

## APPROACHES FOR PROBLEM DIAGNOSIS VIA STATISTICAL PROCESS CONTROL CHARTS

Bülent KOÇER

Selçuk University, Faculty of Engineering and Architecture, Department of Industrial Engineering,  
42300, Selçuklu, Konya, TURKEY

Burak BİRGÖREN\*

Kırıkkale University, Faculty of Engineering, Department of Industrial Engineering,  
71451, Yahşihan, Kırıkkale, TURKEY, e-mail:birgoren@kku.edu.tr

### ABSTRACT

Statistical process control charts aim to detect out-of-control signals which indicate existence of special causes effecting the process. Once such a signal is detected, the interpretation of the signal, that is, discovering the actual causes behind the signal, rests upon the shoulders of operators or engineers. Recently, some techniques have been developed for making this interpretation process easier. This study presents an overview of such techniques in three categories: traditional one-variable control charts, artificial neural network applications and multivariate control charts.

*Key Words:* SPC charts, out-of-control signal, problem diagnosis

## İSTATİSTİKSEL PROSES KONTROL ÇİZELGELERİNDE HATA TEŞHİSİNE YÖNELİK YAKLAŞIMLAR

### ÖZET

İstatistiksel proses kontrol çizelgeleri, süreci etkileyen özel nedenlerin varlığına işaret eden kontrol-dışı sinyalleri saptamayı amaçlar. Böyle bir sinyal saptandığında bunun yorumlanması, diğer bir deyişle sinyale yol açan gerçek nedenlerin ortaya çıkarılması operatör ya da mühendislerin görevidir. Son zamanlarda bu yorumlama işlemi kolaylaştıracak bazı teknikler geliştirilmiştir. Çalışma, bu teknikleri üç ana başlık altında incelemektedir: geleneksel tek değişkenli kontrol çizelgeleri, yapay sinir ağı uygulamaları ve çok değişkenli kontrol çizelgeleri.

*Anahtar Kelimeler:* İPK çizelgeleri, kontrol dışı sinyal, hata teşhisi

### 1. GİRİŞ

İstatistiksel Proses Kontrol (İPK), bir üretim sürecinde (proses) kaliteyi sağlamak, sürdürmek ve iyileştirmek amacıyla kullanılan istatistik teknikleri içerir; bu tekniklerin en önemlisi İPK çizelgeleridir. Bu çizelgeler kısa vadede süreç hatalarının teşhisi ve giderilmesini, uzun vadede ise süreç kalitesinin iyileştirilmesini hedefler.

İPK çizelgelerinde, bir üründe kaliteyi belirleyici olan çap, boy, açı gibi değişkenler çizelgelenir. İPK çerçevesinde kalite, bu tür kalite değişkenlerinin spesifikasyonlara uyumluluğu şeklinde tanımlanır. Örneğin bir borunun iç çapı, bu çap için belirlenen hedef değere ne kadar yakınsa kalite o kadar yüksek olacaktır. İstatistiksel bir ifadeyle, değişkenliğin (varyasyonun) azaltılmasıyla kalite artar.

### 1. INTRODUCTION

Statistical Process Control (SPC), includes various statistical techniques that are used to provide, continue and improve quality in a production process; the most important of these techniques is SPC charts. These charts are used to diagnose and eliminate the process problems in the short term, and also to improve the process quality in the long term.

SPC charts monitor key variables such as diameter, length and angle that are used to define the quality of a product. In SPC framework, quality is defined as the conformance of these variables to specifications. For instance, the closer the inner diameter of a pipe to the target diameter value, the higher the quality of the product. In a statistical sense, if the variability of a variable

Çizelgelerde üründen alınan ölçüm değerleri ya da bunlardan üretilen bir istatistik değer kullanılır. Bu değer, kontrol bölgesi olarak adlandırılan bir değer aralığındaysa sürecin kontrol altında olduğu kabul edilir. Değer kontrol bölgesi dışında ise bu durum bir kontrol-dışı sinyal olarak nitelenir ve süreçte hataya yol açan bir özel nedenin (hata kaynağının) etkili olduğuna hükmedilir. Süreç, mümkünse durdurularak, bu neden araştırılır, saptanır ve ortadan kaldırılması için gerekli önlemler alınır. Literatürde geliştirilmiş birçok İPK çizelgeleme yöntemi vardır ve bunlarının hepsinin temel çalışma mantığı kontrol bölgesi ve kontrol-dışı sinyaline dayalıdır.

