

# İSTATİSTİKSEL ÖZELLİK TEMELLİ BAYES SINIFLANDIRICI KULLANARAK KONTROL GRAFİKLERİNDE ÖRÜNTÜ TANIMA

**Mehmet Onur OLGUN\***, **Gültekin ÖZDEMİR\***

\*Süleyman Demirel Üniversitesi, Mühendislik-Mimarlık Fakültesi, Endüstri Müh. Bölümü, 32260 Isparta  
[onurolgun@sdu.edu.tr](mailto:onurolgun@sdu.edu.tr), [gultekinozdemir@sdu.edu.tr](mailto:gultekinozdemir@sdu.edu.tr)

(Geliş/Received: 21.02.2011; Kabul/Accepted: 09.02.2012)

## ÖZET

İstatistiksel süreç kontrolünde kullanılan Shewhart kontrol grafikleri, süreçteki anormal değişimleri incelemeye önemli bir araçtır. Süreçte zaman içinde oluşabilecek değişimlerin tespit edilmesi, sürecin kontrol altında tutulması ve önlemlerin alınması amacıyla süreçteki anormal değişimlerin örüntülerini tanımlamaya yönelik Yapay Sinir Ağları ve Bayes örüntü tanıma sistemleri oluşturulmuştur. Oluşturulan örüntü tanıyıcılarının sınıflandırma performansları ölçülmüştür. Doğru sınıflandırma performansını artırmak için örüntüleri oluşturan gözlem değerlerinden, altı adet istatistiksel özellik çıkarılmış ve sınıflandırma performansları karşılaştırılmıştır. Yapay sinir ağları ve Bayes örüntü tanıyıcılarının, ilgili özellikler tanımlandıktan sonra daha yüksek performans verdiği görülmüştür. Sonuç olarak, Bayes örüntü tanıyıcısının yapay sinir ağlarına nazaran daha iyi sınıflandırma performansının olduğu sonucuna varılmıştır. Bayes sınıflandırıcı gerçek zamanlı kontrol grafikleri uygulamalarında örüntü tanıma amaçlı kullanılabilir.

**Anahtar Kelimeler:** Kontrol grafikleri, örüntü tanıma, yapay sinir ağları, Bayes sınıflandırıcı, seçilmiş istatistiksel özellikler.

## CONTROL CHART PATTERN RECOGNITION USING STATISTICAL-FEATURE BASED BAYES CLASSIFIER

### ABSTRACT

Shewhart control charts for statistical process control are important tools to examination abnormal changes in a process. Artificial Neural Networks and Bayesian pattern recognition systems are formed to identify patterns of abnormal changes in a process to identify changes that may occur over time, to keep a process under control and to take necessary actions in a process. Classification performance of the generated pattern recognizers was measured. Six statistical features are issued from observations, that patterns were created, and classification performances were compared to improve the performance of correct classification. It is observed that Artificial Neural Networks and Bayesian pattern recognizers have higher performance after related features are defined. In conclusion, it is concluded that Bayesian pattern recognizer has better classification performance than artificial neural networks. Bayesian classifier can be used in real-time control charts for pattern recognition applications.

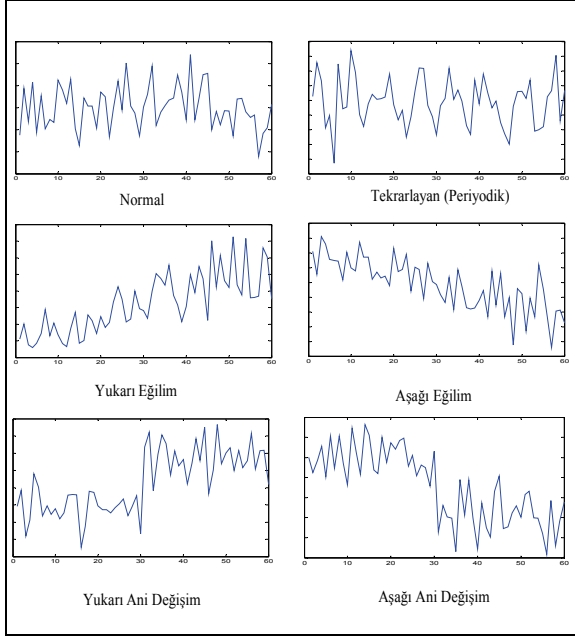
**Key Words:** Control Charts, Pattern Recognition, Artificial Neural Networks, Bayes Classifier, Selected Statistical Features.

### 1. GİRİŞ (INTRODUCTION)

Kontrol grafikleri, istatistiksel süreç kontrolünün önemli araçlarıdır. Shewhart [1] tarafından bulunan kontrol grafikleri süreçteki anormal değişkenlikleri tespit etmede yaygın olarak kullanılmaktadır. Süreçteki değişimler, genel ve özel nedenlerin sonuçlarından dolayı meydana

gelmektedir. Genel nedenler, süreçte her zaman karşılaşılan ve sürecin tamamını etkileyen kaynaklardaki değişimlerden oluşurken, özel nedenler genellikle makine, personel ve malzemeden kaynaklanan aksaklıklardan oluşmaktadır [2]. Bundan dolayı süreçteki anormal değişimleri hızlı ve etkin bir şekilde tanıma ürün kalitesinin sağlanmasında önemli olmaktadır. Kontrol grafikleri, Şekil 1'de verilen;

normal (NOR), tekrarlayan (periyodik) çevrimler (TEÇ), yukarı eğilim (YUE), aşağı eğilim (AŞE), yukarı ani değişim (YAD) ve aşağı ani değişim (AAD) gibi altı farklı örüntü tipinden biriyle gösterebilir [3]. Normal örüntü dışındaki diğer örüntüler, süreçteki anormal değişimlerin kaynağını oluşturmakta ve süreçte hemen önlem alınması gereğini göstermektedir.



