



## YAPAY SİNİR AĞLARIYLA KONTROL ŞEMALARINDA ÖRÜNTÜ TANIMA\*

Şebnem KOLTAN YILMAZ\*\*

M. Mustafa YÜCEL\*\*\*

### Öz

Kontrol şemaları, süreç değişkenlerinin analizi için kullanılan istatistik araçlardır. Süreç kontrol altında olduğu sürece şema üzerinde normal dağılıma uygun bir şekil; özel nedenlerin etkisiyle kontrol dışına çıktığında ise farklı şekiller meydana gelmektedir. Doğal ve doğal olmayan örüntüleri tanıma, kontrol altındaki süreç koşullarını sürdürmek ve değişkenliğe sebep olan potansiyel nedenleri belirlemek için İstatistikî Süreç Kontrolü (İSK) içerisinde önemli bir görevdir. Örüntü tanıma için, örnekler yardımıyla öğrenen Yapay Sinir Ağları (YSA) kullanılmasıyla bilgi ve deneyimlerin aktarıldığı otomatik sistemlerin süreç hakkında bilgi üretmesi sağlanabilmektedir. Bu çalışmada amaç, YSA kullanılarak yapılan Kontrol Şemalarında Örüntü Tanıma (KŞÖT) çalışmalarını incelemek, bu çalışmada kullanılan modelleri ve üstünlüklerini ortaya koymaktır. Diğer çalışmalarından farklı olarak bu araştırmada, YSA modellerine göre sınıflandırma yapılmış ve modellerin topolojileri çıkartılmıştır. Bununla birlikte farklı YSA modellerinin hem kendi aralarında hem de alternatif yöntemlere göre karşılaştırmalarına yer verilmiştir. Çalışmaların ve uygulamaların saptanmasını, incelenmesini ve yorumlanmasını amaçlayan bu araştırma için veriler nitel araştırma yöntemlerinden doküman incelemesi yoluyla toplanmış ve ulaşılan çalışmaların içerik analizleri yapılmıştır. Sonuçlar, farklı tipteki YSA modellerinin örüntü tanıma başarıyla kullanıldığını, en çok kullanılan modelin Çok Katmanlı Algılayıcılar (ÇKA), ÇKA modeli için en çok kullanılan öğrenme algoritmasının Geri Yayılım olduğunu göstermektedir. Karşılaştırmalı çalışmalarda, YSA kendi aralarında kıyaslandığında ÇKA'dan daha üstün modellerin olduğu; alternatif yöntemlerle kıyaslandığında ise YSA daha üstün performans göstermesine karşın daha yüksek tanıma oranı gösteren yöntemlerin de olduğu belirlenmiştir. YSA topolojileri incelendiğinde; girdi, çıktı ve katman sayılarının model önemli olmaksızın farklılık gösterdiği; ayrıca, YSA eğitim parametreleri grubunun ve yapılandırmasının farklı yöntemler aracılığıyla geliştirilebileceği de yine bu çalışmaların sonuçlarında görülmektedir.

**Anahtar Kelimeler** İstatistikî Süreç Kontrolü, Kontrol Şemalarında Örüntü Tanıma, Yapay Sinir Ağları, Çok Katmanlı Algılayıcılar, Doğrusal Vektör Kuantizasyon

### CONTROL CHARTS PATTERN RECOGNITION WITH ARTIFICIAL NEURAL NETWORKS

#### Abstract

Control Charts is a statistical tool used for analysis of process variability. As long as the process is under control there are shapes suitable for normal distribution on the control charts but when the process out of control as a result of special causes the different shapes are formed. Recognition of natural and unnatural patterns is an important task in Statistical Process Control (SPC) to maintain controlled process conditions and to determine variability which are originate from potential causes. Automated systems which are transferred to knowledge and experience can be produced knowledge about process with using Artificial Neural Networks (ANN) who learn the help of examples. The goal in this study is to review the Control Charts Pattern Recognition (CCPR) studies having use of ANN and to demonstrate the model used in and their superiority. Unlike other studies, in this research, classification was made according to YSA models and topologies of the models were determined. However, different ANN models have been compared among the others and alternative methods. For this research, which aims at the identification, examination and interpretation of studies and applications, datas are collected through document review. And then, content analyzes of the studies were conducted. The results show that different types of ANNs are successfully used in pattern recognition, the most widely used model is Multi Layered Perceptrons (MLP) and the most widely used learning algorithm for the MLP is Back Propagation. In

\*Bu çalışma, İnönü Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalında tamamlanan “Doğrusal Vektör Kuantizasyon Modeli Kullanılarak Yapay Sinir Ağlarıyla Kontrol Şemalarında Örüntü Tanıma: Hazır Beton Üreten Bir İşletmede Uygulama” adlı doktora tezinden üretilmiştir.

\*\*Yrd. Doç. Dr., İnönü Üniversitesi, İİBF, İşletme Bölümü, sebnem.yilmaz@inonu.edu.tr

\*\*\*Yrd. Doç. Dr., İnönü Üniversitesi, İİBF, İşletme Bölümü, mustafa.yucel@inonu.edu.tr



comparative studies; there are superior ANN models than MLP when they compared among themselves. Although ANNs performed better, it is determined that there are also methods with a higher recognition rate when they compared with alternative methods. When ANN topologies are examined; the numbers of input, output and layer are different whatever the model is. It is also seen in the results of these studies that the group of ANNs' training parameters can be developed through different methods.

**Keywords:** Statistical Process Control, Control Charts Pattern Recognition, Artificial Neural Networks, Multi Layered Perceptrons, Linear Vector Quantization.

## 1. Giriş

Bir üretim sürecinin temel amacı, çeşitliliklere uygun ürün üretmektir ve bir süreç ne kadar iyi bir şekilde tasarlanmış olursa olsun doğal olarak bir değişkenliğe sahiptir. Üretim sürecindeki değişkenliği meydana getiren hatalı ürünlerin oluşma nedenleri, hatanın oluşup oluşmayacağı tahmin edilebilmesi, hata oluşumunu etkileyen üretim süreci parametrelerinin belirlenmesi veri analiziyle kolaylaşmaktadır (Öztürk ve diğerleri, 2012:1). Bu durum da ürünün bir kalite karakteristiğinin belirlenmesi ve üretim hattındaki süreçlerin bu karakteristik kapsamında izlenmesi ile mümkün olmaktadır. Bu amaçla, kalite karakteristiği sürekli ölçülerek, ölçülen değerler kontrol şemaları üzerine yerleştirilmekte, yorumlanmakta ve süreç hakkında kararlar verilmektedir (Öztemel, 2012:126).


Kontrol şemaları, kolay kullanımı ve diğer şemalara göre sapmaları daha hızlı bulması nedeniyle İstatistikî Süreç Kontrolü (İSK)'da çok geniş bir uygulama alanı bulmuş; süreç ortalamasını ve değişiklikleri görüntülemek için güçlü bir araç olmuştur (Yi, 2001:5; Cheng, 1995:51). Kontrol şemaları,  $H_0$ : Süreç kontrol altındadır ve  $H_1$ : Süreç kontrol altında değildir hipotezlerini test etmektedir. Kontrol sınırları içerisine düşen bir nokta,  $H_0$  hipotezini kabul etmek; kontrol sınırları dışına düşen bir nokta  $H_0$  hipotezini reddetmek anlamına gelmektedir. Bu durumda, süreç denetlenirken karşı karşıya kalınan iki tip hata ortaya çıkmaktadır. I. tip hata, süreç gerçekte kontrol altında iken kontrol dışı olduğuna karar vermek; II. tip hata ise süreç gerçekte kontrol dışında iken kontrol altında olduğuna karar vermektir. I. tip hata yapıldığında katlanılacak sonuçlar; gerçekte süreçte özel bir nedene bağlı bir değişim olmadığı halde süreci durdurup özel neden aramak ya da gerekli olmadığı halde süreçte birtakım düzeltmeler yapmaktır. II. tip hata yapıldığında katlanılacak sonuçlar ise gerçekte özel bir nedenden kontrol dışında olan sürecin hatalı üretiminin devam ettirilmesi ile ortaya çıkan hatalı ürünün maliyetlerin artmasına yol açmasıdır. Bu iki tip hatanın zararı, kontrol şeması yöntemi ile en aza indirilebilmektedir (Yılmaz ve Yücel, 2015:3).

Kontrol şemalarıyla sürece ilişkin yorumların yapılması; grafiğe ait parametrelerle, önceden belirlenmiş bazı kurallara göre olmakla birlikte kontrol şemaları üzerinde oluşan şekillerin yorumlanması ile de gerçekleştirilmektedir. Bu şekiller, sürecin normal olması durumunda normal dağılıma uygun görünmekteyken süreç kontrol dışına çıktığında sürecin ortalama değeri ve dağılımı değişmekte, farklı şekiller oluşabilmektedir. Kontrol şemalarında gözlenen doğal örüntüler kadar doğal olmayan örüntüleri tanıma da süreç iyileştirme için değerli bilgiler sağlamaktadır (Bargash ve Santarisi, 2004:636; Cheng ve Cheng, 2009:311-312; Öztemel, 2012:126).

Literatürde en çok karşılaşılan kontrol şeması örüntüleri; normal, tekrarlayan çevrim, aşağı eğilim, yukarı eğilim, aşağı ani kayma, yukarı ani kayma gibi altı farklı örüntü tipinden biriyle gösterilmektedir (Cheng ve Cheng, 2009:312; Gauri, 2010:1062; Kiran ve diğerleri, 2010:194; Lopez ve diğerleri,2012:5; Noskievicova, 2013:2; Olgun, 2011:2; Öztemel,



2012:128; Sağiroğlu ve diğerleri, 2000:141; Wu, 2010:3465). Şekil 1 kontrol şemalarında gözlenen normal ve normal olmayan örüntüleri göstermektedir.



**Şekil 1:** Kontrol Şeması Örüntüleri

Normal örüntü, üretim hattında her şeyin normal olduğunu, üretimdeki değişikliğin sadece kontrol altında tutulamayan faktörlerden kaynaklandığını göstermektedir. Eğilimler, aşağı ya da yukarı yönde olabilen sürekli hareketlerdir ve kalite karakteristiğindeki ortalama değer zaman içerisinde artmakta ya da azalmaktadır. Ani kayma olarak adlandırılan örüntüler ise süreç ortalamasındaki ani ya da beklenmedik bir değişim olarak tanımlanmaktadır; artma ya da azalma olarak ortaya çıkabilmektedir. Tekrarlayan Çevrim, çevresel koşullardaki sistematik değişimlerden kaynaklanan, kalite karakteristiğinde zaman içerisinde birbirini tekrar eden periyodik şekillerin oluşması durumudur (Cheng ve Cheng, 2009:311-312; Öztemel, 2012: 128; Olgun, 2011:25).