Kontrol-dışı sinyallerin nedenini süreç uzmanı olan operatör ya da mühendis belirleyebilir. Bu kişiler çizelgede sinyale kadarki davranışı doğru yorumlayabilirlerse ne tip bir hatanın mevcut sinyale yol açtığını tahmin edebilirler. Etkin hata teşhisi için süreç uzmanlığının yanı sıra İPK uygulamalarında tecrübe ve istatistik bilgisi de gerekmektedir.

Kontrol dışı sinyallerin yorumlanmasını kolaylaştırmak için yapılan çalışmalar, kontrol dışı sinyaller ile bunlara yol açan hata kaynakları arasındaki ilişkiyi sistematik bir biçimde ortaya koymayı hedefler. Böylece operatör ve mühendislerin sorumluluğu bir ölçüde hafifleyecektir.  $\bar{X}$  ve  $R$  gibi tek değişkenli İPK çizelgelerinde anormal izlerle hata kaynakları arasındaki ilişkiler genel biçimleriyle uzun yıllardır bilinmektedir. Belli bir sürece özel ilişki türlerinin belirlenebilmesi içinse son dönemde bir yapay zeka yöntemi olan yapay sinir ağlarından yararlanılmaktadır. Son yıllarda hızla yaygınlaşan Hotelling  $T^2$  gibi çok değişkenli İPK çizelgelerinde ise bu tür ilişkilerin belirlenmesi için yoğun çalışmalar devam etmektedir.

## 2.GELENEKSEL YAKLAŞIM

Bütün süreçler bünyelerinde değişkenlik barındırırlar. Bu değişkenlik, genel ve özel nedenlere dayanmaktadır. Genel nedenlere dayanan değişkenlik, sürecin doğasında var olan birçok hata nedeninin ortak etkisidir. Özel nedenler ise genel nedenlere kıyasla baskın bir etkiye sahiptir; süreçte ayırt edilebilir izler bırakırlar. Özel nedenler etkili değilse, süreç kontrol altında kabul edilir; aksi taktirde kontrol dışındadır. İPK, öncelikle süreci kötü etkileyen bu özel nedenleri saptayıp ortadan kaldırmayı hedefler. Zamanla özel nedenlerin birer birer giderilmesiyle, çizelgelerin kontrol sınırları daralacaktır. Ayrıca, doğal değişkenliğe yol açan nedenler de su yüzüne çıkacaktır, çünkü bunlar arasında etkileri büyük olanlar özel neden haline dönüşecektir. Böylece uzun vadede doğal değişkenlik azalacaktır.

İstatistiksel bir bakış açısıyla İPK çizelgeleri, doğal değişkenliği ifade eden dağılımdan sapma olduğu hipotezinin çizelgelenen her yeni noktayla sürekli test edilmesi işlemidir (1).  $\bar{X}$ ,  $R$  ve  $S$  gibi geleneksel çizelgelerde, çizelgelenen bir noktanın  $\pm 3\sigma$  kontrol sınırlarının dışına çıkmasıyla hipotez kabul edilir –süreç

decreases, the quality of the product increases.

The charts monitor either directly the measurements taken from a product or a statistical value derived from the measurements. The process is assumed to be in-control, if the monitored value is within a defined range, that is, the control region. If the monitored value is out of the control region, this situation is defined as an out-of-control signal and it is concluded that a special cause (problem source) leading to an error is present in the process. Then, the process is stopped if possible, this cause is searched, identified and the necessary actions are taken to fix it. There are many SPC charting methods proposed in the literature, their operating principles are all based on control regions and out-of-control signals.

The operator or the engineer, as a process expert, can determine the causes of out-of-control signals. If they can correctly interpret the behavior of the chart until the signal, they can predict the problem that led to the signal. For effective problem diagnosis, experience in SPC applications and knowledge of basic statistics as well as process expertise are necessary.

There are studies performed for facilitating the interpretation of out-of-control signals; they aim to describe the relationships between the signals and the problem sources in a systematic way, so that the responsibility of the operator or the engineer would be eased. General relationships between abnormal chart patterns and problems sources have been well known for univariate charts, ie  $\bar{X}$  and  $R$  charts, for a long time. Recently, for determining certain process-specific relationships, artificial neural networks, as an artificial intelligence approach, have been used. Also, rigorous efforts have been spent to identify such process-specific relationships in multivariate SPC charts such as the Hotelling's  $T^2$  chart.

