

KALİTE KONTROL PROBLEMLERİNİN ÇÖZÜMÜNDE YAPAY SİNİR AĞLARININ KULLANIMI

İhsan KAYA*, Selda OKTAY¹, Orhan ENGİN¹

*İTÜ İşletme Fakültesi Endüstri Mühendisliği Bölümü 80680, Maçka/İstanbul

¹S.Ü. Müh.-Mim. Fakültesi Endüstri Mühendisliği Bölümü, Konya/Türkiye

ÖZET

İşletmeler arasındaki artan rekabet, yüksek kalite standartlarını önemli bir hale getirmiştir. Bunun yanı sıra müşteri memnuniyeti de rekabetçi bir iş ortamında önemlidir. Bundan dolayı işletmeler esnek olmalıdır. Esneklik için üretim ve kalite kontrol sistemleri otomatik ve değişikliklere uyumlu olmalıdır. Otomatik bir kalite kontrol sistemi için yapay zekâ teknikleri kullanılmaktadır. Bu çalışmada yapay sinir ağlarının kalite kontrol problemlerindeki uygulamaları araştırılmıştır. Desen tanıma, tahmin, sınıflandırma gibi pek çok kalite kontrol problemi için yapay sinir ağları kullanılmaktadır. YSA yaklaşımı ile birlikte kalite kontrol faaliyetleri daha kolay olmakta, maliyetler ve muayene süreleri minimize edilebilmektedir. Çalışmada, yapay sinir ağlarının uygulamaları, avantaj ve dezavantajları incelenmiştir.

Anahtar Kelimeler: Kalite kontrol, Kalite, Yapay sinir ağları

USING ARTIFICIAL NEURAL NETWORKS TO SOLVE QUALITY CONTROL PROBLEMS

ABSTRACT

Increasing competition between companies made high quality standards very important. Also customer satisfaction is important in a competitive business environment. Hence, companies must be flexible. Manufacturing and quality control systems must be automatically and be able to adapt to change for flexibility. Artificial intelligence techniques are used to perform an automatically control system. In this paper, artificial neural network applications for quality control problems are reviewed. Neural networks are used a number of quality control problems, such as pattern recognition, forecasting, classification. Quality control functions are became easier, and the cost of it and time for inspection is minimized by using neural network approach. In this paper, artificial neural network (ANN) applications, its advantages and disadvantages are investigated.

Keywords: Quality control, Quality, Artificial neural networks

E-mail: ikaya@selcuk.edu.tr
seldaoktay@yahoo.com
oengin@selcuk.edu.tr

1. GİRİŞ

İkinci Dünya Savaşı'ndan sonra seri üretimin daha da yaygınlaşması pazarlar ve tüketici isteklerini de değiştirmiştir. Globalleşme ile birlikte ekonomik sınırların ortadan kalkması tüm dünyada sadece bir tek pazarın oluşmasına sebep olmuştur. Pazar büyümekte ancak her geçen gün yeni üreticiler pazara dâhil olmaktadır. Bu da beraberinde acımasız rekabeti getirmiştir. Önceleri rekabet sadece fiyat odaklı iken artık günümüzde tüketicilerin “kaliteli ürünü” ucuza almak istemeleri kaliteyi de önemli hale getirmiştir. Acımasız rekabetin yanında artık kalite savaşları da yaşanmaktadır.

Kalite hayatımızın birçok noktasında kendisini göstermektedir. Artık “kaliteli yaşam” kavramlarını bile duymaktayız. İşletmelerde sadece “ürün üretmek” değil “kaliteli ürün üretmek” esas olmuştur. Kalite bu denli önemli hale gelirken işletmelerde kalitenin kontrolü esas faaliyetlerden biri sayılmaktadır. Ancak minimum maliyette maksimum kar hedefleyen işletmeler için kalite kontrol maliyetleri problem olmaktadır. Bu sorunu çözmek için işletmeler değişik yöntemler kullanmaya başlamışlardır.

Tarih boyunca insan beyni ve çalışma şekli sürekli merak edilmiştir. Birçok bilim adamı insan beyninin sırlarını çözmeye çalışmıştır. Ve insan beyni gibi çalışan makineler yapmak istemişlerdir. Bunun sonucunda yapay zekâ kavramı ortaya çıkmıştır. Yapay zekâ teknikleri ile birlikte insan beyni modellenmiş ve zeki sistemler geliştirilmiştir.

Günümüzde birçok yapay zekâ sistemi kullanılmaktadır. Uzman sistemler, bulanık mantık, yapay sinir ağları bunlardan bazılarıdır. Yapay zekâ teknikleri ile oluşturulan sistemler sayesinde işlemler daha kısa sürede gerçekleştirilmektedir. Böylece işletmeler için önemli olan zaman faktöründen de kazanım sağlanmaktadır. Kalite kontrol alanında da bu teknikler kullanılmaya başlanmıştır. İşte bu aşamada karşımıza yapay zekâ tekniklerinden yapay sinir ağları çıkmaktadır. Birçok kalite kontrol problemlerinin çözümünde yapay sinir ağlarından yararlanılmıştır.

Bu makalede Yapay Sinir Ağları ele alınmış ve kalite kontrol problemlerinin çözümündeki uygulamaları incelenmiştir.

2. YAPAY SİNİR AĞLARI (YSA)

YSA'lar bilgiyi alabilen, depolayan ve kullanabilen hücresel sistemlerdir. Hali hazırda YSA'lar pek çok problemin çözümünde yardımcıdırlar [1].

Yapay zekânın bir dalı olan yapay sinir ağları, biyolojik beyinden daha iyisini yapmaya çalışan büyük paralel hesaplama mekanizmalarıdır. Bunlar zekâyı birbiriyle bağlantılı ağırlıklarında depolarlar. Bu değişken ağırlıklar düğümleri (nöronları) paralel ve ardışık bir biçimde birleştirirler. Tüm mekanizma hiyerarşik olarak girdi vektörünü düğümler ve ağırlıklar doğrultusunda işleyerek çıktı vektörüne ulaştırır [2].

Yapay sinir ağları genellikle bir girdi, bir ya da daha fazla gizli ve bir çıktı katmanı içerir. Tipik bir nöron girdisi başka bir nöronun çıktısıdır. Bu çıktılar bağlantılar aracılığıyla iletilir. Bu bağlantılara biyolojide sinaps adı verilir. Her bir sinaptik bağlantı kuvveti, ağırlık adı verilen nümerik değerlerle belirtilir. i . nöron j . nörona sinyal gönderdiğinde, bu sinyal i . sinapsın ağırlığıyla çarpılır. i . nöronun çıktısı x_i olarak gösterilir. J . Nörondaki ağırlıklandırılmış girdiler ($w_{ji}x_i$) nörondaki işlemci eleman tarafından toplanır. Elde edilen toplam nöron aktivasyon olarak adlandırılır. Aktivasyon tamamen nöronun iç durumudur. Ağırlıklar ve girdiler pozitif veya negatif olabilirken aktivasyondan dolayı pozitif, sıfır veya negatif olabilir. Pozitif durum aktive olmuş nöronu, negatif durum pasif olan kapalı nöronu gösterir. Aktivasyon belirlendikten sonra nöron çıktısı belirlemek için sinyal transfer fonksiyonlarını uygular [3].

Aktivasyon fonksiyonları ise bir YSA' da nöronun çıkış genliğini, istenilen değerler arasında sınırlar. Bu değerler çoğunlukla $[0,1]$ veya $[-1,1]$ arasındadır. Lineer ve doğrusal olmayan aktivasyon fonksiyonlarının YSA'larında kullanılması karmaşık ve çok farklı problemlere uygulanmasını sağlamıştır [4].

Yapay Sinir Ağlarının özellikleri aşağıda verilmiştir:

1-*Doğrusal Olmama*: Bütün sonuçların her bir girdiyle etkileşim içerisinde olduğu manasına gelir. Doğrusal bir sistemde girdilerin biri değiştirildiğinde, çıktı bu değişmeye orantılı olarak değişir ve bu etki sadece değiştirilen girdinin değeri ile bağlantılıdır [5].

2-*Hata Toleransı*: YSA paralel dağılmış parametrelili bir sistem olduğundan her bir işlem elemanı izole edilmiş bir ada gibidir. Bu nedenle işlem elemanları zarar görse bile bu sistemin performansının düşmesine neden olabilir ancak sistem hiçbir zaman durmaz. YSA sistemlerinin hata toleranslı olmasının sebebi, bilginin sisteme dağıtılıyor olmasıdır. Bu özellik sistemin durmasının önemli bir zarara neden olacağı uygulamalarda önem kazanır [6].

3-*Eğitilme*: Nöron ağı kendi parametrelerini (yapısını, ağırlık katsayılarını) değiştirerek, somut problemin çözümü için kendini adapte etme özelliğine sahiptir. Bu zaman çözülen problem alanı hakkında çok da bilgiye sahip olmadan ağı parametrelerini hesaplamaya imkân verir [5].

4-*Öğrenme*: YSA'nın bir problemi öğrenmesi için problemin giriş verilerine karşılık gelen çıkış verilerinin veya sadece giriş verilerinin sağlanması gerekir. Giriş ve çıkış verileri ile tanımlanan öğrenme kümesi yeteri sayıda örnek içermelidir. Öğrenme süreci sistem girişleri ve sistem çıkışı arasındaki ilişkiyi veya giriş verileri arasındaki ilişkilendirmeyi tanımlayan ağırlık verilerinin elde edilme süreci olarak ta tanımlanabilir [4].

5-*Genelleştirme*: Nöron ağları yalnızca eğitilen tasvirleri üretmekten başka, yeni tasvirler de oluşturabilirler [5].