Günümüz üretim sistemleri, klasik kontrol semalarıyla açıklanamayacak kadar karmaşıklaşmıştır. Bilgisayar teknolojilerindeki gelişmeler, karmaşık ve büyük ölçekli problemleri karar verme yöntemleri kullanılarak çözmeyi mümkün kılmıştır (Mitra, 2008:7). Bu nedenle süreç verilerinin çevrim içi saklandığı ve analiz edildiği günümüzün otomasyona dayalı üretim ortamında kalite kontrol için otomatik örüntü tanıma geliştirme ihtiyacı gerekli olmaktadır. Yapay Zeka (YZ) teknikleri ile oluşturulan sistemler sayesinde bu işlemler daha kısa sürede gerçekleşmektedir (Kaya ve diğerleri, 2005:93).

Yapay Sinir Ağları (YSA) (Artificial Neural Networks (ANN)), değişkenler arasında karmaşık, karşılıklı etkileşimin bulunduğu durumlarda ya da tek bir çözüm kümesinin bulunmadığı durumlarda başarılı sonuçlar üreten bir YZ tekniğidir (Benli, 2005:34). Yapısı ve fonksiyonları, insan beynine ait biyolojik sinir sisteminin yapısına ve bilişsel süreçlerine dayanmaktadır. İnsan beyninin hesaplama yöntemlerini taklit etme ve biyolojik sinir sistemlerini anlama ile ilgilenen bilim adamları tarafından geliştirilmiş modeller sınıfıdır (Shachmurove, 2002:8). Beynin tüm fonksiyonları bilinmediği için belirli oranlarda benzetim yapılarak karar verme algoritmaları geliştirilmiştir. Böylece; insan beyninin özelliklerinden olan öğrenme yoluyla yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri, herhangi bir yardım almadan otomatik olarak yapmak amacıyla modellenen bilgisayar sistemleri ortaya çıkmıştır (Yılmaz, 2014:35). Bilgisayar sistemleri önce bir örnek almakta ve bu örnekten bazı bilgileri öğrenmekte, daha sonra ikinci örneğe bakarak biraz daha bilgi edinmekte, öğrenilecek olay ile ilgili bütün örnekler defalarca gözden geçirilerek tekrarlaması sonucunda ise olayla ilgili genellemeler yapmaktadır (Nabiyev, 2010:537; Öztemel, 2012:21-22,31). YSA'nın eğitilmesi olarak tanımlanan bu süreç, belirli kurallar çerçevesinde olmaktadır ki bu kurallara öğrenme kuralları adı verilmektedir. YSA eğitimi için birçok öğrenme kuralı kullanılmaktadır ve bu öğrenme kuralları kullanılan YSA'nın amacı ve ağıın topolojisi ile doğrudan ilişkilidir (Bayır, 2006:30).



Kontrol şemalarında oluşan doğal ve doğal olmayan örüntüleri tanımak, kontrol altındaki süreç koşullarını sürdürmek ve değişkenliğe sebep olan potansiyel nedenleri belirlemek amacıyla YSA kullanılması; bilgi ve deneyimlerin aktarıldığı otomatik sistemlerin süreç hakkında bilgi üretmesini sağlayabilmektedir. Örüntü tanıma/sınıflandırmada YSA kullanılmasının nedeni, YSA'nın karmaşık ve gürültülü örüntü verileriyle çalışabilmesi, sonucun iyi kalitede bir dağılıma ulaşmasıdır. Ayrıca YSA ile oluşturulan modeller uygulamaya geçirildiğinde kalite kontrol problemlerinin çözümünde etkin olarak kullanılabilir.

Genel olarak YSA ile tahmin, sınıflandırma, veri ilişkilendirme, veri kavramlaştırma ve veri filtreleme fonksiyonlarını gerçekleştirmek mümkündür. Bir problemin çözümü için uygulanacak olan YSA modeli öncelikle problemin türüne bağlıdır. Ancak amaçlarına göre en yaygın kullanılan YSA modelleri bulunmaktadır. Bu yaygın kullanılan modeller Tablo 1'de gösterilmektedir.

**Tablo 1.** Kullanım Amaçlarına Göre Yapay Sinir Ağı Modelleri

Kullanım Amacı	Ağlar
Tahmin	<ul style="list-style-type: none"><li>• Çok Katmanlı Algılayıcılar (ÇKA) (Multi Layered Perceptrons)</li></ul>
Sınıflandırma	<ul style="list-style-type: none"><li>• Doğrusal Vektör Kuantizasyon (DVK) (Learning Vector Quantization (LVQ))</li><li>• Savaşçı Yayılım (Counter-Propagation)</li><li>• Olasılık Sinir Ağı (OSA) (Probabilistic Neural Network (PNN))</li></ul>
Veri İlişkilendirme	<ul style="list-style-type: none"><li>• Hopfield Ağı(Hopfield)</li><li>• Boltzman Makinesi (Boltzman Machine)</li><li>• Hamming Ağı(Hamming Network)</li><li>• Çift Yönlü Çağırışlı Bellek (Bidirectional Associative Memory (BAM))</li><li>• Uzaysal - Mekansal Geçici Örüntü Tanıma (Spatio-Temporal Pattern Recognition)</li></ul>
Veri Kavramlaştırma	<ul style="list-style-type: none"><li>• Adaptif Rezonans Teorisi (ART) (Adaptive Resonance Theory (ART))</li><li>• Kendisini Düzenleyen Harita Ağı (KDHA) (Self Organizing Map (SOM))</li></ul>
Veri Filtreleme	<ul style="list-style-type: none"><li>• Devridaim YSA(Recirculation)</li></ul>

**Kaynak:** Yılmaz, 2014:56

Bu çalışmanın amacı, YSA ile oluşturulan Kontrol Şemalarında Örüntü Tanıma (KŞÖT) modelleri ile ilgili yurt içi ve yurt dışı çalışmalarını incelemek ve hem kalite kontrol alanında hem de YSA konusunda çalışan araştırmacılara rehberlik etmektir. Bu amaç doğrultusunda literatür taraması sonucunda ulaşılan çalışmalar analiz edilmiş; bu çalışmalarda kullanılan YSA modelleri, bu modellerin mimari özellikleri ve diğer yöntemlere göre karşılaştırmalı performansları ortaya konmuştur.

## 2. Yöntem

Kontrol şemalarında oluşan normal ve normal olmayan örüntülerin tanınmasında YSA kullanılması konusunda yapılan çalışmaların ve uygulamaların saptanmasını, derinlemesine incelenmesini ve yorumlanmasını amaçlayan bu araştırma için veriler, nitel araştırma yöntemlerinden biri olan doküman incelemesi yoluyla toplanmıştır.

Doküman incelemesi, konu hakkında bilgilerin yer aldığı yazılı materyallerin analizini ifade etmektedir (Şahin ve Kışla, 2013:82). Bu yöntem, bir araştırma problemi hakkında



belirli zaman dilimi içerisinde ya da değişik aralıklarla üretilmiş dokümanların geniş bir zaman dilimine dayalı analizini olanaklı kılmaktadır (Karadağ, 2014:4)

Bu çalışmada, YSA ile yapılan KŞÖT uygulamaları incelenmiş; kontrol şemalarının kullanım amacı olan kaymaları bulma, süreçteki değişkenlikleri tespit etme, hata sınıflandırma problemleri için YSA kullanımı ile birlikte bu çalışmalarda kullanılan YSA modelleri, YSA girdileri olarak kullanılan veriler ve çıktılarının özellikleri incelenmiştir. Diğer literatür çalışmalarından farklı olarak bu çalışmada, kullanılan YSA modellerine göre sınıflandırma yapılmış ve bu modellerin topolojileri belirlenmiştir. Bununla birlikte farklı YSA modellerinin KŞÖT için performans üstünlüğü ya da alternatif yöntemlere göre üstün olup olmadığı bilgilerine yer verilmiştir.

Bu amaçla, YSA ile yapılmış KŞÖT çalışmalarına ULAKBİM veri tabanı, üniversite kütüphanelerinin elektronik veri tabanları, YÖK tez tarama veri tabanı, Google Scholar veri tabanı gibi pek çok veri tabanı kullanılarak ulaşılmış, bu dokümanlar incelenip analiz edilmiştir. Tarama yapılırken “örüntü tanıma” “kontrol şemalarında örüntü tanıma” ve “yapay sinir ağları” anahtar sözcükleri Türkçe ve İngilizce olarak kullanılmıştır. Ulaşılan kaynaklardan YSA ile yapılmış KŞÖT çalışmaları seçilmiştir. Bu özelliklere sahip 1993-2015 yılları arasında 32 çalışmaya ulaşılmıştır. Bunlardan 2’si yurtdışı 2’si de yurtiçinde olmak üzere toplam 4 tez çalışmasından; 28’i ise yurtdışında çeşitli dergilerde yayımlanmış makalelerden oluşmaktadır.

Araştırmada, doküman incelemesi yöntemi kullanılarak ulaşılan çalışmaların içerik analizleri yapılmıştır. Nitel çalışmalarda dokümanların incelenmesinde kullanılan içerik analizi, metin içeriklerinin ortak yönlerini ortaya çıkarmak amacıyla, önemli olan anlamların yapılandırılmasına ve sınıflandırılmasına yönelik bir yorum biçimidir (Karadağ, 2014:5).

Kontrol şemalarının İSK içerisindeki önemi, YSA’nın örüntü tanımadaki üstünlüğü, YSA’nın yapısal bilinmezlikleri bu konudaki araştırmaları artırmış ve güncelliğini korumuştur. Bu nedenle, kontrol şemalarında örüntü tanımadaki YSA kullanılmasına ilişkin daha önce yapılmış pek çok literatür çalışması (Rajagopalan ve Rajagopalan (1996), Zorriassatine ve Tannock (1998), Kaya ve diğerleri (2005); Masood ve Hassan (2010), Psarakis (2011); Hachico ve Gorbel (2012); Orçanlı ve diğerleri (2015)) bulunmaktadır. Bu çalışmalarda araştırmacılara ve uygulayıcılara yol gösterecek derinlemesine pek çok analiz yapılmıştır.