## 2.CONVENTIONAL APPROACH

All processes have variability stemming from either common causes or special causes. Common-cause variation is the combined effect of many problem sources that naturally exist in a process. Special causes have a dominant effect on the process as compared to common-causes; they leave distinguishable signs observable on an SPC chart. If the special causes are not affecting the process, the process is assumed to be in control; otherwise, it is said to be out-of-control. SPC aims to detect and eliminate these special causes that are affecting the process negatively. As they are eliminated one by one, the control limits on the charts will get narrower. Further, some of the common causes would become apparent, because the common causes with more impact on the process will have been transformed into special causes, through which natural variation would decrease in the long term.

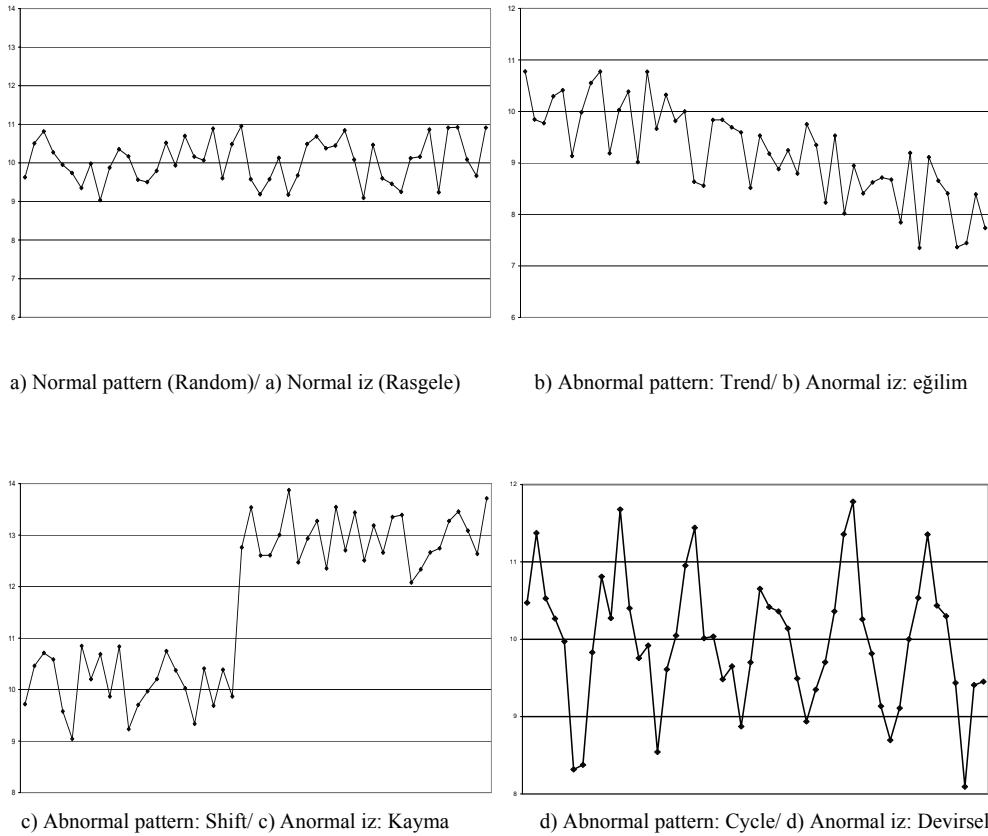
From a statistical viewpoint, monitoring each data point on an SPC chart is equivalent to testing the hypothesis that a deviation has occurred from the distribution that is modeling the natural variability in the process (1). In conventional charts such as  $\bar{X}$ ,  $R$  and  $S$  charts, when a plotted point goes out of  $\pm 3\sigma$  limits, the hypothesis is

kontrol dışıdır (1).

Diğer taraftan çizelgelenen noktaların olası kontrol-dışı durumları saptamak amacıyla incelenmesi, keşfe yönelik (exploratory) veri analizidir (2); bu inceleme, her türlü anormal izi saptamayı ve bunlarla hata kaynakları arasında bağlantı kurmayı hedefler. Böyle başlıca izler ilk kez Western Elektrik şirketi tarafından belirlenmiştir (3). Bu izlere örnek olarak çizelgede  $\pm 2\sigma$  sınırlarının dışında ardışık iki nokta gözlenmesi verilebilir. Hoyer ve Ellis (4), böyle yedi tür anormal iz vererek bunları genel olarak değerlendirmektedir. Montgomery (1), bu izlere ek olarak her türlü anormal izin de bir kontrol dışı sinyal olarak değerlendirilmesi gerektiğini belirtir; kaymalar, eğilimler ve devrimsel izler (S yalpalamaları) başlıca anormal iz türleridir ve Şekil 1'de gösterilmiştir.

accepted, that is, the process is out-of-control (1).