6-*Bellek*: YSA'nın önemli bir özelliği, bilgiyi saklama şeklidir. Biyolojik sistemlerde veri dağınık yapıda saklanır. YSA'da bellek, birçok yerel bellekler oluşturularak dağıtılır. Bağlantı ağırlıkları YSA bellek biçimleridir. Ağırlıkların değerleri, ağırlık o anki bilgi durumunu temsil eder. Örneğin; bir giriş/istenen çıkış çiftinin belirtilen bilgi parçası ağırlık içinde birçok bellek biçimine dağıtılmıştır. Bellek üniteleri ile diğer saklı bilgiler, bu bilgiyi paylaşırlar [6].

2.1. YSA Ağ Yapıları

Yapay Sinir Ağları farklı şekillerde sınıflandırılmaktadır. Birçok YSA yapısı vardır. Bu nedenle çalışmada YSA'lar sadece ileri veya geri beslemeli olarak ikiye ayrılacaktır.


2.1.1. İleri Beslemeli Ağlar

İleri beslemeli YSA'larda katmanlar ileri yöndedir, tersine bir yönelme yoktur [7].

Her bir katmandaki hücreler sadece bir önceki katmanın hücrelerince beslenir [6].

İleri beslemeli yapay sinir ağları nöron adı verilen çok katmanlı karar verici düğümleri kapsar. İlk katman girdi katmanyken son katman ise çıktı katmanıdır. Girdi ve çıktı katmanları dış çevreyle bağlantılı olan katmanlardır. En az bir gizli katman ortada bulunmaktadır. İleri beslemeli YSA'da her bir girdi nöronu ilk gizli katmandaki her nörona bağlıdır. Ve her bir katmanın çıktısı bir sonraki katmanın girdisidir [8].

İleri beslemeli ağlara örnek olarak çok katmanlı perseptron (Multi Layer Perseptron-MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir. Bu ağlar statik ağlar olarak ta bilinirler. İleri beslemeli nöron ağ yapısı şekil 1'de gösterilmiştir [4].




Şekil 1. İleri Beslemeli Nöron Ağı [5].

2.1.2. Geri Beslemeli Ağlar

Geri beslemeli yapay sinir ağlarında en az bir hücre sonraki katmanlardaki hücrelerce de beslenir [6].

Bir geri beslemeli sinir ağı, çıkış ve ara katman çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur [4]. Geri beslemeli ağ yapısı şekil 2’de gösterilmiştir.



Şekil 2. Geri Beslemeli Nöron Ağı [5].

YSA, gösterilen örnekten öğrenerek kendi kurallarını oluşturur. Öğrenme; giriş örneklerine veya bu girişlerin çıkışlarına bağlı olarak ağıın bağlantı ağırlıklarını değiştiren veya ayarlayan öğrenme kuralı ile gerçekleştirilir [6]. Öğrenme kurallarına; hopfield kuralı, delta kuralı ve hebb kuralı örnek verilebilir.

2.2. Öğrenme Algoritmaları

YSA’lar öğrenme evresi boyunca şartsız olarak gerekli kuralları elde eder. Öğrenme sırasında; girdiler doğru çıktılar üretsin diye ağıın ağırlık vektörleri ayarlanmaktadır [9-10]. İki tür eğitim söz konusudur: Danışmanlı ve danışmansız öğrenme.

2.2.1. Danışmansız Öğrenme (Süpervizörsüz)

Bu eğitimde nöron ağıının ortam (çevre) ile karşılıklı ilişkisi minimuma indirilir. Bu eğitimde eğitici kümede yalnızca giriş vektörleri mevcuttur. Eğitimin amacı ağıın uygun parametrelerini uyarlamakla giriş vektörü kümesine özgü olabilecek konuma uygunlukları belirlemektir [5].

2.2.2. Danışmanlı Öğrenme (Süpervizörlü)

Danışmanlı öğrenmede gerçek YSA çıktısı istenilen (hedef) çıktı ile karşılaştırılır. Sonra elde edilen çıktı ile hedef çıktı arasındaki hatayı minimize etmek için bağlantı ağırlıkları ayarlanır. Bu öğrenmede, geri-yayımlı algoritması en popüler olan uygulamadır [9, 11].

Geri-yayımlı Algoritması (BP); Bu algoritma gradyan metodunu (gradient descent) kullanarak ağırlıklardaki hata fonksiyonunun minimize etmek ister. Fonksiyonları minimize eden ağırlık kombinasyonu öğrenme probleminin çözümü olarak düşünülebilir. Bu nedenle bu Metot her bir iterasyonda hata fonksiyonu gradyanının hesaplanmasını gerektirir [12]. Diğer yaygın öğrenme algoritmaları ise; delta-bar-delta, geliştirilmiş delta-bar-delta ve genetik algoritmadır.

3. KALİTE KONTROL PROBLEMLERİNİN ÇÖZÜMÜNDE YAPAY SİNİR AĞLARI KULLANIMI

Pek çok kalite kontrol probleminin çözümünde yapay sinir ağlarından yararlanılmaktadır. Özellikle kontrol diyagramlarındaki şekillerin tanınmasında, ürünlerdeki yabancı maddelerin belirlenmesi ve buna benzer problemlerde YSA’ların kullanıldığı görülmektedir. Çalışmanın bu bölümünde yapay sinir ağlarının ne tür kalite kontrol

problemlerinde kullandıkları ve nasıl uygulandıkları incelenmiştir. Tablo 1’de kontrol diyagramlarındaki YSA uygulamaları, tablo 3’de proses kontrolü ve tablo 5’de kalite tekniklerine yönelik YSA uygulamaları sunulmuştur. Yapılan çalışmalar incelendiğinde kalite kontrolün aşağıda belirtilen alanlarında YSA uygulamasının olduğu belirlenmiştir. Bunlar

- Kontrol Diyagramları
- Proses Kontrol
- Deney Tasarımı
- On-Line Kalite Kontrol
- Kabul Örnekleme
- Hata Modu Ve Etkileri Analizi (HMEA)

Tablo 1. Kontrol Diyagramları ve YSA.

UYGULAMA ALANI	ALT ALAN	ÇALIŞMA
Kontrol Diyagramları	İzleme	Guo ve Dooley [13], Su ve Tong [14], Hwang [15]
	Desen Tanıma	Velasco ve Rowe [16], Pham ve Öztemel [17], Smith [28], Pham ve Öztemel [18], Leger ve ark. [19], Reddy ve Ghosh [20], Karlık [21]
	Oluşturma	Viharos ve Monostori [22], Jackson [23]
	Yorumlama	Smith [28], Reddy ve Ghosh [20]
	Tahmin	Cook ve Shannon [24]
	Sınıflandırma	Hwang ve Hubele [25], Karlık [21]
	Veri Sıkıştırma	Pugh [26; 27], Smith ve Yazıcı [28], Regattieri [29]

Pugh [26-27], kalite kontrol prosesinde veri analizi için geri-yayımlı YSA önermiştir. Bir örnek hacimdeki incelemelere göre girdi düğümleri uyumlu hale getirilir ve bir tek çıktı proses ortalaması hakkında bilgi verir. Çalışmada yapay sinir ağı, değişen ve değişmeyen veriler ile eğitilmiştir. Sonuç olarak YSA’nın performansının kontrol diyagramları ile karşılaştırılabildiği belirlenmiştir.

Hwang ve Hubele [25], altı kontrol şekli üzerinde geri-yayımlı sınıflandırıcıyı kullanmışlardır. Bu altı kontrol şekli; eğilim, çevrim, tabakalandırma, sistematik, çeşit ve ani değişimdir. Guo ve Dooley [13], standart geri-yayımlı YSA kullanarak proses ortalaması ve varyansındaki pozitif değişiklikleri araştırmışlardır. YSA’nın normal kontrol diyagramlarına göre sınıflandırma hatalarını %40 azalttığını belirlemişlerdir.

Cook ve Shannon [24], kompozit tahta imalatında YSA kullanarak prosesin kontrol dışına çıkıp çıkmayacağını tahmin eden bir metodoloji sunmuşlardır. Tahmin doğruluğu %70 düzeyindedir.

Velasco ve Rowe [16], geri-yayımlı yapay sinir ağlarını kontrol diyagramlarının analizinde kullanmışlardır. Buradaki YSA modeli desenleri tanıyarak prosesin kontrol altında olup olmadığını göstermektedir. Kontrol dışı durumlar, Western Electric’in el kitabındaki kurallara göre belirlenmiştir. Sonuç olarak; geri-yayımlı yapay sinir ağları kontrol diyagramlarında tanıma işlemi için oldukça potansiyel bir tekniktir. Ancak pahalı bir teknik olması önemli bir problemdir. Yapay sinir ağları otomatik olarak yeni kontrol limitlerini hesaplayamayabilir fakat bunun için uzman sistem kullanılmalıdır.

Smith [28]; YSA’ların yardımıyla Shewhart X ve R kontrol diyagramlarının tanımlanması ve yorumlanmasını ele almıştır. YSA’lar kontrol limitleri içerisinde düşünülen olasılık dağılımlarından örnekler arasındaki farkı görmek için eğitilmişlerdir. Aynı zamanda YSA’lar örnekleri tanımlama ve periyodik bir dönemde ya da uzun dönemde ortaya çıkabilecek proses noktalarının durumunu tahmin etmek için eğitilmişlerdir. Çalışmada nöral kontrol diyagramlarının avantajları ve dezavantajları geleneksel istatistiksel proses kontrolü ile karşılaştırılmış ve tartışılmıştır. Çalışma YSA’ların ortalama ve varyansdaki büyük değişimler için X ve R kontrol diyagramlarıyla karşılaştırılabileceğini göstermektedir. YSA’lar büyük değişimleri ortaya çıkarmak için yeterli istatistikler olmasına rağmen hem örnek verilerinde hem de örnek istatistiklerinde çok büyük yarar sağlamıştır. Nöral yaklaşımın en önemli yararı eş zamanlı olarak çoklu kontrol stratejilerini modelleyebilmesidir. Bu çalışmada X ve R kontrol diyagramları tek bir YSA’dadır. YSA’lar mevcut X ve R kontrol diyagramlarına göre daha

hassastırlar ve daha başarılıdırlar. Desen tanıma ve tahmin problemlerinde, YSA maksimum girdi ve minimum gürültü faktörüyle en iyi performansı göstermiştir. Tüm yapay sinir ağları seyrek ve gürültülü veriler ışığında bile desen tanımlamada iyi kararlar verebilmiştir.