Rajagopalan ve Rajagopalan (1996), çalışmalarında YSA’nın üretimdeki uygulamalarını görüntü ve örüntü tanıma, yönetsel karar verme, imalat hücre tasarım aracı, durum izleme, gerçek zamanlı robot planlama ve İSK olarak sınıflandırmış; YSA yöntem ve yapısını açıklamıştır. Zorriassatine ve Tannock (1998), alandaki ilk ve en önemli literatür araştırmalarından birisidir. Çalışmalarında; kontrol şemaları ve YSA’nın önemini ortaya koymuşlar, 1989-1997 yılları arasında yapılmış kontrol şeması uygulamalarını geleneksel, algoritmik bilgisayar uygulamaları ve YSA çalışmaları olarak incelemişlerdir. YSA’nın İSK’da kullanım amaçlarını, kullanılan modelleri, modellerin mimari yapılarını ve sonuçlarını sunmuşlardır. Kaya ve diğerleri (2005), çalışmalarında YSA’nın genel olarak kalite kontrol problemlerindeki uygulamalarını araştırmışlar ve kalite kontrolün, Kontrol Şemaları, Süreç Kontrolü, Deney Tasarımı, Çevrim içi Kalite Kontrol, Kabul Örnekleme gibi alanlarında YSA uygulamalarının olduğunu belirlemişlerdir. Bu alanları alt alanlara ayırarak, kontrol şemaları çalışmalarını kontrol şemalarını oluşturma, izleme, üzerinde oluşan şekillere yönelik



örüntü/desen tanıma, yorumlama, sınıflama ve tahmin etme gibi başlıklarla gruplamışlardır. Bu gruplardaki çalışmalar ve diğer alt alanlarla birlikte kullanılan YSA ağ modelleri ve modellerin özet bilgilerine yer vermişlerdir. Masood ve Hassan (2010), çalışmalarında YSA temelli KŞÖT gelişmelerini performans ve yetenek açısından değerlendirmişlerdir. Konuların, 1980'lerin sonundan 1990 başlarına kadar YSA ile KŞÖT yapılabilirliği; 1990'ların sonuna doğru çevrim içi kalite kontrol, denetimsiz YSA; 2000'li yıllarla birlikte ise çok değişkenli süreç görüntüleme ve tanı konularına doğru bir gelişim gösterdiğini ortaya koymuşlardır. Çalışmada bu gelişim; üretilmiş verilerle yapılan tasarım, eğitim, test, geçerlik uygulamalarından gerçek verilerle eğitilmiş KŞÖT ile örüntü sınıflandırma uygulamalarına yönelik olarak özetlenmiştir. Psarakis (2011) çalışmasında; süreçte ortalama ve varyans saptanması, örüntü tanıma, süreç verilerindeki kaymaları tanıma, çok değişkenli İSK şemaları konularındaki YSA uygulamalarının mimarileri ile performanslarını incelemiştir. Bu uygulamaları geleneksel şemaları uygulamalarıyla karşılaştırmıştır. YSA'nın süreçteki değişkenlikleri tespit etme ve tanımda daha doğru ve hızlı sonuçlar verdiğini, bununla birlikte bu uygulamaları en iyi hale getirmek için çalışmaların devam etmesi gerektiğini ortaya koymuştur. Hachicha ve Gorbel (2012), 1991-2010 yılları arasında yapılmış olan çalışmaları süreç ortalaması ya da kaymaların tahmini, değişim noktaları belirleme, doğal olmayan örüntü tespitleri olarak sınıflandırmışlardır. Bu amaçla; veri modelinin varsayımları, kontrol şemalarında ne çalışıldığı, tek zamanlı ve eş zamanlı kontrol şeması türleri, verinin girdi türleri, KŞÖT algılaması için kullanılan yaklaşımlar, veri türleri ve performans kriterleri göz önünde bulundurularak çalışmalar özetlenmiştir. Sınıflandırma kriterleri Hachicha ve Gorbel (2012)'e paralel olarak yapılan bir başka literatür araştırmasında, Orçanlı ve diğerleri (2015), çok değişkenli kontrol şemalarındaki örüntü tanıma çalışmalarını sunmuşlardır.

### 3. Literatür İncelemesi

Kontrol şeması örüntüleri geleneksel olarak elle analiz edilmekte ve yorumlanmaktadır. 1980'lerin sonuna doğru, pek çok araştırmacı kontrol şemalarının analizi ve yorumu için Uzman Sistemler'in kullanımını önermiştir. Daha sonraları, bilgi sistemlerinde yaşanan hızlı ve akıllı teknolojilere dayalı gelişmeler araştırmacıları cesaretlendirmiş ve YSA kullanımına ilişkin çalışmalara yönelmiştir (Hassan ve diğerleri, 2003:1588). Bu çalışmada, YSA ile yapılan KŞÖT çalışmaları incelenmiş, özetlenmiştir. Çalışmalara ilişkin girdi, çıktı, kullanılan YSA modelleri ve topolojileri Tablo 2'de; modellerin kendi aralarında ve diğer alternatif yöntemlerle karşılaştırmaları Tablo 3'te gösterilmiştir.

Pham ve Öztemel (1993), çalışmalarında 6 temel örüntü şeklini tanımayı amaçlayan YSA modelleri oluşturmuşlardır. Girdi olarak bir üretim sürecinden alınan 60 gözlem değerini kullanmışlardır. Bu modeller için Geri Yayılım ÇKA tipi YSA ve DVK tipi YSA modellerini tek tek ve birlikte kullanmışlardır. DVK ve ÇKA tipi YSA birlikte kullanıldığında (%99.1), sadece ÇKA (%95.2) ve sadece DVK (%97.7) ağlarına göre daha yüksek doğruluk oranı ile tanıma gerçekleştirdiğini ortaya koymuşlardır.

Stützle (1995), çalışmasında geleneksel kalite kontrol şemalarını YSA modeliyle karşılaştırmıştır. Bu amaçla, benzetimle oluşturulmuş her biri 6 gözlem değerinden oluşan girdiler kullanarak, kontrol şemalarındaki Tip I ve Tip II hataların sayısını tespit etmek üzere Geri Yayılım ÇKA tipi bir YSA modeli oluşturmuştur. Bu modeli geleneksel kontrol



şemalarının sonuçlarıyla karşılaştırdığında; hataları yanlış sınıflandırma sayısının (606 örnek üzerinden) YSA modeli için 39, klasik kontrol şemaları için 80 olduğunu ve YSA'nın daha başarılı olduğunu ortaya koymuştur.

Cheng (1997), çalışmasında Geri Yayılım ÇKA ve Modüler YSA olmak üzere iki farklı YSA modeliyle KŞÖT oluşturmuştur. 16 gözlem değerinden oluşan girdi kullanarak 5 farklı örüntü şeklini tanımayı amaçladığı YSA modellerinin performanslarını karşılaştırmıştır. Modüler YSA modelinin (%93.1) ÇKA modeline göre (%83.2) daha yüksek doğruluk oranında örüntü tanıma sağladığını ortaya koymuştur. Bu modelin diğer yaklaşımlardan daha çok hesaplama gerektirmesine karşın daha kolay, sürece cevap vermesinin daha hızlı olduğunu ve süreç ortalamasındaki kaymaları bulmada da başarılı sonuçlar verdiğini belirtmiştir.

Pham ve Wani (1997), çalışmalarında kontrol şeması örüntüleri için gözlem değerleri dışında farklı girdiler kullanarak yeni bir yaklaşım önermişlerdir. Bu girdiler; hat geçişindeki sayılar, döngü üyeliği, eğim, alan gibi kontrol şemalarındaki örüntülere ait 9 şekil özelliğinden oluşmaktadır. Kontrol şemalarında gözlenen 6 farklı örüntü tipini tanımak üzere Geri Yayılım ÇKA tipi YSA, Karar Ağaçları, İndüksiyon yöntemlerini karşılaştırmışlardır. Sonuçlar, önermiş oldukları veri yaklaşımının diğer yaklaşımlara göre (literatürdeki değerlerle karşılaştırma) daha iyi sonuçlar verdiğini; yöntemler karşılaştırıldığında ÇKA'nın (%99.0) sezgisel (98.4) ve indüksiyon (94.0) yöntemlerine göre daha yüksek tanıma sağladığını ortaya koymaktadır.

Anagün (1998), çalışmasında Geri Yayılım ÇKA tipi YSA kullanarak 9 farklı örüntü şeklini tanıyan iki farklı model oluşturmuştur. Modellerden birincisinde 60 gözlem değerinden oluşan verileri kullanırken ikincisinde veri noktaları ön işlemden geçirilerek ağa sunulmuştur. Bu süreçte 60 veri noktası, kullanılan sınırların aralığı eşit boyutlu sınıf aralıklarına bölünerek bir histogram formuna dönüştürülmüştür. Böylece birinci modelde veri noktası olarak kullanılan girdiler, ikinci modelde veri yollarının büyüklüğü olarak işlem görmüştür. Sonuçlar, ikinci yöntemdeki veri yaklaşımıyla oluşturulan YSA modelinin (%93.4) verilerin düz gösterimi olarak sunulduğu birinci YSA modeline (%82.2) göre daha yüksek tanıma oranı gösterdiğini ortaya koymaktadır.