**Şekil 1.** Kontrol grafikleri örüntüleri (Control chart patterns)

Son yıllarda, bilgisayarlar aracılığıyla, genellikle örnekler kullanılarak, girdiler ile çıktılar arasında ilişkileri kurup, sınıflandırabilme yetisinden dolayı yapay zeka tekniklerinden olan yapay sinir ağları (YSA) kontrol grafiklerinde örüntü tanıma çalışmalarının ilgi odağı olmuştur. Özellikle, gözlemlenen süreç verilerinin herhangi bir istatistiksel dağılıma ihtiyaç duymaması ve eksik verilerinin işlenmesinde YSA başarıyla kullanılmaktadır. Çoğu çalışmada, danışmanlı geri yayımlı öğrenme algoritmasının kullanılarak çok katmanlı YSA ağları ile çeşitli örüntü tipleri sınıflandırılmıştır [4-13]. Ancak, YSA'nın eğitim için çok sayıda eğitim verisine ihtiyaç duyması, yerel çözüm noktalarına takılıp çözümün iyileşmemesi gibi dezavantajları vardır [14]. Genellikle, bilimsel yazında YSA modellerinde öğrenme algoritması olarak azalan eğilimli öğrenme algoritması kullanılmış olup, ölçeklenmiş konjuge gradyant algoritmasını kullanan bir çalışma mevcut değildir.

Veri madenciliği sınıflandırma algoritmalarından olan Bayes, uygulanabilirliği ve hızlı hesaplama performansı ile araştırmacılar tarafından öne çıkan bir algoritmadır. Temeli istatistiksel Bayes teorisine dayanmakta ve sınıflandırılacak olayları birbirinden bağımsız olarak ele almaktadır. Bilimsel yazın

incelendiğinde, genellikle görüntü işleme ve metin madenciliğinde daha çok kullanılmakta olup kontrol grafiklerinde örüntü tanımayla ilgili herhangi bir çalışma mevcut değildir. Bu açıdan mevcut çalışmanın, bilimsel yazına katkısı olduğu düşünülmektedir.

Çoğu çalışmada her bir örüntü tipi çok sayıdan oluşan gözlem verilerini ham veri (raw data) olarak girdi vektöründe incelenmiştir [15-17]. Ancak girdi vektörünün boyutunun büyük olması sınıflandırma performansını düşürmektedir. Girdi vektörünün boyutunun küçük olması, sınıflandırma ve çalışma performansını artırmaktadır. Bundan dolayı, Hassan [18] tarafından gözlem verilerini iyi temsil eden altı adet istatistiksel özellik çıkarılmıştır. Bunlar; ortalama, standart sapma, çarpıklık katsayısı, ortalama kareler değeri, otokorelasyon katsayısı ve cusum istatistikleridir. Çalışmasında 20 adet gözlem verisini altı adet istatistiksel özellikler temsil etmiş ve sınıflandırma performansını artırmıştır. Anagün [19] tarafından gözlem verilerinin basit ve karmaşık özelliklerinin temsili olarak frekans sayısı (histogram) kümesi kullanılmıştır.

Pham ve Wani [20] ile Gauri ve Chakraborty [12] tarafından ise gözlem verilerinin kontrol grafikleri üzerindeki konumlarından dokuz adet istatistiksel şekil özelliği çıkarılmıştır.

Bu çalışmanın amacı, Naive Bayes sınıflandırıcısı kullanarak girdi vektöründen altı adet farklı istatistiksel özellik çıkararak sınıflandırma performansı incelemektir. Ayrıca çalışmada, özellik çıkararak ve özellik çıkarmadan (raw data) bayes sınıflandırıcısı ve çok katmanlı YSA modelinin performansları incelenerek karşılaştırılmıştır.

Bu çalışmanın 2. bölümünde kullanılacak olan örnek örüntülerin nasıl oluşturulduğu, 3. bölümde istatistiksel özellik çıkarımı, 4. ve 5. bölümlerinde sırasıyla YSA ve Bayes örüntü tanıma modellerinin oluşturulması, 6. bölümde yapılan deneyler ve sınıflandırma performansları verilmiştir.

## 2. ÖRNEK ÖRÜNTÜLER (SAMPLE PATTERNS)

Çok sayıda kontrol grafiği gözlem verisinin girdi vektörü olarak kullanılması örüntüleri sınıflandırma performansını düşürmekte ve harcanan zamanı artırmaktadır. Az sayıda gözlem verisi kullanımı ise, istenilen örüntülerin tam olarak oluşmamasına ve örüntülerin birbirinden ayırt edilmesinin zorlaşmasına neden olmaktadır.

Kontrol grafiklerinin performans ölçümünde yaygın olarak kullanılan performans göstergesi Ortalama Koşum Uzunluğu (OKU)'dur. OKU, süreci kontrol etmek için kullanılan kontrol grafiği, sürecin kontrol

dışında olduğuna dair bir sinyal verene kadar süreçten alınan ortalama örnek sayısını gösterir. Eğer süreç ortalaması hedef değerde ise, grafiğin verdiği alarm yanlıştır ve bu durumda beklenen OKU değeri büyük olmalıdır; süreç ortalaması sapma gösterdiğinde kontrol grafiğinin verdiği alarm doğrudur ve beklenen OKU değeri küçük olmalıdır.

Shewhart  $\bar{x}$  kontrol grafiğinde, bir noktanın kontrol limitleri ( $3\sigma$ ) dışına çıkma olasılığı ( $\alpha$ ) matematiksel olarak eşitlik 1'deki gibidir.

$$\alpha = P(\bar{X} > \text{ÜKL}) + P(\bar{X} < \text{AKL}) \quad (1)$$

Kontrol limitinin 3 sigma olduğu kabul edilirse, standart normal dağılım tablosuna göre,  $P(\bar{X} > 3) = 0,00135$  ve  $P(\bar{X} < -3) = 0,00135$  olarak bulunur. Buradan  $\alpha = 0,0027$  olarak bulunur. Kontrol içi OKU,  $1/0,0027 = 370$  olarak hesaplanır [21]. OKU=370 ifadesi, süreç kontrol altında olsa bile, kontrol diyagramının ortalama 370 örnekte bir kontrol dışı sinyal ürettiğini anlatır. Oluşturulacak olan her bir örüntü örneği büyüklüğünü hesaplamak için benzetim çalışması yapılmıştır. Yapılan denemelere göre örnek büyüklüğü olarak 60 kullanıldığında yaklaşık 366 örnek de bir kontrol dışı sinyal üretmiştir. 60'dan küçük örnek büyüklüğünde yapılan denemelerde 370'den fazla kontrol dışı sinyal ürettiğinden dolayı örnek büyüklüğü olarak 60 seçilmiştir. Bu nedenlerden dolayı çalışmada; girdi vektörü olarak altmış gözlem verisi kullanılmıştır, yani altmış gözlem verisi ile bir örüntü örneği oluşturulmuştur.