Pham ve Öztemel [17], kontrol diyagramlarında oluşan değişik tipteki desenleri tanıması için LVQ ağları yardımıyla bir sınıf desen tanıyıcı oluşturmuşlardır. LVQ'ların standart geri-yayılımlı YSA'dan daha az düzenleme gerektirdiğini söylemişler ve değişik desen tanıyıcılarla karşılaştırmışlardır.

Leger ve ark. [19]; hata bulma ve teşhis sistemi (FDD- Fault Detection And Diagnosis) için birikimli toplam kontrol diyagramları (CUSUM) ile YSA'ların birlikte kullanımlarını araştırmışlardır. Önerilen FDD stratejisi CANDU nükleer reaktörün ısı aktarma sistemi üzerinde test edilmiştir. Araştırmanın sonuçlarına göre, CUSUM kontrol diyagramlarını ve radyal fonksiyonlu YSA'yı kullanan FDD sistemi yalnızca uygun olmayıp aynı zamanda potansiyel bir sistemdir. Kontrol diyagramları ve YSA bulunan ve tanımlanan her bir hatanın karakteristik hata şekilleri kullanılarak birleştirilmiştir. Test edildiğinde, sistem devamlı şekilde tüm yanlış alarmları elimine edebilmiştir. Hemen altı hata durumunu bulmuş ve doğru olarak altı hatanın beşini tanımlayabilmiştir. Altıncı hatanın tanımı neticesizdir. Tablo 2'de çalışmada kullanılan modeller sunulmuş ve bu modellerin yanlış alarm sayıları verilerek performansları karşılaştırılmıştır.

Tablo 2. Yanlış Alarm Sayıları [19].

Toplam Toplam	Bireysel Kullanımlar			Birleşik Uygulamalar	
	CUSUM	RBF	MLP	CUSUM-RBF	CUSUM-MLP
	44	17	68	0	11

Çalışma sonucunda;

Birikimli toplam kontrol diyagramları (CUSUM) ve radyal tabanlı YSA (RBF) kullanılarak proses sırasındaki yanlış alarmlar elimine edilmiştir.

En başarılı aracın radyal tabanlı YSA'ların olduğu görülmüştür. Bunlar CUSUM'la beraber kullanıldığında yanlış alarm vermediği ortaya çıkmıştır. Ancak MLP (multi-layer perceptron) ile CUSUM beraber kullanıldığında yanlış alarmlar elimine edilememiştir. Ancak üç araç (CUSUM, RBF ve MLP) birlikte kullanıldığında tüm hata durumları hızlı bir şekilde bulunabilir. Hata tanımlamasında test sırasında RBF'nin 1 tane sonuçsuz çıktısı varken, MLP'nin 1 yanlış tanımlaması olmuştur. Her iki durumda istenmemekle beraber sonuçsuz bir tanımlama tercih edilmiştir.

Pratik uygulamalarda, CUSUM'un eşiğini geliştirmek, verilerin oto korelasyonlarını karşılamak için uygun bir tekniktir. Bu uygulamada, teknik sonuçlar itibarıyla aksi bir etkiye sahip değildir.

Reddy ve Ghosh [20], önerdikleri geri-yayılımlı yapay sinir ağını, kalite kontrol prosesinde meydana gelen farklı varyasyon şekillerini belirlemek ve yorumlamak için kullanmışlardır. YSA, delta-bar-delta kuralı ile eğitilmiş ve hiperbolik tanjant aktivasyon fonksiyonu kullanılmıştır. Önerilen metodolojideki amaç; küçük ve büyük sapmaları tanımak ve aynı zamanda proses değişikliğini belirlemektir. Böylece oluşabilecek problemler için düzeltici faaliyetler gerçekleştirilebilir. YSA varyasyon şekillerini tanımlayabilir. Bu yaklaşım kontrol dışı bir durumda sinyal vermesi için kullanılabilir. Böylece uygun olmayan ürünlerin üretimi önlenmiş olur. Bu çalışmadan elde edilen sonuçlar doğrultusunda kontrol diyagramlarına göre YSA'ların küçük proses değişikliklerini bulmada daha etkili olduğu belirlenmiştir. YSA'nın doğruluğu %90 düzeyinde olduğu sonucuna varılmıştır.

Viharos ve Monostori [22]; YSA ve genetik algoritmayı kullanarak kontrol diyagramları oluşturmuş ve proses optimizasyonu için çalışmışlardır. YSA'lar girdi verileri olan istatistiksel ölçüler ile operasyon parametreleri arasındaki ilişkileri öğrenmesi için eğitilmiştir. Maliyet minimizasyonu için genetik algoritmalar kullanılabilir. Genetik algoritmalar doğru kontrol diyagramı ve operasyon parametrelerini bulabilir.

Jackson [23], X kontrol diyagramı ve YSA uygulamalarını araştırmıştır. YSA'ların kullanımı, X kontrol diyagramlarına alternatif bir metodoloji olarak sunulmuştur. Çalışmada genetik uyumlu yapay sinir ağı eğitim algoritması (GANNT- Genetic Adaptive Neural Network Training) kullanılarak YSA ve X kontrol diyagramları

karşılaştırılmış ve her birinin performansı değerlendirilmiştir. Sonuçlar GANNT algoritmasıyla eğitilen YSA modelinin X kontrol diyagramlarından daha iyi olduğunu göstermektedir. Sunulan modelin performansı, örnek hacimlerin azaltılabileceğini proses hassasiyetinin yükseltilebileceğini göstermektedir. Zeki sistem, daha düşük muayene maliyetlerine imkân tanırken aynı zamanda proses performansını geliştirebilir. Bu uygulamada yalnızca YSA kullanılmamıştır. YSA modeli Genetik Algoritma (GA) içeren bir eğitim algoritmasıyla eğitilerek güçlendirilmiştir. Böylece zeki sistem oluşturulmuştur. Sonuç olarak; burada sunulan zeki sistem yaklaşımı aynı zamanda hataları ve proses değerlendirmesine ilişkin maliyetleri de azaltabilmektedir.

Hwang [15]; YSA'nın birçok örnekte araştırılan SCC (special-cause control), X, EWMA, EWMAST ve ARMAST kontrol diyagramlarından daha iyi olduğunu göstermiştir. Bu çalışmada kalite kontrolde proses izlemek için YSA kullanılmıştır. Çalışma otokorelasyon içinde proses izleme metodolojisinde YSA kullanımını sunar ve bu yaklaşımın uygulanabilirliğini, geçerliliğini ve gücünü göstermektedir. Burada sunulan YSA uzatılmış delta-bar-delta kuralı ile eğitilmiş ve geri-yayılım algoritması kullanılmıştır. Yapılan çalışmada YSA'lar ile geleneksel istatistiksel kontrol diyagramlarının performansı karşılaştırılmaktadır. Genelde YSA'ların geleneksel istatistiksel kontrol diyagramlarına göre daha iyi olduğu ortaya çıkmıştır. Sonuç olarak; YSA'ların performansı, istatistiksel kontrol diyagramlarına göre daha yüksektir. YSA ile elde edilen çıktılar, değişimin büyüklüğü hakkında da bilgi verir.

Karlık [21], üretim sistemi kontrolünün YSA ile görüntülenmesi için bir çalışma sunmuştur. Burada çok katlı nöron ağları, rastsal olarak metalik çivi ve plastik halkaların seçilmiş görüntülerini tanımlamak için kullanılmıştır. Üç katmanlı ileri beslemeli nöron ağları kullanılmış ve hata geri-yayılım yöntemi ile eğitilmiştir. Çalışmada kamera görüntülerinden yararlanılarak objeler YSA yardımıyla tanımlanmakta ve yabancı bir cisim olup olmadığı kontrol edilmektedir. Üretim proseslerinde kontrole yardım amaçlı bir YSA modellemesi yapılmıştır. Burada sınıflandırma problemi söz konusudur. Sistem öncelikle cismin özelliklerini girdi vektörü olarak almakta daha sonra bu belirtiler ışığında cismi sınıflandırarak tanımlamaktadır. Test verilerinin hepsi nöron ağını tanıttığı zaman, başarılı olarak tanımlanmışlardır. Farklı iterasyonlardan sonra optimum öğrenme hızı 0,9 ve momentum katsayısı 0,7 olarak bulunmuştur. Sonuç olarak üretim hattı kontrolünde YSA'ların başarıyla uygulanabildiği gösterilmiştir.

Tablo 3. Proses Kontrolü ve YSA.