**Tablo 2. YSA ile Yapılan KŞÖT Çalışmaları**

Çalışma	Girdi	Çıktı	Model	Topoloji
Pham ve Öztemel (1993)	60 gözlem değeri	6 örüntü	ÇKA DVK	60x35x6; 60x36x6
Stütze (1995)	6 gözlem değeri	Tip I/II hata	ÇKA	6x2x2
Cheng (1997)	16 gözlem değeri	5 örüntü	ÇKA Modüler YSA	16x12x5; 16x4x3x5
Pham ve Wani (1997)	9 şekil özelliği	6 örüntü	ÇKA	9x13x6
Anagün (1998)	60 gözlem değeri 60 özellikli veri	9 örüntü	2 farklı ÇKA	60x15x9; 60x15x9
Guh ve Tannock (1999)	56 gözlem değeri	4 örüntü	2 aşamalı ÇKA	56x35x4; 56x35x1



Sağiroğlu ve diğerleri (2000)	60 gözlem değeri	6 örüntü	3 farklı ÇKA	60x40x6; 60x40x6; 60x20x6
Perry ve diğerleri (2001)	64 gözlem değeri	5 örüntü	2 farklı ÇKA	64x2x4; 64x2x5
Hassan ve diğerleri (2003)	20 gözlem değeri 6 istatistik özellik	6 örüntü	2 farklı ÇKA	20x6x6 6x6x6
Bargash ve Santarisi (2004)	6 şekil özelliği	Tip I/II hata	ÇKA	6x15x2
Guh (2004)	24 gözlem değeri	7 örüntü	ÇKA	24x2x7
Pujapanda ve Acharya (2007)	4 gözlem değeri	3 örüntü	ÇKA	4x4x3
Gauri ve Chakraborty (2008)	6 şekil özelliği	8 örüntü	ÇKA	6x15x8
Niaki ve Abbasi (2008)	2 öznitelik 3 öznitelik	3 örüntü 4 örüntü	ÇKA	2x20x3 3x30x4
Cheng ve Cheng (2009)	32 gözlem değeri 40 özellikli veri	7 örüntü	3 farklı KDHA	32x7x7; 32x64x7 40x64x7
Gauri (2010)	32 gözlem değeri 7 şekil özelliği	8 örüntü	ÇKA 2 farklı DVK	7x12x8; 7x128x8 32x72x8
Guh (2010)	60 gözlem değeri 30 özellikli veri	3 örüntü	2 aşamalı DVK	60x28x3 30x30x3
Kiran ve diğerleri (2010)	32 gözlem değeri	7 örüntü	2 farklı ÇKA	32x16x7; 32x17x7
Shaban ve Shalaby (2010)	40 gözlem değeri	4 örüntü	ÇKA	40x30x4
Shaban ve diğerleri (2010)	40 gözlem değeri	3 örüntü	ÇKA	40x30x3
Wu (2010)	32 gözlem değeri	14 örüntü	OSA	32x5x3x14
Addeh vd (2011)	3 özellikli veri	6 örüntü	ÇKA	3x23x6
Awadalla vd (2011)	20 gözlem değeri	6 örüntü	Spiking YSA	20x6x6; 20x6x6
Hassan (2011)	6 istatistik özellik	6 örüntü	ÇKA	6x10x6
Olgun (2011)	60 gözlem değeri 6 istatistik özellik	6 örüntü	2 farklı ÇKA	60x20x6 6x20x6
Kim ve diğerleri (2012)	64 gözlem değeri	5 örüntü	KDHA-ÇKA	64x25x6x6
Laosiritaworn ve Bunjongjit (2013)	6, 9 ve 12 gözlem değeri	4 örüntü	9 farklı ÇKA	6x17x4; 6x20x4; 6x20x18 9x13x4; 9x20x4; 9x19x4 12x18x4; 12x18x4; 12x14x4
Nimbale ve Ghute (2013)	50 gözlem değeri	1 özellik	ÇKA	50x16x1
Ranaee ve Ebrahimzadeh (2013)	10 gözlem değeri 12 özellikli veri	6 örüntü	11 farklı ÇKA	10x15x6; 10x15x6 12x20x6; 12x25x6; 12x15x6 12x25x6; 12x15x6; 12x25x6 12x20x6; 12x15x6; 12x25x6
Muluneh (2014)	30 gözlem değeri	7 örüntü	ÇKA	30x35x7





Yılmaz (2014)	35 gözlem değeri 6 özellikli veri	6 örüntü	2 farklı DVK	35x20x6 6x21x6
El Farishi vd (2015)	8gözlem değeri	3 örüntü	3 farklı ÇKA	8x13x3; 8x13x3; 8x13x3

Guh ve Tannock (1999), çalışmalarında normal olmayan örüntüleri tanımak ve örüntülerin içerdiği anahtar parametreleri tanımlayabilmek için Geri Yayılım YSA temelli bir ardışık örüntü yaklaşımı önermişlerdir. Bu yaklaşım kullanılarak hem tek hem de aynı anda meydana gelen örüntüler tanımlanmıştır. İlk aşamada 56 gözlem değeri kullanarak anormal desenleri tanıyan genel bir sistem oluşturulmuş; ikinci aşamada ise bu sistemden elde edilen, gruplanmış desenlerin detaylı özelliklerini (kayma büyüklüğü, kayma eğilimi, döngü genişliği) belirlemek üzere özel amaçlı bir sistem tasarlamışlardır. Sonuçlar, önerilen modelin (%96.38) hem örüntüleri hem de örüntü parametrelerini eş zamanlı olarak tanımada başarılı olduğunu göstermektedir.

Sağiroğlu ve diğerleri (2000), çalışmalarında 60 gözlem değeri kullanarak 6 farklı örüntü şeklini tanımayı amaçlayan ÇKA tipi YSA modelleri geliştirmişlerdir. Verileri; Esnek Yayılım, Geri Yayılım ve Genişletilmiş Delta-Bar-Delta algoritmaları kullanarak oluşturdukları 3 farklı YSA modeli ile eğitmişlerdir. Geri Yayılım algoritmasının (%97.73) kesin sonuçlar verdiği ve diğer algoritmalarından (Esnek Yayılım: %93.18 ve Genişletilmiş Delta-Bar-Delta: %96.21) daha iyi ve daha hızlı sonuçlar sağladığı görülmüştür.

Perry ve diğerleri (2001), çalışmalarında Geri Yayılım ÇKA tipi YSA kullanarak iki farklı model oluşturmuşlardır. 64 gözlem değerini girdi olarak kullandıkları modellerden birincisinde 4 ikincisinde 5 farklı örüntü şeklini tanımayı amaçlamışlardır. Sonuçlar, ikinci modelin (%99.81) birinciye göre (%99.51) çok az farkla daha yüksek sınıflandırma oranına sahip olduğunu göstermektedir. Bununla birlikte birinci modelin sistemde meydana gelen değişikliklerin erken göstergesi olarak, ikinci modelin ise örüntü desenlerini görüntüleme kullanılabileceği belirtilmiştir. Ayrıca her iki sistemin birlikte kullanılmasıyla Tip I ve Tip II hatalarının azaltacağı da vurgulanmaktadır.

Hassan ve diğerleri (2003), çalışmalarında 6 farklı örüntü şekli tanımayı amaçlayan model iki farklı yaklaşımla eğitilmiştir. Geri Yayılım ÇKA tipi YSA kullanılan modellerde, birinci yaklaşım için 20 gözlem değeri girdi olarak kullanılırken ikinci yaklaşımda kontrol şeması grafiğinden elde edilen ortalama, çarpıklık, basıklık gibi 6 adet istatistik özellik girdi olarak kullanılmıştır. Sonuçlar, istatistik özellik çıkarılarak eğitilmiş YSA temelli örüntü tanıma modelinin (%96.8) ham verilerle eğitilmiş modele göre (%92.5) daha yüksek tanıma sağladığını göstermektedir.

Bargash ve Santarisi (2004), çalışmalarında 8 farklı örüntü şekli için kullandıkları Geri Yayılım ÇKA tipi YSA modelinde, eğitim parametrelerinin YSA üzerindeki etkilerini araştırmışlardır. Bu amaçla, her örüntü tipi için üretilen minimum kayma, kayma miktarı, örnek büyüklüğü, kayma yüzdesi, ağ büyüklüğü ve veri boyutu olmak üzere 6 faktör ile Tip I/Tip II hatalarının tespiti yapılmıştır. Sonuçlar, minimum kayma, kayma miktarı, kayma yüzdesi ve örnek büyüklüğü parametrelerinin Tip I/Tip II hataları üzerinde etkili olduğunu; buna karşın ağ büyüklüğü ve veri boyutunun önemli bir faktör olarak değil YSA'nın zaman ve maliyeti azaltıcı etkisi olduğunu ortaya koymaktadır.



Guh (2004), çalışmasında çevrim içi kalite kontrol örüntü tanıma problemini çözmek için Geri Yayılım YSA eğitim parametreleri grubu ve yapılandırmasını geliştirmek amacıyla YZ tekniklerinden biri olan Genetik Algoritma (GA)'yı kullanmıştır. 7 farklı örüntü şeklini tanımak üzere bir çevrim içi sistemden aktarılan pencere boyutundaki gözlem değerleri girdi olarak kullanılmıştır. Girdi sayısı ve katman sayısı GA ile belirlenmiştir. Çalışmanın sonucu, GA'nın YSA mimarisi ve topolojisini otomatik olarak tanımda etkili olduğunu göstermektedir. Böylece YSA'nın bir dezavantajı olan deneme yanılmayla yapılan zaman alıcı ve çevrim içi sistemlerde etkinliği düşürücü bu sorunun iyileştirilebildiği ortaya çıkmıştır.

Pujapanda ve Acharya (2007), çalışmalarında 3 farklı örüntü şeklini tanımak üzere Geri Yayılım ÇKA tipi bir YSA modeli tanımlamışlardır. Ortalama ve standart sapmadaki kayma ile kayma olmama tespitine dönük bu örüntüleri tanımak üzere 4 gözlem değerini girdi olarak kullanmışlardır. Ağ, üretilmiş verilerle eğitildikten ve test edildikten sonra gerçek değerlerle de sınanmıştır. Sonuçlar, ağın çok yüksek doğruluk oranı (%99,9) ile tanıma gerçekleştirdiğini; modelin ortalama veya varyansa göre küçük/büyük kaymaları tespit edebildiğini göstermektedir.

Gauri ve Chakraborty (2008), çalışmalarında 8 farklı örüntü şeklini tanımak üzere kontrol şemasından elde edilen hata kareleri ortalaması çizgisine ait kayma, toplam kayma, örüntü alanı, varyans oranı ile noktalardan geçen düz çizgiye ait kayma ortalaması, kayma oranı olmak üzere 6 adet özellikli veri grubunu girdi olarak kullanmışlardır. Bu veriler için bir karar ağacı ve Geri Yayılım ÇKA tipi bir YSA modeli geliştirmişlerdir. İki modelin sonuçlarını karşılaştırarak YSA modelinin (%96.28) karar ağaçlarına göre (%95.78) örüntü tanımda daha başarılı olduğunu ve standart sapmanın hata tahminine daha az duyarlı olduğunu ortaya koymuşlardır. Bununla birlikte karar ağaçları yönteminin ilgili şekil özellikleriyle tanımlanan özel örüntü tiplerini açık bir biçimde anlamayı sağlayan görselleştirme avantajını vurgulamaktadırlar.