Kontrol grafiklerinde bahsedilen örüntüleri tanımak için eğitim ve test aşamaları için çok sayıda örnek örüntüye ihtiyaç duyulmaktadır. İdeal olarak, örüntüler için gözlem verileri gerçek bir üretim sürecinden alınmalıdır, ancak pratikte bu ekonomik olmamaktadır. Bundan dolayı araştırmacılar benzetim yardımıyla örüntüler oluşturmaktadırlar [10, 12]. Bu çalışmada da örüntüler benzetim ile oluşturulmuş olup, altı tip örüntüyü oluşturmada kullanılan parametreler Tablo 1'de verilmiştir.

Tablo 1'deki örüntü formüllerinde,  $i$  ( $=1, \dots, 60$ ); bir örüntü için oluşturulan gözlem verisi sayısını,  $\mu_i$  ve  $\sigma_i$  sırasıyla standart normal dağılımla oluşturulan rassal sayıyı ve  $i$ 'nci gözlem verisinin değerini göstermektedir.  $k$  değeri ise kayma pozisyonundan önce bir, sonra sıfır değerini almakta, diğer değerler ise ayrı ayrı her örnek için belirtilen aralıklarda rasgele seçilmektedir. Her bir örüntü sınıfı için 150 tane örüntü örneği oluşturulmuş toplam 900 ( $150 \times 6$ ) adet örnek oluşturulmuştur.

**Tablo 1.** Kontrol grafikleri örüntü formül ve parametreleri (Pattern equations and parameters for control charts)

Örüntü Tipi	Örüntü Parametreleri	Parametre Değerleri	Örüntü Formülü ( $y_i$ )
NOR	Ortalama ( $\mu$ ) Standart sapma ( $\sigma$ )	80 5	$\mu + \eta_i \sigma$
TEÇ	Periyodik değişim değeri ( $\alpha$ ) Periyod ( $T$ )	$0 \leq \alpha \leq 15$ 8	$\mu + \eta_i \sigma + \alpha \sin(2\pi i / T)$
YUE	Trend eğimi ( $g$ )	$0,2 \leq g \leq 0,5$	$\mu + \eta_i \sigma + ig$
AŞE	Trend eğimi ( $g$ )	$0,2 \leq g \leq 0,5$	$\mu + \eta_i \sigma - ig$
YAD	Kayma pozisyonu ( $k$ ) Kayma miktarı ( $s$ )	$k=1, k=0$ $7,5 \leq s \leq 20$	$\mu + \eta_i \sigma + ks$
AAD	Kayma pozisyonu ( $k$ ) Kayma miktarı ( $s$ )	$k=1, k=0$ $7,5 \leq s \leq 20$	$\mu + \eta_i \sigma - ks$

### 3. SEÇİLMİŞ İSTATİSTİKSEL ÖZELLİKLER (SELECTED STATISTICAL FEATURES)

Girdi vektörünün boyutunu azaltarak verileri iyi temsil eden istatistiksel özellik çıkarma kontrol grafiklerinde örüntü tanımada (KKÖ) başarıyla uygulanmıştır. Guh [22], yaptığı çalışmada KKÖ için altı adet istatistiksel özellik çıkarmıştır. Bunlar; ortalama, standart sapma, çarpıklık katsayısı, basıklık katsayısı, regresyon doğrusu eğimi, ve Pearson korelasyon katsayısıdır. Merkezi eğilim ölçülerinden olan ortalama, veri kümesi içindeki değerler için kütle merkezi ve denge noktasını tanımlar. Merkezi değişim ölçülerinden olan standart sapma ise veri noktalarının ortalamadan sapmalarını açıklar. Ortalama ve standart sapma normal ve tekrarlayan çevrim örüntülerini ayırt etmeye yardımcı olmaktadır. Şekil ölçülerinden çarpıklık katsayısı, verilerin bir eğri üzerinde eğikliğinin ölçüsüdür. Simetrik bir dağılımda katsayı sıfır olur, sağa yatık bir dağılımda ise pozitif değer alır, sola yatık bir dağılımda ise negatif değer alır.

Basıklık katsayısı, yukarı ve aşağı eğilim gösteren örüntüleri ayırt etmeye yardımcı olur. Basıklık katsayısı, adından anlaşılacağı üzere verilerin basıklığı veya sivrililiğini açıklamaktadır. Eğer basıklık ölçüsü sıfır ise mezo-basık olarak adlandırılır. Pozitif ise lepto-basık negatif ise plati basık olarak adlandırılır [23]. Basıklık katsayısı yukarı ani değişim ve yukarı eğilim örüntülerin aynı zamanda aşağı ani değişim ve aşağı eğilim örüntülerin ayırt edilmesini kolaylaştırır. Regresyon doğrusu eğimi ile Pearson korelasyon katsayısı ise artan ve azalan eğilim, normal örüntüleri sınıflandırmayı kolaylaştırır. Yukarı eğilimde genellikle pozitif değerler alınırken aşağı eğilimde negatif değerler alırlar, normal örüntülerde

ise sifıra yakın değerler almaktadırlar [22]. Bu çalışmada çıkarılan altı özellik formülü eşitlikler 2-6' da verilmiştir:

$$ORT = \frac{\sum_{i=1}^n Y_i}{n} \quad (2)$$

$$STD = \sqrt{\frac{\sum_{i=1}^n (Y_i - ORT)^2}{n-1}} \quad (3)$$

$$\text{ÇAR} = \frac{\sum_{i=1}^n (Y_i - ORT)^3}{nSTD^3} \quad (4)$$

$$BAS = \frac{\sum_{i=1}^n (Y_i - ORT)^4}{nSTD^4} - 3 \quad (5)$$

$$EĞİM = \frac{\sum_{i=1}^n (i - i_{ort})(Y_i - ORT)}{\sum_{i=1}^n (i - i_{ort})^2} \quad (6)$$

$$KOR = \frac{n(\sum_{i=1}^n iY_i) - (\sum_{i=1}^n i)(\sum_{i=1}^n Y_i)}{\sqrt{[n\sum_{i=1}^n i^2 - (\sum_{i=1}^n i)^2][n\sum_{i=1}^n Y_i^2 - (\sum_{i=1}^n Y_i)^2]}} \quad (7)$$

Burada;  $Y_i$ ,  $i$ 'nci gözlem verisinin değerini,  $n$ , ( $n=60$ ), ise gözlem sayısını göstermektedir.