UYGULAMA ALANI	ALT ALAN	ÇALIŞMA
Proses Kontrol	Parametre Tasarımı	Chinnam [30], Rosales [31], Parvathinathan [32], Huang [33]
	Proses Modelleme	Kang ve ark. [34], Sette ve ark. [35], Chinnam [30], Guo ve Brodowsky [36], Çiftçi [37], Chang ve Jiang [38], Poligne ve ark. [39],
	Parametre Tahmini	Andersen ve ark. [40], Zaderej [41], Shea [42], Stinch ve ark. [43], Jiahe ve ark. [44],
	Veri Sınıflandırma	Smith ve Yazıcı [45], Bahlmann ve ark. [46], Kim ve ark. [47], Zhou [48]
	Parametre Belirleme	Chiang ve Su [49]
	Kalite Tahmini	Smith ve Yazıcı [45], Tani ve ark. [50], Liu [51], Chang ve Jiang [38], Huang [33], Paiva ve ark. [52]
	Model Formüle Etme	Park ve ark. [53]
	Proses Değerlendirme	Cheng ve ark. [54]
	Hesaplama Problemi	Feng ve ark. [55]
	Otomatik Kontrol	Patro [3]
	Veri Modelleme	Zhou [48]
	Durum Tahmini	Bukapatnam [56]
	Hata Bulma	Thomsen ve Lund [57]
	Veri Analizi	Smith ve Yazıcı [45], Liu [51]
	Desen Tanıma	Barchdorff [58], Kang ve Park [59]
Proses Kontrolü İle İlgili Diğer Çalışmalar	Beavorstock [60], Cordes ve ark. [61], Shoureshi [62], Cheng [63], Sim ve ark. [64], Puerto ve Ghalia [65]	

Barchdorff [58], elektrik motorlarının kalite kontrolü için YSA tekniği kullanmıştır. Burada hatalar değerlendirilmiştir. Ayarlanmamış motor, bağlanmamış sarımlar, manyetik alan hataları, kayıp parçalar gibi hatalar üç katmanlı YSA'lar tarafından başarıyla tanımlanmıştır. Girdiler 16 spektral motor titreşim özelliği

çermektedir. YSA'nın sınıflandırma tekniği farklı desen tanıma algoritmalarıyla karşılaştırılmıştır. Sonuç olarak; YSA'ların daha iyi olduğu görülmüştür.

Anderson ve ark. [40], girdi parametrelerini kaynağın kalite ölçüleriyle ilişkilendirmek için geri-yayımlı YSA kullanmışlardır. Tahmin eden modeller, kalite kontrol prosesi durumlarına dayalı ürün parametrelerini tahmin etmek içindir.

Thomsen ve Lund [57]; ultrasonik güç tayfinda kalite kontrolünde hata bulma işlemi için YSA kullanmışlardır. Bu nedenle ilk aşamada hata tipleri sınıflandırılmalıdır. Thomsen ve Lund yoğunluk fonksiyonunu göstermek için 21 girdi nöronu, 1 kısıt ve 20 değişken kullanmışlardır. Dört çıktı nöronu vardır. Geri-yayımlı algoritması ile eğitilmişlerdir. Yaptıkları çalışmada 365 tayfıdan %83'ü doğru sınıflandırılmıştır.

Smith ve Yazıcı [45], plastik ekstruder fabrikası için istatistiksel proses kontrol, yapay sinir ağları ve bir uzman sistemi, zeki analiz ve kontrol sistemi için birleştirmişlerdir. İstatistiksel metodoloji YSA tekniği ile karşılaştırılmıştır. Uzman sistem kullanan kompozit kontrol sistemine YSA analizinin entegrasyonu sunulmuştur. Burada yapay sinir ağları veri analizinde ve kontrol diyagramlarında kullanılmıştır. Kontrol diyagramlarında YSA'ların sınıflandırma hata yüzdeleri; iki gizli katmanında 10 nöron bulunduran ağ için 0,247 iken 5 nöron bulunduran ağ için 0,417 dir. YSA'lar kullanılarak ilişkili ve ilişkili olmayan parametreler eş zamanlı olarak izlenilmiştir. Kontrol diyagramları yerine YSA'lar kullanılabilir. YSA'lar istatistiksel proses kontrol teknikleri kadar çok veri ve analiz gerektirmez. Sonuç olarak; YSA'lar kontrol durumlarını başarılı bir şekilde sınıflandırmıştır.

Beaverstock [60], YSA ve uzman sistemlerin birleştirilmesiyle oluşmuş zeki proses kontrol fonksiyonlarını kompleks meyve özü ve kâğıt proseslerinin kontrolü için geliştirmiştir.

Cordes ve ark. [61], kalite kontrolünde klasik orantılı integral türev kontrolcülerini, üç pompalı likit seviyesi bulanık mantık sistemi ve ısı kontrollerinde bulanık mantık-YSA sistemlerini karşılaştırmışlardır.

Zaderej [41], YSA tekniğine dayanan Nöral Proses Kontrolü olarak adlandırılan bir metot sunmuştur. Geçmiş verilerden öğrenen bu metot elde ettiği bilgileri proseslerin girdilerini kontrol etmek ve çıktılardaki değişkenliği minimize etmek için kullanılmaktadır. Çalışmadan elde edilen sonuçlara göre, yapay sinir ağlarının proses çıktılarını tahmin etmek için öğrenebildikleri belirlenmiştir.

Cheng ve ark. [54], yorulma testi sırasında magnezyum alaşımının Akustik Emisyon (AE) davranışlarını ezberlemesi için YSA tekniğini kullanmışlardır.

Feng ve ark. [55], yapay sinir ağlarını hedef noktaların üç boyutlu pozisyonlarının hesaplanması için uygulamışlardır. Bu metotta üç boyutlu bilgi için iki boyutlu bilgi sistemi kullanılmıştır.

Shea [42], yağ rafinerisindeki son kontrol faaliyetleri üzerine bir çalışma yapmıştır. Yağ rafinerisindeki proses limitlerini, indirgeme oranlarını minimize etmek amaç edinilmiştir. Burada lineer olmayan bir problemle karşılaşmıştır. Lineer olmayan imkânları bulmak için YSA kullanılmıştır. Yapay sinir ağları kontrol edilebilir faktörler üzerinde mantıksal regresyonlar seti kuran bir tahmin aracı olarak kullanılmıştır. Her bir gizli nöron mantıksal regresyonlarla ağırlıklandırılmıştır. Sonuçta parametreleri döngüsel olarak tahmin edilebilen, interaktif, lineer olmayan ve parametreleri oluşturulmuş bir model ortaya çıkarılmıştır.

Sim ve ark. [64], fıstık, fındık ve buğday tohumlarına böceklerin gelmesini kontrol eden X ışınli bir sistem oluşturmuşlardır. Bu sistemde geri yayımlı YSA kullanılmıştır.

Patro [3], YSA ve evrimsel algoritma teknolojilerinin birleştirilmesiyle geleneksel kalite kontrol metodlarına ait kısıtların üstesinden gelmek için bir çalışma yapmıştır. Çalışmada değişen çevre şartları ve kontrol hedeflerine yüksek düzeyde adapte olabilen otomatik kontrol sistemi geliştirilmiştir. Bu teknoloji geleneksel kontrol metodlarının üstesinden gelebilmek için kullanılan, ezberleyen ve öğrenen bir tekniktir. YSA geri-yayımlı algoritması ile eğitilmiştir. Geri-yayımlı algoritması ile ağırlıklar düzenlendiği için fabrika çıktısı ile model çıktısı arasındaki hata minimize edilmiştir.

Kim ve ark. [47]; geri-yayımlı algoritmasına dayanan yapay sinir ağlarını kullanarak her bir lehim yerini fazla, yetersiz ve yeterli şeklinde sınıflandırarak kalite kontrol çalışması yapmışlardır. Lehim bağlantı yerleri YSA'lar tarafından kabaca sınıflandırılmaktadır. Eğer sınıflandırma yeterli değilse Bayes kullanılarak lehimlenen yüzeyin üç boyutlu şekli iyileştirilmiştir. Yapılan modellemeye göre iki boyutlu resimlerde tanımlama oranı %99,5 iken üç boyutlu görüntülerde bu oran %100'e yükselmektedir.

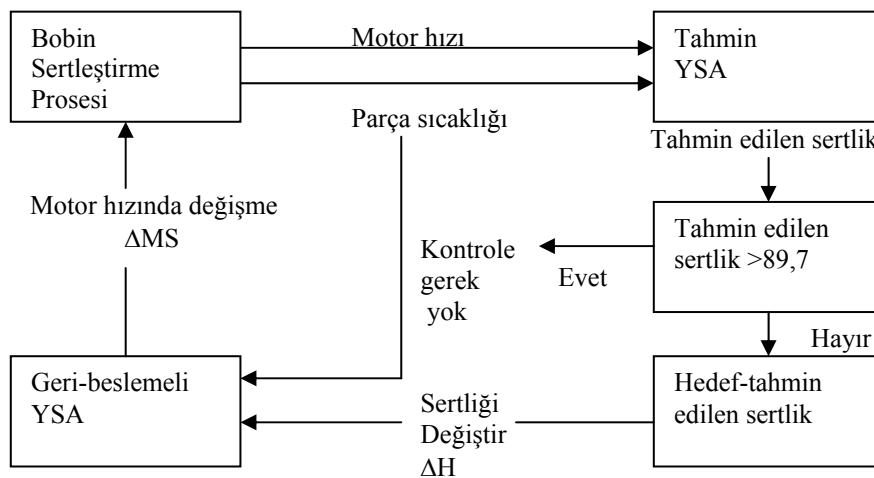
Sette ve ark. [35], genetik algoritmayla birlikte yapay sinir ağlarını kullanmışlardır. İplik eğirme prosesini optimize etmek için kontrol strateji tasarımına yönelik bir metodoloji sunmuşlardır. Çalışmalarında yapay sinir ağları proses modellemesinde kullanılmıştır. Girdiler, makine hazırlık noktaları ve ham iplik kalite parametreleridir. Çıktılar ise ipliğin yapışkanlığı ve gerginliği (uzatılabilme esnekliği) dir. Genetik algoritma ise, YSA'ların kullandığı parametreleri ve YSA yapısını optimize etmek ve optimal kalitedeki iplik için hazırlık değerleri ve hammadde karakteristiklerini elde etmek için kullanılmıştır. Üretim prosesi yapay sinir ağları ile simüle edilirken, YSA'ların yapısı genetik algoritma ile optimize edilmektedir. YSA simülasyonu en önemli iki iplik karakteristiğini tahmin ederek başarılı olmuştur. Genetik algoritma da bu karakteristiklerin her ikisini de etkili olarak optimize etmede kullanılmıştır. Sonuçlardan anlaşılmaktadır ki genetik algoritma ile optimize edilen YSA modeli normal bir YSA modeline göre daha hızlıdır.