Niaki ve Abbasi (2008), çalışmalarında çok değişkenli süreç kalitesini göstermek için kontrol şemalarındaki ortalama-sapmaları saptama ve sınıflandırmak için YSA'dan faydalanmışlardır. Bu amaçla, Geri Yayılım ÇKA tipi iki farklı YSA modeli oluşturmuşlardır. Birinci modelde uygunsuzluk oranı ve kusur türü sayısı olmak üzere 2 girdi ve ortalama sapmaya göre belirlenen 3 örüntü şekli olmak üzere 3 çıktı değeri kullanılmıştır. İkinci modelde ise farklı kusur türleri üzerinde sayım yapmak üzere 3 kusur türü girdi olarak kullanılmış, çıkış katmanındaki hangi özneliğin bozulmaya neden olduğunu belirlemek için 4 örüntü şekli çıktı olarak kullanılmıştır. Sonuçlar, her iki modelin de (%99.3) kontrol dışı koşulda oluşan sapmaların mevcut yöntemlerden daha iyi saptandığını, aynı zamanda sapmaların niteliğinin tespit edilmesinde de YSA'nın daha yetenekli olduğunu ortaya koymaktadır.

Cheng ve Cheng (2009), çalışmalarında kontrol şeması örüntü analizi için KDHA tipi bir YSA modeli önermişlerdir. Önerdikleri model basit bir KDHA modeli ve kümeler ayrılmış bir yapıya sahip olan KDHA modelinin karşılaştırması olarak ortaya çıkmaktadır. Girdi vektörünün bileşenleri olarak ham veriler ve Wavelet Analizi ile elde edilen özellikli veriler kullanılarak 7 farklı örüntü şeklini tanımayı amaçlamışlardır. Sonuçlar, önerilen KDHA modelinin (%85.6) basit KDHA'ya göre (%80.95) daha yüksek doğruluk gösterdiğini;



ham verilere kıyasla özellikli veriler kullanıldığında ise önerilen YSA modelinin performansının attığını (%87.88) ortaya koymuşlardır.

Gauri (2010), çalışmasında 8 farklı örüntü şeklini tanımak üzere DVK ve Geri Yayılım ÇKA tipi YSA modelleri oluşturmuştur. ÇKA için 32 gözlem değeri girdi olarak kullanılırken DVK ağı buna ek olarak kontrol şeması alt ve orta çizgilerine ait kayma oranı, toplam kayma, alan değeri gibi 7 şekil özelliğın de girdi olarak kullanılmasıyla iki farklı modelde kullanmıştır. Bu modeller karşılaştırıldığında, özellik temelli DVK ağı (%95.28) ham veriyle oluşturulmuş DVK ağına göre (%93.77) daha yüksek doğru tanıma performansı gösterirken daha uzun sürede öğrenme gerçekleştirmiştir. DVK ve ÇKA ağlarını karşılaştırdığında DVK ağının öğrenme süresinin çok daha kısa olduğunu; performansları arasında önemli bir fark bulunmadığını ancak ÇKA (%96.11)'nın DVK'ya göre daha yüksek doğruluk oranı gösterdiğini ortaya koymuştur.

Guh (2010), çalışmasında kontrol şeması örüntülerinde varyans ve ortalamanın ikisini de eş zamanlı tanıyan YSA temelli aşamalı bir model oluşturmuştur. Geri Yayılım ÇKA tipi YSA kullanılan ilk aşamada 60 gözlem değeri kullanılarak süreçte normal olan ve normal olmayan (ortalama ve varyans anormallığı) olmak üzere üç kategoride sınıflama yapılmıştır. İkinci aşamada ise 24 gözlem değeri ve verilerden hesaplanan 6 istatistik özellikten oluşan 30 özellikli veri girdi olarak kullanılarak daha önce sınıflandırılmış olan 3 farklı örüntü şeklini tanımak üzere DVK temelli bir YSA modeli oluşturulmuştur. Sonuçlar, önerilen YSA modelinin (%98.3) geleneksel X-R (%65.4) ve CUSUM (%89.2) şemalarına göre daha yüksek örüntü tanıma gerçekleştirdiğini; aynı zamanda ortalama ve varyans sapmalarının da saptanmasında mevcut yaklaşımlardan daha iyi bir performans gösterdiğini ortaya koymaktadır.

Kiran ve diğerleri (2010), çalışmalarında 7 farklı örüntü şeklini tanımak üzere YSA temelli örüntü tanıyıcı oluşturmuşlardır. ÇKA tipi model için 32 gözlem değeri girdi olarak kullanılmış, Gradyan Azalma (traindx) ve Esnek Geri Yayılım (trainrp) algoritmaları olmak üzere iki farklı eğitim algoritmasının performansları değerlendirilmiştir. Algoritmalar, eğitimin erken durdurulması/durdurulmaması için de incelenmiş; her iki durumda da Gradyan Azalma'nın (%94.25 ve %93.20) Esnek Geri Yayılım'a (%92.22 ve %92.10) göre daha yüksek doğrulukta tanıma gerçekleştirdiği ortaya konmuştur.

Shaban ve Shalaby (2010), çalışmalarında 4 farklı örüntü şeklini tanımak üzere iki aşamalı Geri Yayılım ÇKA tipi bir YSA modeli önermişlerdir. 40 gözlem değerini girdi olarak kullandıkları modelin birinci aşamasında normal ve yukarı kayma/eğilim örüntülerini tanımaya yönelik sistemle diğer tüm kalıpları bilinmeyen olarak değerlendirmişlerdir. İkinci aşamada girdi veri işaretlerini tersine çevirerek aşağı kayma/eğilim örüntü şekillerini de tanımayı amaçlamışlardır. Böylece, bilinmeyen kalıpları bilinene dönüştürmüşlerdir. Sonuçlar önerilen model çok yüksek tanıma oranına (%99.8) sahip olduğunu göstermektedir. Bu nedenle çalışmada, modelin otomatik üretim ortamları için uygun olduğu, süreçteki değişkenlikleri tespit etmede bir yalın araç olarak uygulanabileceği vurgulanmaktadır.

Shaban ve diğerleri (2010), çalışmalarında 3 farklı örüntü şeklini tanımak üzere Geri Yayılım ÇKA tipi YSA modeli ile KŞÖT oluşturmuşlardır. Girdi olarak 40 gözlem değerini kullandıkları modelin performansı, örüntü tiplerinin doğru tanınması ve bu sonuçların önceki araştırma çalışmalarıyla karşılaştırılması ile değerlendirilmiştir. Sonuçlar, ağın tanıma



başarının yüksek olduğunu (%99.55) ve önceki rapor edilen sonuçlardan daha üstün olmasa da karşılaştırılabilir olduğunu göstermektedir.

Wu (2010), çalışmasında toplu üretimde verimliliği ve etkililiği arttıran güçlü bir üretim stratejisi olan hücresel üretime yönelik bir KŞÖT uygulaması yapmıştır. Bu amaçla, 14 farklı örüntü şeklini tanımak üzere Olasılık Sinir Ağı (OSA) tipinde bir YSA modeli oluşturmuştur. 32 gözlem değerinden oluşan girdi verilerini 5 farklı Wavelet fonksiyonu kullanarak 3 seviyeye ayırmış ve bunlar için doğru tanıma oranlarını belirlemiştir. Önerdiği model ile yüksek tanıma oranı (%98.5), basit yapı, hızlı uyum, yüksek düşük tip I/ II hatası gibi sonuçlara ulaşmış ve bu modelin hücresel üretimde kullanılabilir olduğunu ortaya koymuştur.

Addeh vd (2011), çalışmalarında, KŞÖT için farklı özelliklerle eğittiği Geri Yayılım ÇKA tipi 3 YSA modelini birleştirdiği bir hibrit model önermiştir. Girdi olarak ortalama, örüntü-orta çizgi arasındaki alan ve sinyal genişliği olmak üzere istatistik ve şekil özelliklerinden oluşan 3 özellik tanımlanmıştır. Bu özellikleri tek tek ve birlikte girdi olarak kullanarak ikişerli gruplara ayırdığı toplam 6 farklı örüntü şeklini tanımak üzere tasarlamış ve ağırları eğitmiştir. Modelleri birleştirerek oluşturduğu hibrit YSA modelinin doğru tanıma oranını belirlemiştir. Sonuçlar, önerilen hibrit modelin (%99.21) girdilerin tek tek tanımlandığı ağlara (sırasıyla %97.15, %99.16 ve %99.06) göre daha yüksek tanıma oranına sahip olduğunu görülmektedir.

Awadalla vd (2011) çalışmalarında KŞÖT için kullanılabilir yeni nesil Spiking YSA (SYSA) modeli önermişlerdir. Temel mimari yapısı diğer sinir ağları gibi olan bu ağlarda zaman, bilgi sunumu ve işlenmesi için önemli bir özellik olarak değerlendirilmektedir. Katmanlar arasında gecikme ve ağırlık ile ilişkili sinaptik terminal bulunmaktadır. Bu çalışmada 6 farklı örüntü şeklini tanımak üzere 20 gözlem değeri kullanılmıştır. Geri Yayılım ÇKA tipi bir YSA modeli; tek bağlantılı ve çok bağlantılı terminallere sahip olan iki farklı SYSA modeli geliştirilmiştir. SYSA için ağırlık, gecikme, zaman ve sinir eşik güncellemeleri yapılarak performansları ölçülmüştür. Doğru tanıma oranları karşılaştırıldığında, çok bağlantılı SYSA (%98.61) modelinin, tek bağlantılı SYSA (%94.06) modeline ve basit ÇKA (%86.769) modeline göre daha başarılı olduğu ortaya çıkmaktadır. Sonuçlar, önerilen modeldeki ağırlık, gecikme, zaman ve sinir eşik gibi iyileştirmelerin ek öğrenme kuralları sağladığını ve performansta önemli bir artış sağladığını göstermektedir.

Hassan (2011), çalışmasında 6 farklı örüntü şeklini tanımak üzere iki alternatif şema sunmaktadır. İlk modelde doğrudan sürekli tanımaya dayanan bir sistem, ikincisinde ise yalnızca gerektiğinde tanıma temelli bir sistem oluşturulmuştur. ÇKA tipi YSA kullanılan modellerde farklı bir eğitim algoritması, Broyden, Fletcher, Goldfarb, Shanno (BFGS) Quasi-Newton ile ağ eğitilmiştir. Modellerde, ortalama, standart sapma, CUSUM istatistiği, otokorelasyon ve kareler ortalaması olmak üzere 6 istatistik özellik girdi olarak kullanılmıştır. Ağın performansı, doğru tanıma yüzdesi, ortalama çalışma süreleri temel alınarak değerlendirilmiştir. Birinci modelin tanıma oranı (%78.8) ikinci modelin tanıma oranı (%71) daha yüksek olmasına karşın, ortalama çalışma süreleri karşılaştırıldığında ikinci modelin (212.0) birinci modele (89.3) kıyasla önemli ölçüde daha iyi olduğu görülmektedir. Bu nedenle, sonuçlar, çevrimiçi tanınmanın ancak gerektiğinde yapılması gerektiğini ortaya koymaktadır.