#### 4. BAYES SINIFLANDIRICI KULLANARAK ÖRÜNTÜ TANIYICI TASARIMI (PATTERN RECOGNIZER DESIGN USING BAYES CLASSIFIER)

Naive Bayes sınıflandırıcı, temeli Bayes teorisine dayanan, verileri istatistiksel sınıflandırma tekniklerinden biridir. Bu teorem, örüntü sınıflandırma problemine göre aşağıdaki şekilde açıklanabilir.

$X = \{x_1, x_2, \dots, x_n\}$ , sınıfı belli olmayan örüntüyü içeren girdi vektörünü,  
 $C_i$  ( $i = 1, 2, 3, 4, 5, 6$ ) hipotezi,  $X$ 'in altı sınıftan herhangi biri olan  $C$  sınıfına ait olduğunu,  
 $P(C_i|X)$  (Sonsal olasılık),  $X$  verildiğinde  $C_i$  hipotezinin kabul edilebilir (doğru) olma olasılığı,  
 $P(C_i)$  (Önsel olasılık),  $C_i$  hipotezinin gözlem yapılmadan önceki ilk haldeki olasılığını,  
(Mevcut girdi vektörünün altı örüntü sınıfından (AAD v.b.) birine ait olma olasılığı,  $P(C_i)=1/6$  olarak belirlenmiştir)  
 $P(X)$ , örnek girdi vektörünün gözlemlenmesi olasılığını,  
 $P(X|C_i)$ ,  $C_i$  hipotezinin doğru olduğu verildiğinde  $X$ 'in gözlemlenme olasılığını gösterirken;

$$P(C_i|X) = \frac{P(X|C_i)P(C_i)}{P(X)} \quad (8)$$

olur.

Hesaplamalardaki işlem yükünü azaltmak için  $P(X|C_i)$  olasılığını basitleştirmek amacıyla her örüntüye ait  $x_i$  değerlerinin birbirinden bağımsız olduğu kabul edilerek eşitlik 9 elde edilir:

$$P(X|C_i) = \prod_{k=1}^n P(x_k|C_i) \quad (9)$$

Bilinmeyen örüntü örneği  $X$ 'i sınıflandırmak için eşitlik 9'daki  $P(C_i|X)$  içinde yer alan paydalar birbirine eşit olduğundan sadece pay değerlerinin karşılaştırılması yeterlidir. Bu değerler içinden en büyük olanı;

$$\arg \max_{C_i} \{P(X|C_i)P(C_i)\} \quad (10)$$

seçilerek bilinmeyen örüntünün bu sınıfa ait olduğu belirlenir.

Dikkat edilecek olursa sonsal olasılıkları kullanan eşitlik 10, en büyük sonsal sınıflandırma yöntemi (Maximum A Posteriori Classification) olarak bilinir. Sonuç olarak eşitlik 11'deki

$$C_{map} = \arg \max_{C_i} \prod_{k=1}^n P(x_k|C_i) \quad (11)$$

ifade örüntü tanıma eğitim ve test veri setleri için Bayes sınıflandırıcısı olarak kullanılmıştır [24].

Bayes sınıflandırıcıda nitelik değerleri sayısal olduğunda koşullu olasılıkları modellemek için sayısal verilerin dağılımının normal dağıldığı varsayılarak eşitlik 12'deki olasılık yoğunluk fonksiyonu kullanılır. Bulunan olasılık değerleri eşitlikler 10-11'e göre en büyükleri seçilerek sınıflandırma performansları elde edilmiş olur.

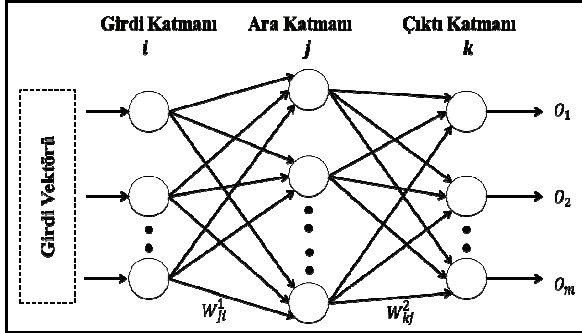
$$P(x_k|C_i) = f(x_k, \mu_{C_i}, \sigma_{C_i}) = \frac{1}{\sqrt{2\pi\sigma_{C_i}}} e^{-\frac{(x_k - \mu_{C_i})^2}{2\sigma_{C_i}^2}} \quad (12)$$

Burada;  $\mu_{C_i}$  ortalama,  $\sigma_{C_i}$  standart sapma değerleridir. Altı farklı örüntü tipi sınıflandırmak için hazırlanan Bayes Sınıflandırıcı MATLAB®'ta kodlanmış sonuçları Bölüm 6'da anlatılmıştır.