Zhou [48], genetik algoritma ve yapay sinir ağlarını veri modelleme ve sınıflandırmada kullanmıştır. Genetik eğitilen YSA modelinin, geleneksel istatistiksel metotlar ya da geri-yayımlı YSA'dan daha iyi olduğu görülmüştür. Sistemde kriterlerin belirlenmesine gerek yoktur. Çünkü YSA otomatik olarak probleme ilişkin faktörleri ayırt edebilir. Sınıflandırma işlemi başarıyla gerçekleşmiştir.

Bahlmann ve ark. [46] çalışmalarında; tekstil endüstrisinde dikişlerin otomatik olarak kalite kontrolü için bir metot geliştirmişlerdir. Sistemde; uygun bir görüntü elde etme mekanizması, dikişleri kontrol etme yeri, dikişlerin özelliklerinin ortaya çıkarılması ve sınıflandırma için YSA yer almaktadır. Sonuçlar iyi sınıflandırmanın yapıldığını göstermektedir. Doğru sınıflandırma oranı %80'dir. Yalnızca 1/5'lik bir hata söz konusudur. Çalışmanın amacı, tekstil muayenelerinde daha iyi ve standartlaşmış kalite ölçümleri için bir uzmanın yapabileceği kalite kontrol işlemini daha düşük maliyetle gerçekleştirmektir. Bu da otomatik bir sistemle olabilir. Sistemin performansı 200 dikişin sınıflandırılması ile ölçülmüştür. Sonuçlar bir uzmanın cevaplarıyla karşılaştırılmış ve doğruluk düzeylerinin aynı olduğu görülmüştür. Sınıflandırma işlemi PC'de 1 sn. sürmektedir. Hâlbuki bir uzmanın ihtiyaç duyduğu süre daha fazladır.

Kang ve ark. [34], kalite kontrol işlemi için hibrit bir metot sunmuşlardır. Öğrenen sistemler ve YSA'lar birleştirilerek daha iyi imalat koşullarını oluşturmada ve denetlemede kullanmışlardır. Aynı zamanda bu metoda yarı iletken ve CRT-renk prosesinde zeki proses kontrol sistemi olarak başvurulmuştur. Öğrenen sistemler birbirleri arasında kompleks korelasyon bulunan verilerden kolaylıkla kurallar oluşturabilir. Ancak bu sistemlerde devamlı çıktı elde etmek oldukça zordur. Bu problemi çözmek için de YSA kullanılmıştır. Çalışmanın sonucunda; sıralı prosesler içeren imalat endüstrisinde proses kontrolü, izlenmesi ve güçlendirilebileceği ortaya çıkmıştır. Kalite iyileşmesi, öğrenen sistemler ve YSA'ların kullanımı ile sağlanabilir.

Stitch ve ark. [43], bobin sertleştirme prosesinin kontrolü ve izlenmesinde YSA uygulamalarına değinmişlerdir. YSA'lar geleneksel metotlarla çözülemeyen, değişkenler arasında kompleks ilişkilerin olduğu problemlerin üstesinden gelebilir. Basit lineer regresyon bu tür non-lineer prosesler için bir cevap değildir. YSA'ların diğer bir avantajı da; değişken etkileşimlerinin tam olarak anlaşılınması halinde bile doğru çıktılar üretebilmeleridir. Buradaki bobin sertleştirme prosesinin otomatik kontrolü için yakın ilişkili YSA sistemi geliştirilmiştir. Sistem iki tür geri-yayımlı YSA içermektedir. Şekil 3'de geliştirilen proses kontrol sistemi gösterilmiştir.



Şekil 3. YSA Proses Kontrol Sistemi [43].

YSA kullanımının sağladığı avantajlar, tablo 4'de görülmektedir.

Tablo 4. YSA'lı ve YSA'sız Proses Analizleri [43].

	Test 1		Test 2	
	YSA'sız	YSA'lı	YSA'sız	YSA'lı
Potansiyel Kapasite (C_p)	2,42	4,65	2,35	3,35
Max. Kapasite (C_{pv})	2,97	5,07	3,11	3,80
Min. Kapasite (C_{pl})	1,88	4,23	1,59	2,90
Prosesin Kapasitesi (C_{pk})	1,88	4,23	1,59	2,90
Hedef	90,0	90,0	90,0	90,0
Üst Spesifikasyon Limiti (USL)	95,0	95,0	95,0	95,0
Alt Spesifikasyon Limiti (LSL)	85,0	85,0	85,0	85,0
Proses Ortalaması (μ)	88,8800	89,5488	88,3873	89,9253
Standart Sapma (s)	0,6880	0,3587	0,7098	0,4976

Test-1'de %125 ve Test-2'de %82 iyileşme kaydedilmiştir. YSA kullanılarak proses hedefine yaklaşılmış ve daha sıkı proses kontrolü başarılmıştır. Araştırmanın amacı iki tür geri-yayımlı süpervizörlü öğrenen YSA'nın kullanılmasıydı. Tahmin YSA'sı ve geri-beslemeli YSA bobin sertleştirme proses kontrolünde kullanılmıştır. Proses kapasitesi (C_{pk}) nde %80'den fazla iyileşme sağlanmıştır. YSA kullanımı, ürün kalitesini geliştirmede ve proses kontrolünü azaltmada potansiyel bir uygulamadır. YSA'lar değişkenleri arasındaki ilişkilerin çok iyi anlaşılmasıyla kompleks imalat proseslerini modellemede mükemmel araçlardır.

Chinnam [30]; kontrol edilemeyen faktörler hakkında mevcut ekstra bilgi kullanan prosesler ve ürünlerin on-line parametre tasarımını kolaylaştırmak için bir metodoloji ileri sürmektedir. Burada iki farklı modda çalıştırılan zeki kalite kontrol sistemi önerilmektedir.

- ✓ Tanımlama modu
- ✓ On-line parametre tasarım modu.

Ürün/ proses tanımlama modu, kontrol edilebilen ve edilemeyen kalite karakteristiklerine bağlı bir model kurmaktadır. On-line parametre tasarım modu, kontrol edilemeyen değişkenleri dikkate alarak istenilen kalite parametrelerine bağlı kalarak kontrol edilebilir değişkenlerin optimizasyonunu içerir. Literatürdeki diğer metotlara karşılık bu metotta zor proses parametre tasarımı araştırma metotları ve parametrik olmayan proses modelleme için YSA teknolojisi kullanılmıştır. Çalışmada, imalat proseslerinin kalite karakteristiklerini modellemek için parametrik olmayan YSA modeli ileri sürülmüştür. Ve kontrol edilebilir değişkenlerin optimizasyonu için gradyan eğilimli YSA önerilmiştir. Sonuç olarak; ileri beslemeli YSA'lar parametrik olmayan, güçlü yaklaşım özelliklerine göre ve adaptif sistemlere uyumluluklarına göre kalite karakteristiklerini modellemek için önerilmektedir.

Çiftçi [37], yapay sinir ağlarını, ürün kalitesini etkileyecek olan fırının çalışma parametrelerini (sıcaklık.. gibi.) kontrol etmek için kullanmıştır. Çok katmanlı ileri beslemeli YSA kullanarak, lineer olmayan prosesi modellemeye çalışmıştır. Proseslerin ters dinamiklerini öğrenmek için YSA, geri-yayımlı algoritması ile eğitilmiştir. Girdi katmanında 20 nöron, gizli katmanda 5 nöron ve çıktı katmanında ise 1 nöron vardır. Gizli ve çıktı katmanındaki nöronlar, aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonunu kullanmışlardır. Veri seti 2500 için, YSA'nın kümülâtif tahmin hatası 0,303 olmuştur.

Kang ve Park [59], İPK prosedürlerini tamamlamak için, kalite problemlerini çözmeye yapay sinir ağları ve kurallı öğrenmeden oluşan üç bütünleşik metot sunmuşlardır. İstatistiksel proses kontrol (İPK) kalite problemlerini çözmeye anahtar rol oynasa da, henüz tam olarak proses ve değişkenler arasındaki kompleks ilişkileri, çok boyutlu değişkenler ve çok sayıda veriye sahip endüstrilerdeki etkisi anlaşılabilmiştir. Çalışmada

ilk olarak, kalite kontrolde gerekli olan değişiklikleri azaltmak için alt özellik seçim metodu önerilmiştir. İkincisi, kurallı öğrenmede doğru tahmin yüzdesini artırmak için kümeleyici kurallı öğrenme metodu sunulmuş ve son olarak da, kaynak desenlerle karşılaştırarak farklı desenleri tanımlamak için desen tanıma metodu önerilmiştir. Bu metotlar için YSA kullanılmıştır. Metotlar iki veri setinde denenmiştir. Sonuçlar göstermiştir ki, bu üç metot çok değişkenli proses kontrolünde etkilidirler. Çalışmada çok değişkenli proses kontrolünde İPK prosedürlerini tamamlamak için üç hibrit metot önerilmiştir. Geleneksel metotların çok değişkenli prosesleri kontrol etmede ve izlemede kısıtları söz konusudur. Sunulan hibrit metotlar kullanıldığında çok değişkenli proses kontrolünde iyi sonuçlar alınabilir.