Olgun (2011), çalışmasında 6 farklı örüntü şeklini tanımak üzere Geri Yayılım YSA ve Bayes Sınıflandırıcı ile örüntü tanıma sistemleri oluşturmuştur. ÇKA tipi YSA kullandığı 2



farklı modelden birincisinde 60 gözlem değeri, ikincisinde ise çarpıklık, basıklık, standart sapma gibi 6 istatistik özellik girdi olarak kullanılmıştır. ÇKA modelleri için doğru tanıma oranlarını karşılaştırarak özellikli verilerle oluşturulan modelin (%97.85) ham verilerle oluşturulan modele göre (%96.70) daha yüksek performans gösterdiği belirlenmiştir. Bayes Sınıflandırıcı ile oluşturulan sistem için doğruluk oranları özellikli veri (%99.2) ve ham veri (%91.56) hesaplanarak her iki yöntem ile oluşturulan örüntü tanıyıcılarının sınıflandırma performansları karşılaştırılmış, Bayes Sınıflandırıcı'nın daha iyi sonuç verdiği ortaya konmuştur.

Kim ve diğerleri (2012), çalışmalarında, 5 farklı örüntü şeklini tanımak üzere Wavelet dönüşümlü KDHA-ÇKA tipi bir YSA modeli önermişlerdir. Girdi olarak 64 gözlem değerinin kullanıldığı çalışmada, kontrol şemalarından detaylı ve anlamlı bilgi üretmek için Wavelet dalgacık analizi ile zaman-şekil ve zaman-frekans katsayıları üretilmiştir. Daha sonra çift yönlü KDHA ağı kullanılarak KDAH giriş haritasından uzaklığa dayalı özellikler çıkarılmıştır. En son olarak da Geri Yayılım ÇKA ile örüntüler sınıflandırılmıştır. Önerilen yöntemin doğruluğu (%98.08) literatürdeki farklı çalışmalarla karşılaştırılarak performansın daha iyi olduğu ortaya konmuştur. Yöntemin çok değişkenli kontrol şemaları için genişletilmesi gerekliliği önerilmiştir.

Laosiritaworn ve Bunjongjit (2013), çalışmalarında YSA ile oluşturduğu KŞÖT modelini gerçek üretim sürecine göre tasarlamış ve test etmişlerdir. Geri Yayılım ÇKA tipi model ile 3 ürün için 4 farklı örüntü şeklini tanımak üzere oluşturdukları model için 6,9 ve 12 gözlem değerini girdi olarak kullanmışlardır. Çalışmada KÖT için sınıflandırma yapma üzere K-En Yakın Komşu ve Karar Ağaçları yöntemlerini de YSA modeli ile karşılaştırarak en iyi tanıma performansını gösteren model tespit edilmiştir. Sonuçlar, K-En Yakın Komşu tekniğinin (%97.62) YSA modeli (%88.72) ve Karar Ağaçları (%86.59) yöntemlerine göre daha iyi tanıma oranı gösterdiğini ortaya koymaktadır. Girdi sayıları karşılaştırıldığında en iyi sonucu her üç ürün için de 12 gözlem değerinden (ortalama olarak; 12 için: %97.62, 9 için: %97.13 ve 6 için: %96.93) elde ettikleri görülmektedir.

Nimbale ve Ghute (2013), çalışmalarında kusur/kusursuzluk oranını görüntülemek için Geri Yayılım ÇKA tipi bir YSA modeli geliştirilmişler ve klasik kontrol şeması ile (p-şeması) karşılaştırmışlardır. Girdi olarak 50 gözlem değeri kullanılmış ve farklı kayma noktalarına göre sürecin kontrol altında olup olmadığı incelenmiştir. Geleneksel kontrol şeması ve YSA modelinin performansı, ortalama çalışma süresi aracılığıyla değerlendirilmiştir. Sonuçlar, YSA modeli için örüntü tanıma oranının (%97) yüksek olduğunu, bununla birlikte ortalama çalışma süresi performansının da p-şemalarından daha iyi olduğunu göstermektedir. Ancak YSA modelinin küçük kaymaları izlemede daha etkili olduğu, büyük değişim için en uygun yöntemin olmadığı ortaya konmuştur.

Ranaee ve Ebrahimzadeh (2013), çalışmalarında YSA temelli en iyi KŞÖT uygulamasını önermek üzere farklı eğitim algoritmaları ve veri yaklaşımları kullanmışlardır. Bu amaçla, ÇKA tipi modeller oluşturmuşlardır. 10 gözlem değeri ve 12 özellikli veri (kayma, ortalama kayma, kayma farkı, örüntü ve hat çizgileri arası alanlar, geçiş sayılarından oluşan şekil özellikleri ile standart sapma, çarpıklık, basıklık, otokorelasyondan oluşan istatistik özellikler) girdi olarak kullanılarak 6 farklı örüntü şeklini tanıyan modeller oluşturmuşlardır. Bu modeller için her biri ÇKA tipi YSA'na ait olan 9 farklı eğitim algoritması kullanmışlar ve en iyi eğitim algoritması olarak Levenberg–Marquardt (LM)



(%99.13) belirlemişlerdir. Sonuçlar, diğer algoritmalar için performans sırasına göre; Ölçeklendirilmiş Eşlenik Gradyan (%99.08), Powell/Beale Başlatmalı Eşlenik Gradyan (%99.01), Esnek Yayılım (%98.74), Fletcher-Powell Eşlenik Gradyan (%98.93), Polak-Ribie' re Eşlenik Gradyan (%98.83), Tek Adımlı Quasi-Newton (%98.75), Değişken Öğrenme Oranı (%98.33), BFGS Quasi-Newton (%98.36) olarak ortaya konmuştur. Çalışmada ayrıca, LM ile eğitilen ham veri ve özellikli veri yaklaşımlarının karşılaştırmaları da saptanmıştır. Sonuçlar, özellikli veri (%99.66) yaklaşımının ham veri (%94.8) yaklaşımına göre daha yüksek performansa sahip olduğunu göstermektedir.

Mulneh (2014), çalışmasında Geri Yayılım ÇKA kullanarak 7 farklı örüntü şeklini tanımak üzere çok değişkenli kontrol şemalarına ilişkin bir örüntü tanıma sistemi oluşturmuştur. Girdi olarak 30 gözlemin  $T^2$  değerleri ağa alınmıştır. Oluşturulan modelin tanıma performansı (%94.9) ölçüldükten sonra üretim işletmesine ait gerçek değerlerle veri dönüşümü yapılarak YSA modeli kullanılmıştır. Sonuçlar sistemin üretim sürecinden alınan verileri başarılı bir şekilde normal olan örüntü tanıma altında sınıflandırabildiğini ve modelin kullanılabilir olduğunu göstermektedir.

Yılmaz (2014), çalışmasında 6 farklı örüntü şeklini tanımak üzere DVK temelli YSA modeli kullanarak KŞÖT sistemi oluşturmuş ve görsel programını hazırlayarak uygulamaya dönük hale getirmiştir. Bu sistem için 2 farklı DVK ağı kullanmış ve en iyi sonucu veren ağ kodlanarak uygulama haline dönüştürmüştür. Ham verilerin kullanıldığı birinci modelde 35 gözlem değeri, ikinci modelde ise kontrol şemalarına ilişkin sınırlar, standart sapma, ortalama gibi 6 özellik girdi olarak belirlenmiştir. Sonuçlar, ham veri ile oluşturulan modelin (%98) özellikli verilerle oluşturulan modele (%96) göre daha yüksek doğru tanıma oranına sahip olduğunu göstermektedir. Ayrıca çalışmada, bir üretim işletmesine ait gerçek değer kullanılarak model kullanılmış ve işletme verilerinin normal olan ve olmayan örüntüler şeklinde başarılı bir şekilde sınıflandırılabilirdiği ortaya konmuştur. Bu nedenle, önerilen modelin görsel program aracılığıyla endüstri uygulamalarında uygulaması da kolaylaşmaktadır.

El Farishi vd (2015), çalışmalarında 3 farklı örüntüyü tanımak üzere farklı sayıdaki gözlem değerlerinden oluşan girdilerle YSA modelleri oluşturmuşlardır. ÇKA tipi bu YSA modelleri için Geri Yayılım, Gradient Descent (Gradyan Azalma) ve Levenberg –Marquardt olmak üzere üç farklı eğitim algoritması kullanmışlar ve çeşitli mimari biçimler test edilmiştir. Sonuçlar, 8 örnek büyüklüğü ve 13 gizli katmandan oluşan bir ağ yapılandırmasının her eğitim algoritması için en iyi performansı sağladığını göstermektedir. Bununla birlikte Levenberg-Marquardt algoritmasının mükemmel tanıma oranına (%99.9) sahip olduğu ortaya konmuş ve araştırmacılara önerilmiştir.