On the other hand, investigation of plotted points for discovering potential out-of-control situations is considered as exploratory data analysis (2); this investigation intends to detect all kinds of abnormal patterns and associate them with their special causes. Such major patterns were first designated by Western Electric Company (3). As an exemplary pattern, observing two successive points out of  $\pm 2\sigma$  limits is considered an out-of-control signal. Hoyer and Ellis (4) presented an assessment of seven such patterns. In addition to these patterns, Montgomery (1) states that all types of abnormal patterns should be treated as an out-of-control-signal; shifts, trends and cycles are such major pattern types and are illustrated in Figure 1.



**Figure 1.** Some general types of patterns on SPC charts  
**Şekil 1.** İPK çizelgelerinde bazı genel iz türleri

Bu izlerin nelerden kaynaklandığı artık bilinmektedir. Örneğin eğilimler, makine aksamının giderek yıpranması ya da bir kimyasal süreçte karışımın bileşenlerinin farklılaşması gibi durumlarda sıkça ortaya çıkar.

Geleneksel yaklaşımın yanı sıra geçmişte başarıyla uygulanmış ancak yaygınlık kazanmamış yöntemler de vardır. Bunların en ilgi çekicilerinden birinde Seder (5), bazı grafik yöntemler kullanmanın teşhisi kolaylaştıracağını belirtmiştir. Bunlardan pozisyon-boyut

Sources of these patterns are now well-known. For example, trends appear as machine tools are worn out, or components of a chemical mixture change in time.

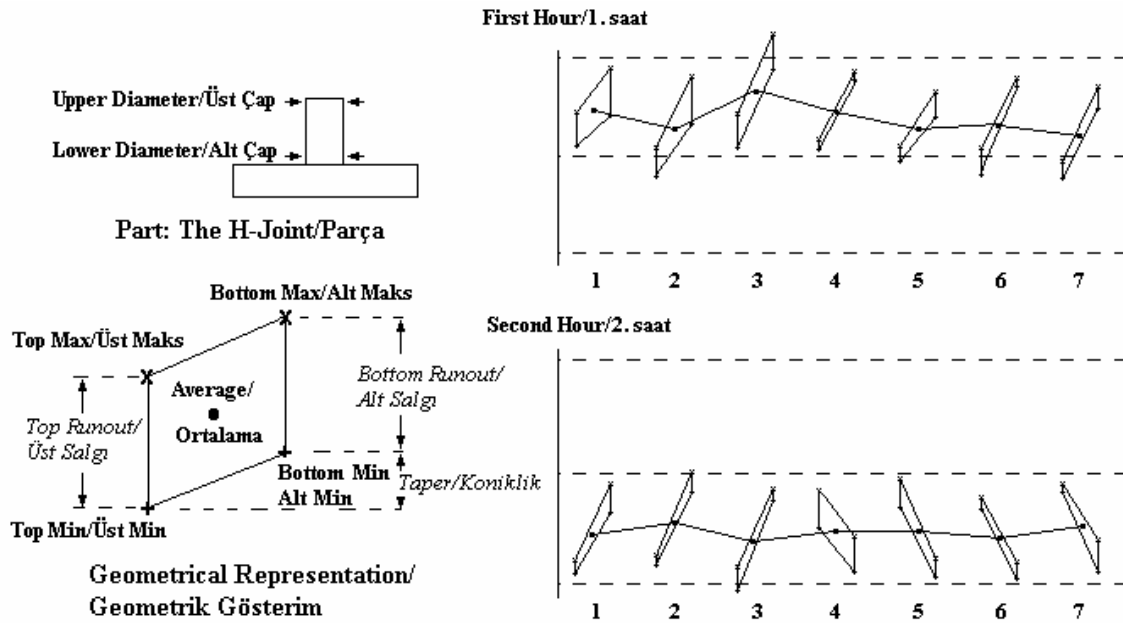
Besides the conventional approach discussed so far, there are some other methods that have been applied successfully, but have not got as popular. In one of them, Seder (5) mentioned that using graphics facilitates diagnosis of problems. He proposed new charts and graphical methods that distinguish different sorts of

diyagramları (6) ve çok-boyut (Multi-vari) çizelgeleri (7), kalite uzmanlarının ilgisini çekmeye devam etmiştir. Pozisyon-boyut diyagramları, parçaların teknik çizimlerini andıran şekiller üzerinde, gözlem alınan noktalardaki ölçümleri gösterir. Bu diyagramlar, çok değişkenli İPK bölümünde ele alınacaktır.

