>> a=asin(net, p)
a =
1.0000
0.1042
0.8857
0.9999
0.9042
2.1705e-006
0.3158
0.0089
>>
>>
Workspace
```

Şekil 5:
Örnek parça için elde edilen YSA çıktı değerleri

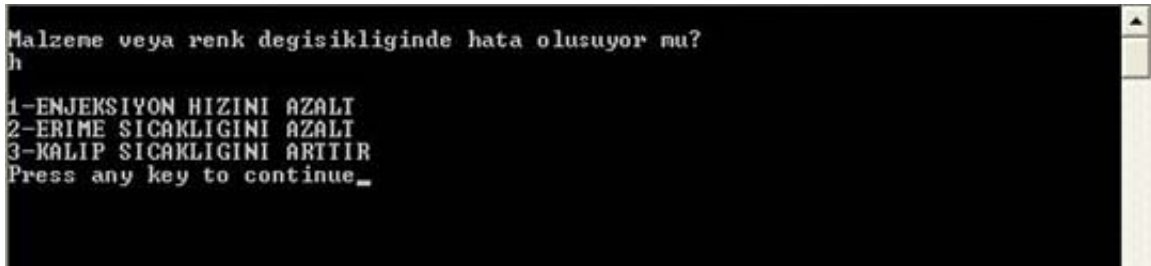
Çalışmanın ikinci kısmında, ürünün uygunsuz olduğu tüm göstergeler yapay sinir ağı ile tespit edildikten sonra devreye girecek bir uzman sistem tasarımı yapılmıştır. Uzman Sistem C++ dilinde yazılmıştır.

Şekil 6’da uzman sistem kullanıcı ara yüzü görülmektedir. Örneğin, hata tipi olarak kabuklanma hatasının seçilmesi amacıyla 11’e basılmıştır.



Şekil 6:
Uzman Sistem kullanıcı ara yüzü

Kabuklanma hatası seçildikten sonra, uzman sistem kullanıcıya bu hata ile ilgili soruyu sormuştur. Kullanıcı, problemle ilgili sorulara “hayır” cevabını vermiştir. Sonuçta, uzman sistem problemin çözülmesi için kullanıcıya öneriler sunmuştur. Uzman sistemin örnek problemle ilgili önerileri Şekil 7’de verilmiştir.



Şekil 7:
Kabuklanma hatası için uzman sistem önerileri

Benzer biçimde, yapay sinir ağının çalışması sonucunda belirlediği diğer hatalar için de uzman sistem kullanıcıya öneriler sunmuştur.

Uzman sistem sayesinde elde edilen parametrelerin yeni değerlerine göre yapay sinir ağı yeniden çalıştırılmış ve ağdan yeni bir sonuç elde edilmiştir. Örnek ürün için yapay sinir ağının çıktıları Şekil 8’de verilmektedir.


```
Command Window
>>
>>
>> p=[550; 1.55; 240; 3.5; 5.05; 74; 6.0; 22; 165]

p =
550.0000
1.5500
240.0000
3.5000
5.0500
74.0000
6.0000
22.0000
165.0000

>> a=linnet(p)