**Tablo 3. YSA ile Yapılan KŞÖT Çalışmalarında Kullanılan Yöntemlerin Karşılaştırmaları**

Çalışma	YSA Modeli	Karşılaştırma	En Yüksek Doğruluk
Pham ve Öztemel (1993)	ÇKA,	Geri Yayılım ÇKA,	DVK+ÇKA
	DVK,	DVK,	
Stützel (1995), Guh (2010)	DVK+ÇKA	DVK+ Geri Yayılım ÇKA	Geri Yayılım ÇKA DVK
	ÇKA	Geleneksel Kontrol Şemaları, YSA Kontrol Şemaları	
Nimbale ve Ghute (2013)	ÇKA	ÇKA	Geri Yayılım ÇKA
Cheng (1997)	ÇKA	Geri Yayılım ÇKA,	Modüler YSA
	Modüler YSA	Modüler YSA	
Pham ve Wani (1997)	ÇKA	Geri Yayılım ÇKA,	ÇKA
		Karar Ağacı İndüksiyon Tekniği	
Sağiroğlu ve diğerleri (2000)	ÇKA	Esnek Yayılım ÇKA,	Geri Yayılım ÇKA
		Geri Yayılım ÇKA, Genişletilmiş Delta-Bar-Delta ÇKA	
Gauri ve Chakraborty (2008)	ÇKA	Geri Yayılım ÇKA	ÇKA
		Karar Ağacı	
Cheng ve Cheng (2009)	KDHA	Basit KDHA, Kümelemeli KDHA	Kümelemeli KDHA
Gauri (2010)	ÇKA,	Geri Yayılım ÇKA,	Geri Yayılım ÇKA
	DVK	DVK	
Kiran ve diğerleri (2010)	ÇKA	Esnek Yayılım ÇKA,	Gradyan Azalma ÇKA
		Gradyan Azalma ÇKA	
Awadalla vd (2011)	ÇKA	Geri Yayılım ÇKA, Spiking YSA	Spiking YSA
Olgun (2011)	ÇKA	Geri Yayılım ÇKA,	Bayes Sınıflandırıcı
		Bayes Sınıflandırıcı	
Laosiritaworn ve Bunjongjit (2013)	ÇKA	Geri Yayılım ÇKA,	K-En Yakın Komşu
		K-En Yakın Komşu, Karar Ağaçları	
Ranaee ve Ebrahimzadeh (2013)	ÇKA	Esnek Yayılım ÇKA, Ölçeklendirilmiş Gradyan ÇKA, Polak-Ribie' re Gradyan ÇKA,	Levenberg–Marquardt ÇKA
		Powell/Beale Gradyan ÇKA, Fletcher-Powell Gradyan ÇKA, BFGS Quasi-Newton ÇKA, Tek Adımlı Quasi-Newton ÇKA, Levenberg–Marquardt ÇKA	



---

		Değişken Öğrenme Oranı ÇKA	
		Geri Yayılım ÇKA,	
El Farishi vd (2015)	ÇKA	Gradyan Azalma ÇKA,	Levenberg–Marquardt ÇKA
		Levenberg–Marquardt ÇKA	

---

Tablo 3 incelendiğinde, literatür incelemesi yapılan çalışmalar içerisinde farklı yöntemler uygulanarak bunların YSA modellerinin performansları ile olan karşılaştırmaları; farklı öğrenme algoritmaları ile eğitilen YSA modelleri ve farklı tipteki YSA modellerinin kendi aralarındaki karşılaştırmaları görülmektedir.

#### 4. Bulgular ve Sonuç

Günümüz koşullarında, artan rekabet ve teknolojik gelişmelerle birlikte kalite işletmeler için en önemli anahtar güç haline almıştır. Kalite kontrol şemaları, süreçteki hataları önceden tespit etmek ve gerekli düzeltici önlemleri almak üzere İSK içerisinde önemli bir görev olarak yer almaktadır. Kontrol şemaları, parametre ortalamalarındaki herhangi bir kaymayı bulmak için kullanılmaktadır. Ancak geleneksel yolla bu analizleri yapmak günümüz koşullarında yeterli olmamaktadır. YSA ile oluşturulan akıllı sistemler, kontrol şemaları üzerinde oluşan normal ya da normal olmayan örüntüleri analiz etmede oldukça önem arz etmektedir. Bilgisayarlar aracılığıyla, örnekler kullanılarak girdiler ve çıktılar arasında ilişkiler kurup sınıflandırabilme yeteneği nedeniyle YSA ile kontrol şemalarında örüntü tanıma çalışması yapılabilmektedir. Özellikle gözlemlenen süreç verilerinin herhangi bir istatistik dağılıma ihtiyaç duymaması ve gürültülü (normal olmayan) verilerin işlenebilmesi nedeniyle YSA başarılı sonuçlar vermektedir.

YSA ile yapılan kontrol şemalarında örüntü tanıma çalışmalarının 1980'lerin sonunda başladığı göz önünde bulundurulduğunda, bu konudaki araştırma ve uygulamaların artan bir eğilim gösterdiği görülmektedir. Bu çalışmada, 1990'ların sonuna kadar tespit edilen çalışmaların sayısı 6 iken 2000-2009 yıllarında bu sayı 9 ve 2010-2015 yıllarında 17'dir. Sonuçlar, üretim sürecinin kontrol altında olup olmadığına karar vermek amacıyla KŞÖT uygulamalarında YSA'nın başarıyla uygulanabildiği ve İSK'ya alternatif bir yöntem olarak kullanılabileceği görülmektedir.

Çalışmalar, kontrol şemalarının İSK'da kullanım amaçlarına göre incelendiğinde; YSA ile oluşturulan modellerin, TipI/TipII hatalarını tanıma, süreç ortalaması ve süreçteki değişikliklerin çeşitliliğini saptama; kontrol dışı, ortalama sapmalar, varyans sapmalarını tanımlama ve sapmaların niteliğini tespit etme konularında yüksek doğruluk oranlarıyla başarılı sonuçlar verdiği ortaya konmuştur. Modellerin başarı performansları değerlendirilirken yüzdelik tanıma oranı ölçücünün kullanıldığı; ancak son yıllardaki çalışmalarda bu orana kontrol şemaları ortalama çalışma sürelerinin de dahil edilmesi gerekliliği belirtilmektedir.

Kullanılan YSA modellerine göre çalışmalar incelendiğinde; Çok Katmanlı Algılayıcılar (ÇKA), Doğrusal Vektör Kuantizasyon (DVK), Olasılık Sinir Ağı (OSA), Kendini Düzenleyen Harita Ağı (KDHA), Modüler YSA ve bunların birlikte ya da aşamalı kullanıldığı bileşik, hibrit YSA modelleri tespit edilmiştir. Bu modellerin içerisinde en çok kullanılan modelin ÇKA, ÇKA modeli için en çok kullanılan öğrenme algoritmasının ise Geri





Yayımlım olduğu görülmektedir. ÇKA modellerinin kendi içerisinde farklı algoritmalarla eğitilip karşılaştırmalı sunulduğu çalışmalarda ise Levenberg–Marquardt ÇKA ve Geri Yayımlım ÇKA'nın diğer algoritmalarla eğitilmiş ÇKA modellerine göre daha yüksek doğruluk oranı gösterdiği belirlenmiştir.

Karşılaştırmalı modellerin kullanıldığı uygulamalar, alternatif yöntemlerle ve YSA uygulamalarıyla karşılaştırmalar olmak üzere iki farklı gruptan oluşmaktadır. Bu çalışmalarda YSA'nın geleneksel kontrol şemalarına göre daha başarılı olduğu ortaya konurken Bayes Sınıflandırıcı ile yapılan sınıflandırmanın YSA modeli'ne göre daha yüksek doğruluk oranı gösterdiği sonucu elde edilmiştir. YSA modelleri kendi aralarında karşılaştırıldığında DVK ve Modüler YSA modellerinin ÇKA'ya göre; DVK Modeli'nin ÇKA ile birlikte kullanıldığı bileşik YSA modeli'nin ise DVK'ya göre daha üstün olduğu ortaya çıkmıştır. Modellerin kullanım amaçları göz önünde bulundurulduğunda, ÇKA'nın literatürde tahmin amaçlı kullanımı yaygın olarak belirtilmekteyken KŞÖT çalışmalarının sonuçları, bu modelin sınıflandırma problemlerinde de başarıyla uygulandığını göstermektedir.

Çalışmalarda kullanılan YSA modellerinin topolojileri incelendiğinde; uygulanan model hangi tipte olursa olsun girdi, çıktı ve katman sayıları farklılık göstermektedir. Girdi ve çıktı sayıları kullanılan verinin türüne göre benzerlik göstermekteyse de gizli katman sayısı tamamen farklıdır. Bu durum, en iyi sonucu veren YSA modeline ulaşmak üzere tasarım sürecinde farklı alternatiflerin denemesi gerekliliğinden kaynaklanmaktadır. Girdiler, YSA'da eğitilen verilere göre incelendiğinde; çalışmalarda, kontrol şemalarına ilişkin gözlem değerleri (ham veri) yanı sıra bu şemalardan elde edilen istatistik değerlerle de (özellikli veriler) KŞÖT oluşturulduğu ve istatistik özellikli verilerle oluşturulan modellerin ham verilere göre daha başarılı sonuçlar ürettiği gözlenmiştir. Ayrıca, örüntülerdeki minimum kayma, kayma miktarı, örnek büyüklüğü, kayma yüzdesi gibi parametrelerin YSA üzerinde etkisi olduğu ve bir başka YZ tekniği olan GA kullanılarak eğitim parametreleri grubunun ve yapılandırmasının geliştirilebileceği de yine bu çalışmaların sonuçlarında görülmektedir.

Geleceğe dönük çalışmalarda; aynı YSA modelleri yerine farklı ya da bileşik YSA modelleri kullanabileceği, diğer YZ teknikleri ile geliştirilebileceği ve iyileştirilebileceği, oluşturulan modellerin üretim sektöründe kullanıcıya dönük uygulamaları için işbirliği çabaları önemli görülmektedir.

## Kaynaklar

- Addeh, J., Ebrahimzadeh, A. & Ranaee, V. (2011). "Control Chart Pattern Recognition using Adaptive Back-Propagation Artificial Neural Networks and Efficient Features", The 2nd International Conference on Control, Instrumentation and Automation, 742-746, 27-29 Dec. 2011, Shiraz, Iran.
- Anagun, A. S. (1998). "A Neural Network Applied to Pattern Recognition in Statistical Process Control", Computers ind. Engng, 35(1-2), 185-188.
- Awadalla, M. H., Ismaeil, A & Sadek M. A. (2011). "Spiking Neural Network-Based Control Chart Pattern Recognition", Journal of Engineering and Technology Research, 3(1), 5-15.