#### 5. YAPAY SİNİR AĞI KULLANARAK ÖRÜNTÜ TANIYICI TASARIMI (PATTERN RECOGNIZER DESIGN USING ARTIFICIAL NEURAL NETWORK)

Genel olarak bir YSA ağ modeli, süreç elemanlarının bağlanması sonucu oluşan yapı, süreç elemanlarının sahip oldukları girdileri çıktılara dönüştüren aktivasyon fonksiyonları ve öğrenme algoritmalarından oluşmaktadır. Son yıllarda, kullanılan öğrenme algoritması ve yapısına göre çok sayıda model geliştirilmiştir. Örneğin, çok katmanlı algılayıcı (ÇKA), vektör kuantizasyon modelleri, olasılıklı ağlar (OA) ve diğer ağ modelleri gibi. Fakat ÇKA kontrol grafikleri örüntü tanıma çalışmalarında başarıyla uygulanmıştır [25]. Basit bir ÇKA yapısı, girdi katmanı, bir veya daha fazla ara katman ve çıktı katmanından oluşmaktadır. Girdi katmanı dışarıdan aldıkları girdi vektörlerini herhangi bir işlem yapmadan ara katmana aktarır. Ara katman ise girdi katmanından gelen bilgileri işleyerek bir sonraki katmana gönderir. Ara katmandaki her bir süreç elemanı, girdi ve çıktı katmanındaki bütün süreç elemanlarına bağlıdır. Süreç elemanlarında bilgi akışı sırasında herhangi bir geri besleme mekanizması

mevcut değildir. Şekil 2’de 3 katmanlı ve katmanlar arası ağırlıkları  $W_{ji}^1$  ve  $W_{kj}^2$  olan örnek bir ÇKA ağ modeli verilmiştir.



Şekil 2. ÇKA yapay sinir ağ modeli (MLP neural network architecture)

Örüntü tanıyıcı ağ modeli, uygulanmadan önce eğitilip test edilmesi gerekmektedir. Danışmanlık öğrenme yaklaşımında girdi ve çıktı vektörleri ÇKA ağ modeline gösterilir. Öğrenme sürecinde ise ağın ürettiği çıktılar ile üretmesi gereken çıktılar arasındaki fark (hata) enazlanmaya çalışılır. Yani amaç, kullanılan girdi-ara katmanı arasındaki ağırlık ( $W_{ji}^1$ ) ile ara-çıkı katmanı arasındaki ağırlığı ( $W_{kj}^2$ ) zaman içinde istenilen performansa göre gerekli ayarlamalar ve dağıtımları yaparak farkı en aza indirmektir.

### 5.1 Yapay Sinir Ağ Yapısı (Neural Network Configuration)

Genel kural; oluşturacak olan ağın boyutunun olabildiğince küçük olmasıdır. Çalışmada kullanılan YSA uygulamasında, girdi katmanındaki süreç elemanı sayısı, girdi vektörünün büyüklüğüne paralel olarak işlenmemiş (ham) veri için 60 adet, özellik çıkartılmış veri için ise 6 adet girdi süreç elemanı kullanılmıştır. Diğer taraftan ara katmanda kullanılacak olan süreç elemanı sayısını belirlemek için 10 ile 20 arasında değişen süreç elemanı ile gerekli denemeler yapılarak en yüksek sınıflandırma performansı alınan 20 adet süreç elemanı kullanılmasına karar verilmiştir. Çıktı katmanında ise altı adet örüntü tipi sınıflamak için altı tane süreç elemanı kullanılmıştır. İstenilen hedef çıktı matrisinin yapısı Tablo 2’de görülmektedir.

Bütün yapılan denemeler ve kurulan ağ modelleri MATLAB® YSA Toolbox’ı kullanılarak kodlanmıştır. Kullanılan transfer fonksiyonları ve öğrenme algoritmaları sırasıyla bölüm 5.2 ve bölüm 5.3’te detaylı bir şekilde ele alınmıştır. Yapılan deneme sonuçlarına göre en yüksek performansı veren modeller, işlenmemiş veri için 60x20x6 ve özellik çıkartılmış veri için ise 6x20x6 boyutunda ağ oluşturulmuştur [26].

Tablo 2. Hedef çıktı matrisi (Target output matrix)

Örüntü Sınıfı	Örüntü Açıklaması	Çıktılar					
		1	2	3	4	5	6
1	NOR	1	0	0	0	0	0
2	TEÇ	0	1	0	0	0	0
3	YUE	0	0	1	0	0	0
4	AŞE	0	0	0	1	0	0
5	YAD	0	0	0	0	1	0
6	AAD	0	0	0	0	0	1

### 5.2 Transfer Fonksiyonu (Transfer Function)

Ara katmanda hiperbolik tanjant (tansig), çıktı katmanında ise lojistik sigmoid (logsig) aktivasyon fonksiyonları kullanılmıştır. Hiperbolik tanjant aktivasyon fonksiyonu katmanındaki verileri -1 ile 1 arasındaki değerlere dönüştürür. Sigmoid fonksiyon ise verileri 0 ile 1 arasında değişen değerlere dönüştürür [12].

### 5.3 Öğrenme Algoritması (Training Algorithm)

Çoğu çalışmada, kullanılan ağ modeli için öğrenme algoritması seçilir. Genellikle, kontrol grafiklerinde örüntü tanıma çalışmalarında kullanılan iki tip öğrenme algoritması vardır. Bunlar, Levenberg-Marquardt (trainlm) ve azalan eğilimli (traingdx). Bu iki algortmadan azalan eğilimli algoritma önceki çalışmalarda daha iyi ve tutarlı sonuçlar alınmıştır ayrıca, daha az bilgisayar hafızası gerektirmektedir [18]. Trainlm daha az adımda hızlı hata düşürme eğilimi göstermesine rağmen çok fazla bilgisayar hafızası gerektirir. Ancak geri yayımlı öğrenme algoritmalarından olan ölçeklenmiş konjuge gradyan algoritması (trainsecg) daha önceki çalışmalarda kullanılmamıştır. Yapılan denemeler sonucunda ölçeklenmiş konjuge gradyan algoritması diğer algoritmalara göre daha hızlı sonuç vermesinden dolayı öğrenme algoritması olarak ölçeklenmiş konjuge gradyan algoritması kullanılmıştır. YSA eğitiminde kullanılan algoritmaların ham veri sınıflandırma performans hızları saniye cinsinden Tablo 3’de verilmiştir. Bu işlem için MATLAB®, 4 Gb bellekli Core i5 460m işlemcili bilgisayarda çalıştırılmıştır. Çalışmada ağ performansı ortalama hata kareler yöntemine (OHKY) göre hesaplanmıştır.