Rosales [31], ayar parametrelerini belirlemek ve kontrol dışı durumları minimize etmek için zeki bir sistem tasarlamıştır. Geliştirilen zeki sistem, YSA ve bulanık mantık tekniklerini içermektedir. Zeki sistemde ayrıca ileri-beslemeli YSA kullanılmıştır. YSA modelinin girdileri, döküm parçaların görünüş veya ölçüleridir. Çıktılar ise kalite parametrelerinden negatif ve pozitif sapmalardır. Oluşturulan zeki sistem optimal döküm proses parametrelerini elde etmek için kullanılmıştır. Zeki sistemin önerdiği proses parametre değerleri, sistem hazırlık sürelerini azaltmakta ve hata sayılarını da minimize etmektedir.

Chang ve Jiang [38]; imalat prosesinde takımın hatasını görüntülemek için toplanan sensör ölçümleri ve bitmiş ürünün kalitesi arasındaki bağıntıyı araştırmak için YSA modeli geliştirmişlerdir. Burada YSA modelinin kullanılmasının gerçek sebebi modelleme prosedürünü göstermektir. Eğitilmiş yapay sinir ağı kullanılarak, nihai ürüne ait kalite bilgileri on-line sensör ölçümlerinden elde edilebilir. Sonuçlar göstermektedir ki, sensör ölçümleri yalnızca proses durumu hakkında bilgi vermekle kalmayıp aynı zamanda nihai ürünün kalite performansı hakkında da bilgi vermektedir. Çalışmada eğitilmiş YSA on-line kalite performans tahmini de yapmaktadır. Çalışmada; otomatik proses kontrolünde on-line sensörlerin kullanılması etkili olmuştur. Çünkü üretim devamlı olarak izlenebilmekte ve kesilmemektedir. Ayrıca ürünün kalite karakteristikleri teçhizatın sensör ölçümleri ile ilişkilendirilmiştir.

Huang [33], çoklu kesme araçlarını içeren YSA tabanlı adaptif yüzey pürüzlülük kontrol sistemi (neural networks-based in-process adaptive surface roughness control- NN-IASRC) geliştirmiştir. Yapay sinir ağlarını yüzey pürüzlülük kontrolünde karar verme tekniği olarak kullanmıştır. NN-IASRC sistemi iki alt sistemden oluşmaktadır. İlki YSA tabanlı yüzey pürüzlülük tahmin sistemi (INN-SRP – in-process neural networks based surface roughness prediction) dir. Bu sistem yüzey pürüzlülüğünü tahmin etmek için kullanılmıştır. Diğer alt sistem ise YSA tabanlı adaptif işleme parametreleri kontrol sistemi (NN-APMC – neural networks based adaptive machining parameters control) dir. Bu alt sistem ise tahmin edilen yüzey pürüzlülük değerleri istenmeyen şekilde olduğu durumlarda parametre oranını ayarlamaktadır. INN-SRP sisteminin doğruluğu %93 iken NN-IASRC sisteminin doğruluğu %100 dür.

Jiahe ve ark. [44]; yapay sinir ağlarını 60Si2MnA adındaki çeliğe ait rulolama ve soğutma işlemi kontrol parametrelerinin tahmininde kullanmışlardır. YSA modeli proses parametrelerinin etkileşim içerisinde olup olmadığını tahmin edebilir. Bu özellik 60Si2MnA çeliğinin kalite kontrolünde çok önemlidir ve kontrol edilen rulolama ve soğutma proseslerinde bu model kullanılacaktır. Yapay sinir ağları rulolama ve soğutma proses parametreleri ve 60Si2MnA çeliğinin mikro yapısı arasındaki ilişkiyi modellemek için kullanılmıştır. Yapay sinir ağları regresyon analizleri ile karşılaştırıldığında daha etkili olduğu açıktır.

Parvathinathan [32], YSA kullanarak su kalite parametrelerini modellemeye bağlı belirsizlikleri araştırmıştır. Lower Rio Grande Nehri (LRGR) su kalitesini modellemek için Qual2E-UNCAS (Belirsizlik Analizi) 'ı kullanarak belirsizlik ve kısıtları tahmin etmek üzere çalışmıştır. Burada yapay sinir ağları su kalite parametrelerini modellemede kullanılmıştır. YSA LRGR'deki klorofil-a maddesini tahmin etmede oldukça başarılı olmuştur.

Chiang ve Su [49], ince dörtlü paketleme prosesinde (TQFP) çoklu nitel ve nicel cevaplar içeren birleşik optimizasyon problemi üzerine odaklanmıştır. Öncelikle bulanık kalite kayıp fonksiyonu (Fuzzy Quality Lost Function-FQLF) nitel cevaplar için kullanmışlardır. YSA proses parametreleri ve cevaplar arasındaki doğrusal olmayan ilişkiyi kurmada kullanılmıştır. Önerilen metot Tayvan'da yarı iletken montaj fabrikasında uygulanmaktadır. Bu çalışmadan elde edilen sonuçlar önerilen metodun uygunluğunu göstermektedir.

Paiva ve ark. [52], kağıdın son parlaklığını tahmin ederek beyazlık kalitesini belirlemek için bulanık-YSA önermişlerdir. Bulanık kurallar setini oluşturmak için bulanık kümeleme tekniği kullanılmıştır. Üyelik fonksiyonlarının merkez ve genişlikleri (dağılım aralığı) geri-yayımlı algoritması ile eğitilen bulanık-YSA ile iyileştirilmiştir.

Tablo 5. Kalite Kontrol Uygulamaları ve YSA.

UYGULAMA ALANI	ÇALIŞMA
Deney Tasarımı	Mezgar ve ark. [66]
On-Line Kalite Kontrol	Grauel ve ark. [67], Haussler ve Wortberg [68], Zavarehi [69], Bridges ve Mort [70], Auger [8]
Kabul Örnekleme	Zhang ve ark. [71], Sanchez ve ark. [72]
HMEA	Burke [73], Guillot ve Ouafi [74], Wu ve ark. [75], Reddy ve Ghosh [20]
Diğer Kalite Problemleri	Dornfeld [76], Shoureshi [62], Dominguez ve ark. [77], Chang ve Song [78], Du ve Wolfe [79]

Burke [73], genelde operatörler tarafından yapılan makinenin işlem yapması sırasında teçhizat takma görevini yarışmalı öğrenen YSA yardımıyla tanımlamıştır. Böylece kalite kontrole ilişkin teçhizat takma sırasında oluşabilecek hatalar önlenmiş olmaktadır.

Dornfeld [76], teçhizat durumunu izlemek için yapay sinir ağlarını kullanmıştır. Torna tezgahında daha hızlı takım (teçhizat) kullanmak için bir takım testler yapmıştır. YSA'ların performansı lineer sınıflandırıcılarla karşılaştırılmış ve %6'lık bir artış rapor edilmiştir.

Guillot ve Ouafi [74], Burke'nin yaptığına benzer bir çalışma yapmışlardır. Süpervizörlü öğrenen YSA kullanmışlar ve takım kırığını tanımlamada YSA'lardan yararlanmışlardır.

Wu ve ark. [75], plastik endüstrisi iğneyle şekillendirme prosesinde ve teşhissel ve kalite kontrolünde düzeltici faaliyetler için hata belirleme modelinde geri-yayımlı korelasyon modeliyle çalışmışlardır.

Dominguez ve ark. [77], çelik şeritlerin üretiminde düz parçaların kalite kontrolü için yapay sinir ağlarını kullanmışlardır. Çalışmalarında yeni bir YSA modeli kompleks sınıflandırma görevi için kalite kontrol sistemi içerisine yerleştirilmiştir. Sonuç olarak; YSA sınıflandırıcıları kullanılarak çelik endüstrisi için bir kalite kontrol sistemi sunulmuştur.

Chang ve Song [78], sensör veri füzyonu için iki metot sunmuşlardır. Çalışmada yapılan deney sonuçlarına göre gürültü faktörleri söz konusu olduğunda YSA'ların daha başarılı olduğu gözlenmiştir. Gürültü faktörleri olmadığında matematiksel model daha doğru sonuçlar vermektedir.

Haussler ve Wortberg [68], tüm plastik proseslerinde on-line proses izleme ve %100 kalite tahmini için yapay sinir ağlarını kullanmışlardır.

Zhang ve ark. [71] CMM (Coordinate Measuring Machine) kullanarak optimal örnek hacmi belirlemek için YSA yaklaşımı kullanmışlardır. Çalışmada tasarım, üretim ve ölçüm bakımından örnek hacmi etkileyen faktörler üzerinde durulmuştur. Proses tipi, büyüklük ve tolerans aralığı örnek hacmi etkileyen faktörler olarak belirtilmiştir. Örnek hacmi ve faktörler arasındaki korelasyon, toplanan verileri kullanan geri-yayımlı YSA tarafından oluşturulmuştur. Verilen özellik için uygun bir örnek hacmi belirlemek karmaşık bir problemdir. Çünkü problem; proses tipi, boyutsal ve geometrik toleranslar, büyüklük ve ölçümdeki güven seviyesi gibi pek çok faktör tarafından etkilenebilir. Örnek hacmi ve bu faktörler arasındaki korelasyonu belirlemek problemin anahtar çözümüdür. Geri-yayımlı YSA tekniği, örnek hacmi ve üç faktör (proses tipi, büyüklük ve tolerans aralığı) arasındaki korelasyonu yaklaştırmak için önerilmiştir. Test sonuçları, YSA tekniğinin örnek hacmi belirlemede potansiyel bir araç olduğunu göstermektedir.