a =
1.0000
1.0000
0.9049
0.9999
0.9472
0.8537
0.9994
0.8590

>>
>>
```

Şekil 8:
Örnek parça için uzman sistem sonrası YSA çıktı değerleri

YSA çıktı değerlerinden, devreye alma süreci devam eden motor üst kaplama ön ürünü için uzman sistemin ürettiği aksiyonlar gerçekleştirilince tüm göstergelerde uygunsuzlukların giderildiği görülmektedir.

4. SONUÇ

Bu çalışmada termoplastik ürünlerin üretiminde yeni ürün devreye alma süresini kısaltabilme ve malzeme, makine kullanım, işgücü gibi maliyetleri azaltabilmek için bir yapay zeka yaklaşımı kullanılmıştır. Oluşturulan Yapay Sinir Ağı – Uzman Sistem (YSA-US) sayesinde termoplastik ürünlerin yeni ürün devreye alma sürecinde, en kısa zaman dilimi içerisinde kalite problemi bulunmayan uygun parçaların elde edilmesi sağlanabilecektir.

Çalışmada, plastik enjeksiyon yönteminde yeni ürün devreye alma sürecinde elde edilen ürünlerin kalite problemine sahip olup olmadıklarının tespiti için Matlab programı ile oluşturulan çok katmanlı Yapay Sinir Ağı kullanılmıştır. Yapay sinir ağının öğrenme kabiliyeti sayesinde formlerin bilgi ve tecrübesinin ağ içinde depolanması sağlanabilmiştir. YSA çıktılarına göre öneriler sunma yeteneğine sahip olarak C++ ile tasarlanan bir Uzman Sistem, sisteme entegre edilmiştir. Otomotiv yan sanayi firmasında yürütülen çalışmalarda, örnek olarak yeni devreye alınacak motor üst kaplama ön parçası üretimi için optimum makine ve ürün parametrelerine çok kısa ve sürekli iyileşen bir şekilde ulaşılmıştır.

Bu çalışmada oluşturulan yapay zeka yaklaşımının, termoplastik ürünlerin yeni ürün devreye alma sürecinde uygulanmasıyla, karmaşık şekilli ürünlerin daha rahat üretilebileceği, parça kalitesinin ve birim zamanda elde edilen parça sayısının ortalama % 40 oranında artacağı, birim üretim başına elektrik sarfiyatının % 10 - % 15 oranında azalacağı, kalıp ömrünün yaklaşık % 10 oranında artacağı ve hurda miktarının asgariye indirileceği öngörülmektedir.

5. KAYNAKLAR

1. Albino, V. and Garavelli, A.C., (1998) A neural network application to subcontractor rating in construction firms, *International Journal of Project Management*. 16(1), 9-14.
2. Akyüz, Ö. F., (2001) *Plastikler ve Plastik Enjeksiyon Teknolojisine Giriş*, Pagev Yayınları, İstanbul.

3. Chang, P.C., Hwang, S.J., Lee, H.H., Huang, D.Y., (2007) Development of an external-type microinjection molding module for thermoplastic polymer, *Journal of Materials Processing Technology*, 184, 163-172.
4. Changyu, S., Lixia, W., Qian, L., (2007) Optimization of injection molding process parameters using combination of artificial neural network and genetic algorithm method, *Journal of Materials Processing Technology*, 183, 412-418.
5. Chen, Z. and Turng, L.S., (2005) A review of current developments in process and quality control for injection molding, *Advances in Polymer Technology*, 24(3), 165–182.
6. Kalima, V., Pietarinen, J. Siitonen, S., Immonen, J., Suvanto, M., Kuittinen, M., Mönkkönen, K., Pakkenen, T.T. (2007) Transparent thermoplastics: replication of diffractive optical elements using micro-injection molding, *Optical Materials*, 30(2), 285-291.
7. Karataş, Ç., Sözen, A., Arcaklıoğlu, E., Ergüney, S., (2007) Modelling of yield length in the mould of commercial plastics using artificial neural networks, *Materials and Design*, 28, 278-286.
8. Keçe, A., (2006) Yapay sinir ağları ile plastik enjeksiyon süreci başlangıç parametrelerinin belirlenmesi, Yüksek Lisans Tezi, Uludağ Üniversitesi Endüstri Mühendisliği Anabilim Dalı.
9. Kurtaran, H., Özçelik, B., Erzurumlu, T., (2005) Warpage optimization of a bus ceiling lamp base using neural network model and genetic algorithm, *Journal of Materials Processing Technology*, 169, 314-319.
10. Lau, H.C.W., Ning, A., Pun, K.F., Chin, K.S., (2001) Neural network for the dimensional control of molded parts based on a reverse process model, *Journal of Materials Processing Technology*, 117, 89-96.
11. Öktem, H., Erzurumlu, T., Erzincanlı, F., (2006) Prediction of minimum surface roughness in end milling mold parts using neural network and genetic algorithm, *Materials and Design* 27, 735-744.
12. Özçelik, B., Erzurumlu, T., (2006) Comparison of the warpage optimization in the plastic injection molding using ANOVA, neural network model and genetic algorithm, *Journal of Materials Processing Technology*, 171, 437-445.
13. Pramujati, B., Dubay, R., Samaan, C., (2006) Cavity pressure control during cooling in plastic injection molding, *Advances in Polymer Technology*, 25(3), 170–181.
14. Saleem, Z., Rennebaum, H., Pudiel, F., Grimm, E., (2008) Treating bast fibres with pectinase improves mechanical characteristics of reinforced thermoplastic composites, *Composites Science and Technology*, 68(2), 471-476.
15. Shi, F., Lou, Z.L., Lu, J.G., Zhang, Y.Q., (2003) Optimisation of plastic injection moulding process with soft computing, *International Journal of Advanced Manufacturing Technology*, 21, 656-661.
16. Zhu, J., Chen, J.C., (2006) Fuzzy neural network based in process mixed material caused flash prediction (FNN-IPMFP) in injection molding operations, *International Journal of Advanced Manufacturing Technology*, 29, 308-316.

Makale 29.08.2008 tarihinde alınmış, 15.12.2008 tarihinde düzeltilmiş, 18.12.2008 tarihinde kabul edilmiştir. İletişim Yazarı: N. Öztürk (nursel@uludag.edu.tr).