**Tablo 3.** Kullanılan YSA eğitim algoritmalarının sınıflandırma performans hızları (The classification performance speeds of used ANN training algorithms)

Sınıflandırıcı Numarası	Ölçeklenmiş Konjuge Gradyant (trainscg)	Levenberg-Marquardt (trainlm)	Azalan Eğimli (traingdx)
1,1	19,53	45,31	45,47
1,2	10,79	46,34	44,53
1,3	25,15	41,09	43,88
1,4	11,80	57,36	44,13
1,5	15,33	50,67	43,57
<b>Ortalama</b>	16,52	48,15	44,31

#### 5.4 Kullanılan Öğrenme ve Test Parametreleri (Used Training and Test Parameters)

Bu çalışmada oluşturulan YSA örüntü tanıma modelinin, tanıma performansı ve test edilmesi gerçek hayat uygulamaları için önemlidir. YSA tabanlı örüntü tanıyıcı için her biri 900 örüntü seti içeren 5 farklı eğitim ve test verisi oluşturulmuştur. ÇKA modelinin eğitim ve test aşamaları için aşağıdaki parametreler seçilmiştir:

- Maksimum adım (epoch) sayısı: 2500
- Öğrenme oranı: 0,1
- Öğrenme oranı artış miktarı: 1,05
- İstenilen Hata oranı: 0,01
- Momentum sabiti: 0,5
- Öğrenme oranı azalma miktarı: 0,7

Ağ durdurma, istenilen hata oranı veya maksimum adım sayısına ulaşıldığında gerçekleşecektir. Oluşturulan 5 farklı örüntü tanıma veri seti için uygulamadaki aynı öğrenme ve test parametreleri kullanılmıştır.

#### 6. DENEYLER VE SONUÇLARI (EXPERIMENTS AND RESULTS)

Gerçek zamanlı uygulamalarda, geliştirilen örüntü tanıyıcının kabulü için sınıflandırma performansının ölçülmesi ve değerlendirmesi iki önemli konudur. Bu amaçla, her biri 900 farklı örüntü örneği içeren sınıflandırıcıların eğitim ve test performanslarını ölçmek için 5 farklı (5x900) örnek kümesi oluşturulmuştur. Ham veri ve eşitlikler 2-6'da verilen altı istatistiksel özelliği kullanarak oluşturulan YSA ve Bayes örüntü sınıflandırıcılarının eğitim ve test aşamalarındaki sınıflandırma oranı sonuçları sırasıyla Tablo 4 ve Tablo 5'te verilmiştir. Oluşturan örüntü tanıyıcı modellerin akış şeması ise Şekil 3'te görülmektedir.

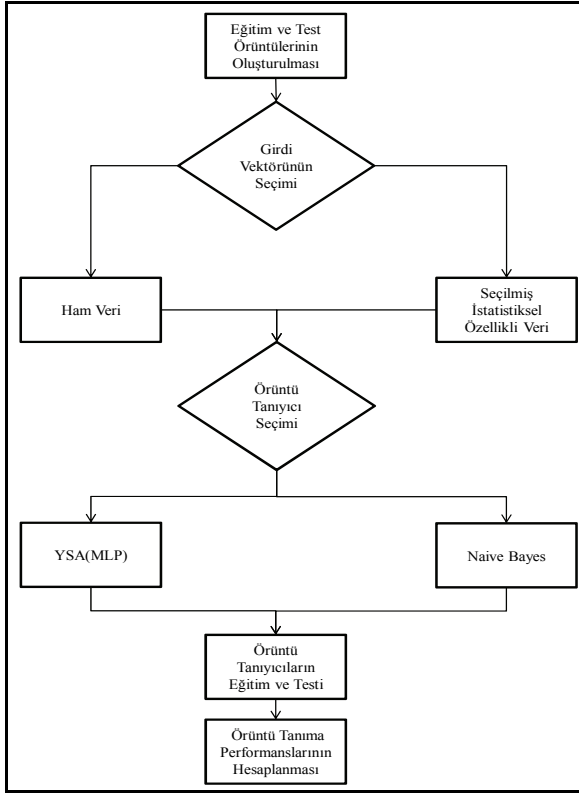
**Tablo 4.** Ham veri ve istatistiksel özellik kullanarak elde edilen YSA eğitim-test performansları (ANN training-test performances based on raw data and statistical features)

Ham Veri YSA Örüntü Tanıyıcı		
Sınıflandırıcı Numarası	Eğitim Sınıflandırma Yüzdesi	Test Sınıflandırma Yüzdesi
1,1	100	95,78
1,2	100	96,67
1,3	100	95,33
1,4	100	97,78
1,5	99,56	98,00
<b>Ortalama</b>	99,91	96,70
<b>Standart Sapma</b>	0,20	1,18
Özellik-Temelli YSA Örüntü Tanıyıcı		
Sınıflandırıcı Numarası	Eğitim Sınıflandırma Yüzdesi	Test Sınıflandırma Yüzdesi
2,1	98,67	98,44
2,2	98,67	97,56
2,3	98,44	96,00
2,4	98,67	98,67
2,5	98,67	98,56
<b>Ortalama</b>	98,62	97,85
<b>Standart Sapma</b>	0,10	1,21

**Tablo 5.** Ham veri ve istatistiksel özellik kullanarak elde edilen Bayes eğitim ve test performansları (Bayes training-test performances based on raw data and statistical features)

Ham Veri Bayes Örüntü Tanıyıcı		
Sınıflandırıcı Numarası	Eğitim Sınıflandırma Yüzdesi	Test Sınıflandırma Yüzdesi
3,1	100	90,22
3,2	100	91,56
3,3	100	92,89
3,4	100	90,89
3,5	100	92,22
<b>Ortalama</b>	100	91,56
<b>Standart Sapma</b>	0	1,05
Özellik-Temelli Bayes Örüntü Tanıyıcı		
Sınıflandırıcı Numarası	Eğitim Sınıflandırma Yüzdesi	Test Sınıflandırma Yüzdesi
4,1	99,78	99,33
4,2	99,78	99,11
4,3	99,56	98,67
4,4	99,56	99,11
4,5	99,56	98,89
<b>Ortalama</b>	99,65	99,02
<b>Standart Sapma</b>	0,12	0,25





Şekil 3. Örüntü tanıma modeli akış şeması (Pattern recognition flow diagram)