Mezgar ve ark. [66], deney teknolojilerinin tasarımını birleştiren bir çalışma sunmuşlardır. Bunlar Taguchi metodu ve bilgi tabanlı simülasyon teknikleridir. YSA tasarım faktörleri ile sistem performansı arasındaki ilişkiyi haritalandırması için önerilmiştir. Yaklaşımın uygulanabilirliği verilen sistemde AGV hızının belirlenmesi ve bir takım deneyler doğrultusunda analiz edilmiştir. Çalışmada aynı zamanda test desenlerinin tahmininde gizli nöron sayısının etkisi araştırılmıştır.

Zavarehi [71], hidrolik sistemlerin on-line kontrolü için uzman sistemler ve yapay sinir ağlarını kullanmıştır. Uzman sistemleri hata teşhisinde, YSA sınıflandırıcıları da hata tanımlamada kullanmıştır. Sonuç olarak, uzman sistemlerin sayesinde hatalı alarm sayısı azalmıştır. Hızlı öğrenen YSA sınıflandırıcıları uzman sistem içerisinde kullanılması önerilmiştir. YSA modeli hata prosesini anlamaksızın ya da net kurallar gerektirmeksizin uzman

sistem içerisinde otomatik olarak hata semptomlarını tanımlayabilmektedir. Böylece YSA modeli kural sayısını yarı yarıya azaltmıştır. Bu durum YSA'nın başarısını göstermektedir.

Auger [8], kaynağın erime bölgesine ilişkin değişik parametrelerin tahmini için bir sistem tanımlamıştır. Yapay sinir ağları üç sensörden elde edilen erime bölgesine ait geometrik özellikleri içeren verileri birleştirmek için kullanılmıştır. Sonuç olarak, sistem on-line kalite izleme prosesinde kabul edilemez kusurlu kaynakları tahmin edebilmektedir. Burada, yapay sinir ağları kalite kontrol sisteminin bir parçası olarak laserli kaynakta erime bölgesi karakteristiklerini tahmin etmede bir araç olarak kullanılmıştır. YSA kullanımının avantajı; YSA'nın girdi ve çıktı sinyalleri arasındaki ilişkiyi kendisinin belirleyebilmesidir. Bireysel parametreler YSA tarafından en iyi şekilde tahmin edilmiştir.

4. SONUÇ

İşletmede yapılan muayeneler ürüne değer katmamaktadır. Yapılan muayeneler sadece ürünün kalitesini garanti etmektedir. Gelişen teknoloji ile birlikte otomasyona dayalı üretim ön plana çıkmıştır. Bu tür üretim sistemlerinde kontrol faaliyetleri de otomasyona dayalı hale gelmiştir. Otomatik kontrol sistemlerinde yapay zeka teknikleri etkin olarak kullanılmaktadır. Pekçok kalite kontrol probleminin çözümünde yapay sinir ağlarından yararlanılmıştır. Özellikle kontrol diyagramlarındaki şekillerin tanınmasında, üründeki yabancı maddelerin ortaya çıkarılması ve benzer problemlerde YSA'lar kullanılmaktadır. Literatürdeki çalışmaların değerlendirilmesi ile;

- ❖ Yapay sinir ağlarının, kalite problemlerinde başarıyla uygulandığı,
- ❖ Doğruluk düzeyinin yüksek olduğu,
- ❖ Zaman açısından işletmeye pek çok kazanım sağladığı,
- ❖ Maliyetleri minimize ettiği,
- ❖ Tek başına bir tek yapay zeka tekniği kullanmak yerine, iki veya daha fazla yapay zeka tekniğinden oluşan bir kombinasyon kullanmanın daha faydalı olduğu belirlenmiştir.

KAYNAKLAR

1. Canpolat, F., Yılmaz, K., Ata, R., Köse, M., Prediction of Ratio of Mineral Substitution In The Production of Low-Clinker Factored Cement By Artificial Neural Network, Celal Bayar University, Mathematical and Computational Applications, **8(2)**, 209-217,2003.
2. Smith, A. E., X-Bar and R Control Chart Interpretation Using Neural Computing, International Journal of Production Research, **32 (2)**, 309-320, 1994.
3. Patro, S., Neural Networks and Evolutionary Computation for Real-time Quality Control, A Dissertation in Industrial Engineering, Texas Tech University, 1997.
4. Sağiroğlu, Ş., Beşdok, E., Erler, M., Mühendislikte Yapay Zeka Uygulamaları-I: Yapay Sinir Ağları, Ufuk Yayıncılık, Kayseri, 2003.
5. Allahverdi, N.,Yapay Sinir Ağları, Yayınlanmamış Ders Notları, Selçuk Üniversitesi, Konya, 2003
6. Karlık, B., Çok Fonksiyonlu Protezler İçin Yapay Sinir Ağları Kullanılarak Miyoelektrik Kontrol, İstanbul, 1994.
7. Haykin, S., Neural Networks: A Comprehensive Foundation, New York: MacMillan College Publishing Company, 1994.
8. Auger, M., Detection of Laser-Welding Defects Using Neural Networks, A Thesis for The Degree Of Master of Science (Engineering), Queen's University, 2001.
9. Werbos, P. J., Generalization of Backpropagation with Application to a Recurrent Gas Market Models, Neural Networks, **1**, 339-356, 1988.
10. Kohonen, T., Self-Organizing Map, Proceedings of the IEEE, **78 (9)**, 1464-1480, 1990.
11. Caudill, M., Neural Network Training Tips and Techniques, AI Expert, **6, (1)**, 56-61, 1991.
12. Rojas, R., Neural Networks- A Systematic Introduction, Springer-Verlag, 1996.
13. Guo, Y., Dooley, K. J., Identification of Change Structure in Statistical Process Control, International Journal of Production Research, **30**, 1655-1669, 1992.
14. Su, C., Tong, L., A Neural Network-Based Procedure for the Process Monitoring Of Clustered Defects in Integrated Circuit Fabrication, Computers in Industry, **34**, 285-294, 1997.
15. Hwang, B. H., Detecting Mean Shift in AR (1) Processes, Decision Sciences Institute, Annual Meeting Proceedings, 2002.
16. Velasco, T., Rowe, M. R., Back Propagation Artificial Neural Networks for the Analysis of Quality Control Charts, Computers and Industrial Engineering, **25(1-4)**, 397- 400, 1993.

17. Pham, D. T., Öztemel, E., Control Chart Pattern Recognition Using Learning Vector Quantization Networks, *International Journal of Production Research*, **32(3)**, 721-729, 1994.
18. Pham, D. T., Öztemel, F., An Integrated Neural Network And Expert System Tool For Statistical Process Control, *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering*, **209 (B2)**, 91-97, 1995.
19. Leger, R. P., Garland, Wm. J., Poehlman, W.F.S., Fault Detection And Diagnosis Using Statistical Control Charts And Artificial Neural Networks, *Artificial Intelligence in Engineering*, **12(1)**, 35-47, 1998.
20. Reddy, D.C., Ghosh. K., Identification and Interpretation of Manufacturing Process Patterns through Neural Networks, *Mathematical and Computer Modelling*, **27 (5)**, 15-36, 1998.
21. Karlık, B., A Neural Network Image Recognition for Control of Manufacturing Plant, *Mathematical & Computational Applications*, **8(2)**, 181-189, 2003.
22. Viharos, Zs. J., Monostori, L., Optimization of Process Chains by Artificial Neuronal Networks and Genetic Algorithms Using Quality Control Charts, 8th Daaam International Symposium, 1997.
23. Jackson, N. F., Neural Network Model Using A Genetic Algorithm To Perform The Functions of X-Bar Charts, A Dissertation for the doctor of Philosophy Degree, The University of Mississippi, 1999.
24. Cook, D. F., Shannon, R. E., A Predictive Neural Network Modeling System for Manufacturing Process Parameters, *International Journal of Production Research*, **30 (7)**, 1537-1550, 1992.
25. Hwang, H. B., Hubele, N. F., X-bar Chart Pattern Recognition Using Neuralnets, *ASQC Quality Congress Transactions*, 884-889, 1991.
26. Pugh, G. A., Synthetic Neural Networks for Process Control, *Computers and Industrial Engineering*, **17 (1-4)**, 24-26, 1989.
27. Pugh, G. A., A Comparison of Neural Networks to SPC Charts, *Computers and Industrial Engineering*, **21 (1-4)**, 253-255, 1991.
28. Smith, A. E., Yazıcı, H., an Intelligent Composite System for Statistical Process Control, *Engineering Applications Artificial Intelligence*, **5 (6)**, 519-526, 1992.
29. Regattieri, M., Zuben, F.J.V., Rocha, A. F., Neurofuzzy Interpolation: II-Reducing Complexity of Description, *IEEE International Conference on Neural Networks*, 3, 1835-1840, 1993.
30. Chinnam, R. B., Role of Neural Networks and Genetic Algorithms in Developing Intelligent Quality Controllers for On-line Parameter Design, *International Journal of Smart Engineering System Design*, 2000.
31. Rosales, D. J. V., Soft Computing Technologies In Quality Control With Applications To Injection Molding, A Dissertation for the Degree of Philosophy, New Mexico State University, 2001.
32. Parvathnathan, G., An Evaluation Of Uncertainty In Water Quality Modeling For The Lower Rio Grande River Using Qual2E-Uncas and Neural Networks, A Thesis for the Master of Science, Texas A&M University, 2002.
33. Huang, P. T. B., A Neural Networks-Based-In-Process Adaptive Surface Roughness Control (NN-IASRC) System In End-Milling Operations, A Dissertation For The Degree of Doctor of Philosophy, Iowa State University, 2002.
34. Kang, B. S., Choe, D. H., Park, S. C., Intelligent Process Control In Manufacturing Industry With Sequential Processes, *International Journal of Production Economics*, **60-61**, 583-590, 1999.
35. Sette, S., Boulhart, L., Langenhove, L. V., Using Genetic Algorithms To Design A Control Strategy Of An Industrial Process, *Control Engineering Practice*, **6**, 523-527, 1998.
36. Guo, W., Brodowsky, H., Determination of the Trace 1, 4-Dioxane, *Microchemical Journal*, **64**, 173-179, 2000.
37. Çiftci, A. S., A Neural Internal Model Control Scheme for an Industrial Rotary Calciner, a Dissertation for the Degree of Doctor of Philosophy, Michigan Technological University, 2000.
38. Chang, D.S., Jiang, S. T., Assessing Quality Performance Based On The On-Line Sensor Measurement Using Neural Networks, *Computers & Industrial Engineering*, **42**, 417-424, 2002.
39. Poligne, I., Broyart, B., Trystram, G., Colligran, A., Prediction Of Mass-Transfer Kinetics And Product Quality Changes During A Dehydration-Impregnation-Soaking Process Using Artificial Neural Networks Application To Pork Curing, *Lebensm – Wiss. U. Technology*, **35**, 748-756, 2002.
40. Andersen, K., Cook, G. E., Karsai, G., Ramaswamy, K., Artificial Neural Networks Applied To Arc Welding Process Modeling And Control, *IEEE Transactions on Industry Applications*, **26**, 824-830, 1990.
41. Zaderej, V. V., The Use Of Neural Networks To Reduce Process Variability, A Thesis For The Degree of Master of Business Administration, Quinnipiac College, 1995.
42. Shea, G., The Economic Control Of Quality, *Nonlinear. Analysis. Theory Methods. & Applications*, **(30)**, 4033-4040, 1997.
43. Stutch, T. J., Sporre, J. K., Velasco, T., The Application Of Artificial Neural Networks To Monitoring And Control Of An Induction Hardening Process, *Journal of Industrial Technology*, **1**, 1999.