- Bargash, M. A. & Santarisi, N. S. (2004). "Pattern Recognition of Control Charts using Artificial Neural Networks-Analyzing The Effect of The Training Parameters", *Journal of Manufacturing*, 15, 635-644.
- Bayır, F. (2006). *Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama*, İstanbul: İstanbul Üniversitesi Sosyal Bilimler Enstitüsü Sayısal Yöntemler ABD, Yayımlanmamış Yüksek Lisans Tezi.
- Benli, Y. K. (2005). "Bankalarda Mali Başarısızlığın Öngörülmesi Lojistik Regresyon ve Yapay Sinir Ağı Karşılaştırması", *Gazi Üniversitesi Endüstriyel Sanatlar Eğitim Fakültesi Dergisi*, 16, 31-46.
- Cheng, C. S. (1997). "A Neural Network Approach for The Analysis of Control Chart Patterns", *International Journal of Production Research*, 35(3), 667-697.
- Cheng, H. P. & Cheng, C. S. (2009). "Control Chart Pattern Recognition Using Wavelet Analysis and Neural Networks", *Journal of Quality*, 16(5), 311-320.
- El Farissi, O., Moudden, A. & Benkachcha, S. (2015). "Using Artificial Neural Networks for Recognition of Control Chart Pattern", *International Journal of Computer Applications*, 116(3), 46-50.
- Gauri, S. K. (2010). "Control Chart Pattern Recognition Using Feature-Based Learning Vector Quantization", *Int Journal Adv Manuf Technology*, 48, 1061–1073.
- Gauri, S. K. & Chakraborty, S. (2008). "Feature-Based Recognition of Control Chart Patterns: A Generalized Approach", *Quality Technology & Quantitative Management*, 5(3), 203-220.
- Guh, R. S. (2004). "Optimizing Feedforward Neural Networks for Control Chart Pattern Recognition Through Genetic Algorithms", *International Journal of Pattern Recognition and Artificial Intelligence*, 18(2), 75-99.
- Guh, R. S. (2010). "Simultaneous Process Mean and Variance Monitoring Using Artificial Neural Networks", *Computers & Industrial Engineering*, 58, 739–753.
- Guh, R. S. & Tannock, J. D. T. (1999). "A Neural Network Approach to Characterize Pattern Parameters in Process Control Charts", *Journal of Intelligent Manufacturing*, 10, 449-462.
- Hachicha, W. & Ghorbel, A. (2012). "A Survey Of Control-Chart Pattern-Recognition Literature (1991–2010) Based On A New Conceptual Classification Scheme", *Computers & Industrial Engineering*, 63, 204–222.
- Hassan, A. (2011). "An Improved Scheme for Online Recognition of Control Chart Patterns", *Int. J. Computer Aided Engineering and Technology*, 3(3/4), 309–321.
- Hassan, A., Baksh, M. S. N., Shaharoun, A. M. & Jamaluddin, H. (2003). "Improved SPC Chart Pattern Recognition Using Statistical Features", *Int. J. Prod. Res.*, 41(7), 1587–1603.
- Karadağ, R. (2014). "Okuma İlgisi, Tutumları ve Alışkanlığı Konusunda Yapılmış Çalışmaların Lisansüstü Tezlere Dayalı Analizi: YÖK ve ProQuest Veri Tabanları Örnekleme", *Pamukkale Üniversitesi Eğitim Fakültesi Dergisi*, 35, 1-17.



- Kaya, İ., Oktay, S. & Engin, O. (2005). “Kalite Kontrol Problemlerinin Çözümünde Yapay Sinir Ağlarının Kullanımı”, Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 21(1-2), 92-107.
- Kim, J. S., Park, C. S., Baek, J. G. & Kim, S. S. (2012). “Control Chart Pattern Recognition using Wavelet Based Neural Networks”, International Scholarly and Scientific Research & Innovation, 6(12), 1717-1721.
- Kiran, N. V. N. I.; Devi, M. P. & Lakshmi, G.V., (2010). “Effective Control Chart Pattern Recognition using Artificial Neural Networks”, IJCSNS International Journal of Computer Science and Network Security, 10(3), 194-199.
- Laosiritaworn, W. & Bunjongjit, T. (2013). “Classification Techniques for Control Chart Pattern Recognition: A Case of Metal Frame for Actuator Production”, Chiang Mai J. Sci., 40(4), 701-712.
- Lopez, J. A. V., Acevedo, S. G., Juarez, I. L. & Lira, A. J. R. (2012). “An Approach for Control Chart Pattern Recognition Using The Fuzzy Artmap Artificial Neural Networks With Improved Efficiency”, 1st LACCEI International Symposium on Software Architecture and Patterns, Panama City, Panama.
- Noscievicova, D. (2013). “Complex Control Chart Interpretation, International Journal of Engineering Business Management”, 3(13), 1-7.
- Masood, I. & Hassan, A. (2010). “Issues in Development of Artificial Neural Network-Based Control Chart Pattern Recognition Schemes”, European Journal of Scientific Research, 39(3), 336-355.
- Mitra, A. (2008). Fundamentals of Quality Control and Improvements, 3rd Edition, New Jersey: John Wiley & Sons Inc. Publications.
- Muluneh, A. (2014). Control Chart Pattern Recognition for Multivariate Autocorrelated Processes using Artificial Neural Network, Addis Ababa: Addis Ababa Üniversitesi Mekanik ve Endüstriyel Mühendislik Enstitüsü Yayınlanmamış Yüksek Lisans Tezi.
- Nabiyev, V. V. (2010). Yapay Zeka: İnsan-Bilgisayar Etkileşimi, 3. Baskı, Ankara: Seçkin Yayıncılık.
- Niaki, S. T. A. & Abbasi, B. (2008). “Detection and Classification Mean-Shifts in Multi-Attribute Processes by Artificial Neural Networks”, International Journal of Production Research, 46(11), 2945–2963.
- Nimbale, S. M. & Ghute, V. B. (2015). “Artificial Neural Network Model for Monitoring the Fraction Nonconforming Control Chart”, International Journal of Science and Research, 4(3), 188-190.
- Olgun, M. O. (2011). “Kalite Kontrol Grafiklerinde Örüntü Tanıma”, Isparta: Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği ABD Yayınlanmamış Yüksek Lisans Tezi.
- Orçanlı, K., Oktay, E. & Birgören, B. (2015). “A Survey Of Multivariate Control Chart Pattern-Recognition Literature”, Social Sciences Research Journal, 4(2), 23-42.
- Öztemel, E. (2012). Yapay Sinir Ağları, 3. Basım, İstanbul: Papatya Yayıncılık.



- Öztürk, B. A.; Weber, G. W. & Kayalığıl, S. (2007). “Kalite İyileştirmede Veri Kümeleme: Döküm Endüstrisinde Bir Uygulama”, Yöneylem Araştırması ve Endüstri Mühendisliği 27. Ulusal Kongresi, 1207-1212, İzmir, Turkey.
- Perry, M. B., Sporre, J. K. & Velasco, T. (2001). “Control Chart Pattern Recognition using Back Propagation Artificial Neural Networks”, Int. J. Prod. Res., 39(15), 3399- 3418.
- Pham, D. T. & Öztemel, E. (1993). “Control Chart Pattern Recognition Using Combinations of Multi-Layer Perceptrons and Learning-Vector-Quantization Neural Networks”, Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering, 207, 113-118.
- Pham, D.T. & Wani, M.A. (1997). “Feature-based Control Chart Pattern Recognition”, International Journal of Production Research, 35(7), 1875-1890.
- Pujapanda, A. & Acharya, S. P. (2007). Identification of Control Chart Patterns using Neural Networks, Rourkela: Rourkela Ulusal Teknoloji Enstitüsü Makina Mühendisliği Yayınlanmamış Yüksek Lisans Tezi.
- Ranaee, V. & Ebrahimzadeh, A. (2013). “Control Chart Pattern Recognition using Neural Networks and Efficient Features: A Comparative Study”, Pattern Anal Applic, 16, 321–332.
- Psarakis, S. (2011). “The Use of Neural Networks in Statistical Process Control Charts”, Qual. Reliab. Engng. Int., 27, 641-650.
- Rajagopalan, R. & Rajagopalan, P. (1996). “Applications of Neural Network in Manufacturing”, Proceedings of The 29th Annual Hawaii International Conference on System Sciences, 447-453, Hawaii.
- Sağıroğlu, Ş., Beşdok, E. & Erler, M. (2000). “Control Chart Pattern Recognition using Artificial Neural Networks”, Turk J Elec Engin, 8(2), 137-147.
- Shaban, A. & Shalaby, M. A. (2010). “A Double Neural Network Approach for The Automated Detection of Quality Control Chart Patterns”, Int. J. Rapid Manufacturing, 1(3), 278-291.
- Shaban A., Shalaby, Abdelhafiez, M., Ashraf, E. & Youssef, S. (2010). “Automated Identification of Basic Control Charts Patterns Using Neural Networks”, J. Software Engineering & Applications, 3, 208-220.
- Stützle, T. (1995). “A Neural Network Approach to Quality Control Charts”, Proceedings of The International Workshop on Artificial Neural Networks, Torremolinos, Spain.
- Şahin, M. & Kışla, T. (2013). “Kişiselleştirilebilir Öğrenme Ortamları: Literatür İncelemesi”, Eğitim ve Öğretim Araştırmaları Dergisi, 2(1), 81-91.
- Wu, S. (2010). “Intellegence Statistical Control in Cellular Manufacturing Based on Wavelet Transform and Probablistic Neural Network”, Journal Of Computattional Information Systems, 6(10), 3463-3470.
- Yılmaz, Ş. K. (2014). Doğrusal Vektör Kuantizasyon Modeli Kullanılarak Yapay Sinir Ağlarıyla Kontrol Şemalarında Örüntü Tanıma: Hazır Beton Üreten Bir İşletmede



## AKADEMİK BAKIŞ DERGİSİ

Sayı: 60 Mart - Nisan 2017

Uluslararası Hakemli Sosyal Bilimler E-Dergisi

ISSN:1694-528X İktisat ve Girişimcilik Üniversitesi, Türk Dünyası  
Kırgız – Türk Sosyal Bilimler Enstitüsü, Celalabat – KIRGIZİSTAN

<http://www.akademikbakis.org>



Uygulama, Malatya: İnönü Üniversitesi Sosyal Bilimler Enstitüsü Yayınlanmamış  
Doktora Tezi.

Yılmaz, Ş. K. & Yücel, M. M. (2015). “Kontrol Şemalarında Örüntü Tanıma Modelinin  
Bilgisayar Ortamına Aktarılması: Beton Basınç Dayanımı Örneği”, 15. Üretim  
Araştırmaları Sempozyumu, 14-16 Ekim 2015, İzmir.

Zorriassatine, F. & Tannock, J.D.T. (1998). “A Review of Neural Networks for Statistical  
Process Control”, Journal of Intelligent Manufacturing, 9, 209-224.

### İnternet Kaynakları

Shachmurove, Y. (2002). “Applying Artificial Neural Networks to Business, Economics and  
Finance”, Penn CARESS Working Papers, Penn Economics Department,  
<http://EconPapers.repec.org/RePEc:cla:penntw:5ecbb5c20d3d547f357aa130654099f3>,  
Erişim Tarihi: 02.10.2015.