YSA ve Bayes sınıflandırıcılarının eğitim ve test aşamalarında 5 örnek kümesi için örüntüler istatistiksel özellikleri çıkarılarak ve ham olarak girdi vektörüne sunulmuş, aynı zamanda istenilen çıktı matrisleri ağa gösterilmiştir. Örnek kümeleri, YSA ve Bayes sınıflandırıcılarına ayrı ayrı sunulmuştur. Tablo 4'e göre ham ve istatistiksel özellik temelli YSA modelinin test performanslarının ortalaması sırasıyla % 96,70 ve % 97,85 olarak bulunmuştur. Buna göre istatistiksel özellik çıkarıldıktan sonra örüntüleri doğru sınıflandırma performansı olarak % 1,19 oranında artmıştır. Bu çalışmadaki bulgular, Gauri [12] ve Hassan [18]'in farklı istatistiksel özellikler kullanarak, YSA sınıflandırma performanslarını artırdıklarını gösterdikleri çalışmalarla uyumludur. Tablo 5'e bakıldığında, Bayes sınıflandırıcı kullanıldığında, bu fark % 91,56'dan % 99,02'ye, %8,15 oranında artmıştır. Ayrıca, YSA özellik temelli sınıflandırıcıya göre % 1,17 oranında daha doğru sınıflandırmıştır.

### 6.1 Hata Matrisleri (Confusion Matrix)

Hata matrisi tablosu kullanılan sınıflandırıcının ilgilenilen örüntüyü doğru sınıflandırma oranı veya diğer muhtemel beş örüntü sınıfından olma oranını (yanlış sınıflama oranı) gösteren matristir [17]. Tablo 6 ve Tablo 7'de ham veri veya istatistiksel özellik kullanarak elde edilen test sonuçlarının hata matrisleri verilmiştir. YSA ile yapılan örüntü tanıyıcı sistem için, doğru sınıflandırma performansları birbirlerine yakın olduğundan dolayı hata matrisleri

oluşturulmaya gerek duyulmamıştır. Tablo 6'da ham veri YSA Bayes örüntü tanıyıcı sistem sonuçları incelenecek olursa, normal örüntülerin % 16,53 gibi büyük bir oranda, tekrarlayan çevrim örüntüleri olarak ve % 0,26 oranında da aşağı eğilim örüntüsü olarak sınıflandırma eğilimi gösterdikleri görülmektedir. Fakat, istatistiksel özellik kullanarak sınıflandırma yapıldığında ise tüm normal örüntülerin % 100 oranında doğru sınıflandırmıştır. Bu, istatistiksel özellik temelli sınıflandırıcıların doğru sınıflandırma performansını artırdığının kanıtıdır. Aynı şekilde diğer örüntü tiplerinin sınıflandırma performansı, ham veri kullanılan örüntü tanıyıcı sisteme göre başarı oranlarının arttığı açık şekilde görülmektedir. Ayrıca, Tablo 8'de bu iki örüntü tanıyıcı sistem için Tablo 5'de bulunan doğru sınıflandırma performansları  $\alpha=0,01$  anlam düzeyinde eşleştirilmiş t (paired- t test) testi kullanılarak performans farkları karşılaştırılmıştır.

Tablo 6. Ham veri hata matrisi (Raw data based confusion matrix)

Gerçek Örüntü Sınıfları Yüzdesi	Belirlenmiş Örüntü Sınıfları Yüzdesi					
	NOR	TEÇ	YUE	AŞE	YAD	AAD
NOR	83,20	4,80	0,00	0,00	0,27	0,00
TEÇ	16,53	95,20	0,53	0,00	0,00	0,27
YUE	0,00	0,00	98,40	0,00	14,40	0,00
AŞE	0,26	0,00	0,00	99,46	0,00	12,00
YAD	0,00	0,00	1,07	0,00	85,33	0,00
AAD	0,00	0,00	0,00	0,54	0,00	87,73

Tablo 7. İstatistiksel özellikli veri hata matrisi (Statistical-feature based data confusion matrix)

Gerçek Örüntü Sınıfları Yüzdesi	Belirlenmiş Örüntü Sınıfları Yüzdesi					
	NOR	TEÇ	YUE	AŞE	YAD	AAD
NOR	100	1,34	0,00	0,00	0,00	0,00
TEÇ	0,00	98,66	0,00	0,00	0,00	0,00
YUE	0,00	0,00	98,93	0,00	1,04	0,00
AŞE	0,00	0,00	0,00	99,46	0,00	1,87
YAD	0,00	0,00	1,07	0,00	98,93	0,00
AAD	0,00	0,00	0,00	0,54	0,00	98,13

Tablo 8. Performans oranı anlamlılık testi (Significance test of performance rate)

Performans Ölçütü	Hipotez	$t_{ist}$	$t_{kri}$	Karar
Doğru Sınıflandırma Ortalaması	$H_0 : \mu = 0$ $H_1 : \mu > 0$	12,85	3,36	$H_0$ reddedilir $H_0$ reddedilemez

Tablo 8'e göre  $t_{istatistik} > t_{kritik}$  olduğundan  $H_0$  hipotezi reddedilir. Böylelikle istatistiksel özellik çıkarımlı Bayes örüntü tanıyıcının, ham veri kullanan örüntü

tanıyıcıya göre performansının yüksek olmadığını gösterecek yeterli istatistiksel kanıt mevcut değildir.

## 7. SONUÇ (CONCLUSION)

Bu çalışmada, kontrol grafiklerinde oluşabilecek normal, tekrarlayan çevrimler, aşağı eğilim, yukarı eğilim, aşağı ve yukarı değişim şeklindeki örüntüleri sınıflandırmak için ham veri ve istatistiksel özellikler olarak da ortalama, standart sapma, çarpıklık, basıklık katsayısı, regresyon doğrusu eğimi ve Pearson korelasyon katsayısı değerlerini girdi vektöründe kullanan YSA ve Bayes sınıflandırıcıları kullanılmıştır.