44. Jiahe, A., Huiju, J. G., Yaohe, H., Xishan, X., Artificial Neural Network Prediction Of The Microstructure Of 60Si2MnA Rod Based On Its Controlled Rolling And Cooling Process Parameters, *Materials Science and Engineering*, **A344**, 318-322, 2002.
45. Yazıcı, H., Smith, A. E., A Composite System Approach For Intelligent Quality Control, *Proceedings of the IIE Research Conference*, 325-328, 1992.
46. Bahlmann, C., Heidemann, G., Ritter, H., Artificial Neural Networks For Automated Quality Control Of Textile Seams, *Pattern Recognition*, **32**, 1049-1060, 1999.
47. Kim, T. H., Cho, T. H., Moon, Y. S., Park, S. H., Visual Inspection System For The Classification Of Solder Joints, *Pattern Recognition*, **32**, 565-575, 1998.
48. Zhou, J., Using Genetic Algorithms And Artificial Neural Networks For Multisource Geospatial Data Modeling And Classification, *The University of Connecticut*, 1998.
49. Chiang, T. L., Su, C. T., Optimization Of TQFP Molding Process Using Neuro-Fuzzy-GA Approach, *European Journal of Operation Research*, **147**, 156-164, 2003.
50. Tani, T., Murakoshi, S., Sato, T., Umano, M., Tanaka, K., Application Of Neuro-Fuzzy Hybrid Control System To Tank Level Control, *IEEE Int. Conf. On Fuzzy Systems*, **1**, 618-623, 1993.
51. Liu, J. N. K., Quality Prediction For Concrete Manufacturing, *Automation in Construction*, **5**, 491-499, 1997
52. Paiva, R. V., Dourado, A., Duarte, B., Quality Prediction In Pulp Bleaching: Application Of A Neuro-Fuzzy System, *Control Engineering Practice*, **12(5)**, 587-594, 2004.
53. Park, G. H., Lee, Y. J., Leclair, S. R., Intelligent Rate Control For MPEG-4 Coders, *Engineering Applications of Artificial Intelligence*, **13**, 565-575, 2000.
54. Cheng, R. W., Tozawa, T., Gen, M., Kato, H., Takayama, Y., AE Behaviors Evaluation With BP Neural Network, *Computers and Industrial Engineering*, **31(3-4)**, 867-871, 1996
55. Feng, T. J., Li, X., Ji, G. R., Zheng, B., Zhang, H. Y., Wang, G. Y., Zheng, G. X., A New Laser-Scanning Sensing Technique For Underwater Engineering Inspection, *Artificial Intelligence in Engineering*, **10 (4)**, 363-368, 1996.
56. Bukkapatnam, S. T. S., Monitoring And Control Issues In Chaotic Processes: An Application To Turning Process, A Thesis in Industrial and Manufacturing Engineering, *The Pennsylvania State University*, 1997.
57. Thomsen, J.J., Lund, K., Quality Control Of Composite Materials By Neural Network Analysis Of Ultrasonic Power Spectra, *Materials Evaluation*, **49(5)**, 594-600, 1991.
58. Barschdorff, D., Case Studies In Adaptive Fault Diagnosis Using Neural Networks, *Proc.of the IMACS Annals on Computing and Applied Mathematics MIM-S2*, Brussels, pp. III.A.1/1-1/6, 1990.
59. Kang, B.-S., Park, S.-C., Integrated Machine Learning Approaches For Complementing Statistical Process Control Procedures, *Decision Support Systems*, **29**, 59-72, 2000.
60. Beavorstock, M. C., It Takes Knowledge To Apply Neural Networks For Control, *ISA Transactions*, **32**, 235-240, 1993.
61. Cordes, G. A., Smatt, H. B., Johnson, J. A., Design And Testing Of A Fuzzy Logic/ Neural Network Hybrid Controller For Three-Pump Liquid Level/Temperature Control, *IEEE Int. Conf. On Fuzzy Systems*, **1**, 167-171, 1993.
62. Shoureshi, R., Intelligent Control Systems: Are They For Real? *Trans. ASME*, **115**, 392-401, 1993.
63. Cheng, C. S., A Multi-Layer Neural Network Model For Detecting Changes In The Process Mean, *Computers and Industrial Engineering*, **28 (1)**, 51-61, 1995.
64. Sim, A., Parvin, B., Keagy, P., Invariant Representation And Hierarchical Network For Inspection Of Nuts From X-Ray Images, *International Journal of Imaging Systems and Technology*, **7(3)**, 231-237, 1996.
65. Puerto, F. D., Ghalia, M. B., White Color Tracking Adjustment In Television Receivers Using Neural Networks, *Engineering Applications of Artificial Intelligence*, **15**, 601-606, 2002.
66. Mezgar, I., Egresits Cs., Monostori, L., Design And Real-Time Reconfiguration Of Robust Manufacturing Systems By Using Design Of Experiments And Artificial Neural Networks, *Computers in Industry*, **33**, 61-70, 1997.
67. Grauel, A., Ludwig, L. A., Klene, G., Comparison of Different Intelligent Methods for Process and Quality Monitoring, *International Journal of Approximate Reasoning*, **16**, 89-117, 1996
68. Haussler, J., Wortberg, J., Neural Network-Based System Boosts Quality, *Modern Plastics International*, **26(12)**, 103-107, 1996.
69. Zavarehi, M. K., On-Line Condition Monitoring and Fault Diagnosis In Hydraulic System Components Using Parameter Estimation and Pattern Classification, *Department Of Mechanical Engineering, The University of British Columbia*, 1997.
70. Bridges, L. W., Mort, N., New Approaches To On-Line Quality Control For Enameled Wire Manufacture, *Control Engineering Practice*, **6**, 1397-1403, 1998.

71. Zhang, Y.F., Nee, A. Y. C., Fuh, J. Y. H., Neo, K. S., Loy, H.K., A Neural Network Approach To Determining Optimal Inspection Sampling Size For CMM, *Computer Integrated Manufacturing Systems*, **9(3)**, 161-169, 1996.
72. Sanchez, M.S., Bertran, E., Sarabia L. A., Ortiz, M.C, Quality Control Decision With Near Infrared Data, *Chenometrics and Intelligent Laboratory Systems*, **53**, 69-80, 2000.
73. Burke, L. I., Automated Identification of Tool Wear States in Machining Processes: An Application of Self-Organizing Neural Network. Ph.D. Thesis, University of California-Berkeley, 1989.
74. Guillot, M., El Ouafi, A., On-line Identification Of Tool Breakage In Metal Cutting Processes By Use Of Neural Networks, In *Intelligent Engineering Systems Through Artificial Neural Networks*, Amer Society of Mechanical, 701-709, 1991.
75. Wu, H.-J., Cheng-Shin Liou and Hsu-Heng Pi, Fault Diagnosis Of Processing Damage In Injection Molding Via Neural Network Approach, In *Intelligent Engineering Systems Through Artificial Neural Networks*, Amer Society of Mechanical, 645-650, 1991.
76. Dornfeld, D. A., Unconventional Sensors and Signal Conditioning For Automatic Supervision, III. International Conf. On Automatic Supervision, Monitoring and Adaptive Control in Manufacturing, Rydzyna, Poland, 197-233, 1990.
77. Dominguez, S., Campoy, P., Aracil, R., A Neural Network Based Quality Control System For Steel Strip Manufacturing, *Annual Review in Automatic Programming*, **19**, 185-190, 1994.
78. Chang, C. C., Song, K. T., Ultrasonic Sensor Data Integration And Its Application To Environment Perception, *Journal of Robotic Systems*, **13(10)**, 663-677, 1996.
79. Du, T. C., Wolfe, P. M., Implementation of Fuzzy Logic Systems and Neural Networks in Industry, *Computers in Industry*, **32**, 261-272, 1997.