Örüntüleri oluşturan gözlem değerlerinden seçilmiş istatistiksel özellikleri kullanan YSA ve Bayes sınıflandırıcılarının doğru sınıflandırma performansının, ham verileri kullanan sınıflandırıcılara göre daha yüksek tanıma performansı gösterdikleri gözlenmiştir.

Kontrol grafikleri üzerinde değişik şekiller oluşabilmektedir. Pratikte, izlenen süreçte ölçülen kalite karakteristiğinin ortalama değerinde zaman ile bir düşme söz konusu olursa o zaman grafik üzerinde aşağıya doğru azalan bir eğilim görülmektedir. Kalite kontrol grafiklerinde oluşan her bir şekil için çeşitli önleyici önlemler alınmalıdır. Önemli olan örüntünün tanınmasıdır. Otomatik olarak örüntü tanıyan bir sistem kurulması halinde önleyici tedbirleri çalışanlara bildirmek ve gerekeni yapmaları istemek mümkün olabilir. Bu nedenle oluşabilecek olan örüntülerin otomatik olarak tanınması imalat sektörü için çok önemlidir. Bu çalışma sonucuna göre, istatistiksel özellik temelli Bayes sınıflandırıcının yüksek sınıflandırma performansı vermesinden dolayı, bu sınıflandırıcının gerçek zamanlı örüntü tanıma uygulamalarında rahatlıkla kullanılabileceği düşünülmektedir. Bu çalışmanın devamında ise diğer sınıflandırma teknikleri (k-en yakın komşuluk metodu ve karar ağaçları gibi) ile burada kullanılan sınıflandırıcıların performanslarına yönelik çalışmalar yapılabilir.

## KAYNAKLAR (REFERENCES)

1. Shewhart W.A., **Economic Control of Quality of Manufactured Product**. New York: Van Nostrand, 1931.
2. Bozkurt, R. **Kalite İyileştirme Araç ve Yöntemleri (İstatistiksel Teknikler)**, Ankara: MPM Yayınları No:630, 2001.
3. Montgomery DC. **Introduction to Statistical Quality Control**, 5th edition, John Wiley, NJ, ABD, 2005.
4. Pham D.T., Oztemel E., “Control chart pattern recognition using neural networks”, **Journal of Systems Engineering**, Cilt No:2, 256–262, 1992.
5. Hwang H.B., Hubele N.F., “Back-propagation pattern recognisers for X control charts:

methodology and performance”, **Computers & Industrial Engineering**, Cilt 24, 219-235, 1993.

6. Velasco T., Rowe M.R., “Back propagation artificial neural networks for the analysis of quality control charts”, **Computers and Industrial Engineering**, Cilt 25,397–400, 1993.
7. Cheng C.S., “A neural network approach for the analysis of control chart patterns”, **International Journal of Production Research**, Cilt No: 35, 667–697, 1997.
8. Guh R.S., Tannock J.D.T., “Recognition of control chart concurrent patterns using a neural network approach” **International Journal of Production Research**, Cilt 37,1743–1765, 1999.
9. Guh R.S., Zorriassatine F., Tannock J.D.T, O’Brien C., “On-line control chart pattern detection and discrimination—a neural network approach”, **Artificial Intelligent Engineering**, Cilt 13, 413–425, 1999.
10. Perry M.B., Spoeer J.K., Velasco T., “Control chart pattern recognition using back propagation artificial neural networks”, **International Journal of Production Research**, Cilt 39,3399–3418, 2001.
11. Sagiroglu S., Besdok E., Eler M. “Control chart pattern recognition using artificial neural networks”, **Turkish Journal of Electrical Engineering**, Cilt 8, 137-147, 2000.
12. Gauri S.K., Chakraborty S., “Feature-based recognition of control chart patterns”, **Computers and Industrial Engineering**, Cilt 51,726–742, 2006.
13. Ebrahimzadeh A., Ranaee V., “Control chart pattern recognition using an optimized neural network and efficient features”, **ISA Transactions**, Cilt 49,387-393, 2010.
14. Ranaee V., Ebrahimzadeh A., Ghaderi R., “Application of the PSO-SVM model for recognition of control chart patterns”, **ISA Transactions**, Cilt 49, 577-586, 2010.
15. Swift J.A., Mize J.H., “Out-of-control pattern recognition and analysis for quality control charts using lisp-based systems”. **Computers & Industrial Engineering**, Cilt 28, 81-91, 1995.
16. Le Q., Goal X., Teng L., Zhu M., “A new ANN model and its application in pattern recognition of control charts” **Proc. IEEE. WCICA**, 1807-1811, 2008.
17. Cheng Z., Ma Y., “A research about pattern recognition of control chart using probability neural network”, **Proc. ISECS**, 140-145, 2008.
18. Hassan A., Nabi Baksh M.S., Shaharoun A.M., Jamaluddin H., “Improved SPC chart pattern recognition using statistical features”, **International Journal of Production Research**, Cilt 41, 1587–1603, 2003.
19. Anagun, A.S., “A Neural Network Applied to Pattern Recognition in Statistical Process



- Control”, **Computers and Industrial Engineering**, 35:1-2, 185-188, 1998.
20. Pham D.T., Wani M.A., “Feature-based control chart pattern recognition”, **International Journal of Production Research**, Cilt 35,1875–1890, 1997.
21. Khoo, Michael B.C. , “Performance Measures for the Shewhart  $X$  Control Chart”, **Quality Engineering**, Vol. 16, No.4, 585-590, 2004.
22. Guh R.S., “Simultaneous process mean and variance monitoring using artificial neural networks”, **Computers and Industrial Engineering**, Cilt 58, 739-753, 2010.
23. Joanes, D.N., Gill C.A., “Comparing measures of sample skewness and kurtosis”, **Journal of the Royal Statistical Society (Series D): The Statistician**, 47 (1), 183-189, 1998.
24. Ozkan Y., **Veri Madenciliği Yöntemleri**, Papatya Yayıncılık, İstanbul, 2008.
25. Gauri S.K., Chakraborty S., “Improved recognition of control chart patterns using artificial neural networks”, **International Journal of Advanced Manufacturing Technology** Cilt 36, 1191- 1201, 2008.
26. Demuth H., Beale M., **Neural network toolbox user's guide**. Math Works, Natick, MA, ABD, 1998.