Çok-boyut çizelgeleri ise, birbiriyle ilişkili birden çok kalite değişkenini belli geometrik şekiller oluşturacak şekilde çizelgeler; böylece hata kaynaklarının ürettiği izler kolayca gözlenebilir. Şekil 2’de sanayide uygulanmış bir çok-boyut çizelgesi verilmiştir (7).

variations. Among them, position-dimension diagrams (6) and Multi-vari charts (7) have continued to attract the attention of quality specialists. Position-dimension diagrams show quality measurements on diagrams that resemble technical drawings of a product. An example of these diagrams will be given in the multivariate SPC section.

Multi-vari charts, on the other hand, plot several correlated quality variables in a manner to create meaningful geometric figures, so that the patterns would be easily discerned. Figure 2 illustrates a Multi-vari chart applied on a real process (7).



**Figure 2.** Example of a Multi-vari chart  
**Şekil 2.** Çok-boyut (multi-vari) çizelgesine bir örnek

Bu uygulamada bir silindirik eklem parçasının alt ve üst kısımlarına ait minimum ve maksimum çap değerleri -dört kalite değişkeni- günün farklı iki saatinde alınan yedişer parçada ölçülmüş; şekildeki geometrik gösterim esas alınarak çizelgelenmiştir. Orta çizgi hedef değer, alt ve üst çizgiler tolerans sınırlarıdır. Çizelgedeki gösterimde dört değişkenin değerlerinin yanı sıra, bunların birer fonksiyonu olan ve idealde sıfır olması istenen alt salgı, üst salgı ve koniklikteki değişim de kolayca gözlenebilmektedir: Örneğin 2. saatte, 3. üründen 4. ürüne geçişte konikliğin yönü değişmiş, salgı değerlerinde ciddi artış olmuştur.

Çok-boyut çizelgeleri, birden çok değişkenin değerini aynı çizelgede gösterir; bu bakımdan çok değişkenli İPK çizelgelerinden farklıdır. Değişik parçalar ve kalite değişkenleri için daha farklı geometrik gösterimler benimsenebilir.

In this application, the minimum and maximum diameters of lower and upper sections of a cylindrical joint –four variables– are measured on seven parts per hour for two different hours of a day, and they are charted so as to form the geometric representation given in Figure 2. The center-line is the target value, the upper and lower lines are the tolerance limits. This representation also allows monitoring runouts of lower and upper diameters and taper, which are functions of the charted variables and desired to be zero as their target value: For instance, at the 2<sup>nd</sup> hour, moving from the 3<sup>rd</sup> part to 4<sup>th</sup> part, the direction of taper changed, and serious increases in runout values were observed.

Multi-vari charts display several variables on a single chart; in this respect, they are different from multivariate SPC charts. For different parts and quality variables, various geometric representations can be adopted.

### 3. YAPAY SINİR AĞI UYGULAMALARI

Geleneksel yaklaşıma kıyasla izlerin daha etkin biçimde saptanması için son dönemde yapay sinir ağı kullanılan birçok çalışma yapılmıştır (8). Bu çalışmalarda, Şekil 1'de gösterilen izler ve bu izlerin daha karmaşık biçimlerinin bilgisayar tarafından otomatik teşhisi amaçlanmıştır. Kullanılan yapay sinir ağlarında danişmalı öğrenme algoritmaları kullanılmaktadır. Sinir ağları, çizelgelerdeki belli iz türlerini öğrenmek üzere bir eğitim kümesiyle eğitilmekte ve ardından gerçek sürecin benzetimi yapılarak ağların bu izleri benzetim verisinde ne ölçüde saptayabildiği ölçülmektedir. Çalışmalarda ele alınan çizelgeler  $\bar{X}$ ,  $R$ ,  $S$  ve  $CUSUM$  çizelgeleridir.

Bu alandaki ilk çalışmalarda Pugh (9) ve Smith (10),  $\bar{X}$  ve  $R$  çizelgelerinde ortalama değişikliklerinin saptanması için yapay sinir ağlarını kullanmışlar ve eğittikleri ağların ortalama ve varyanstaki özelliklerle küçük değişimleri saptamada geleneksel kontrol sınırlarından daha başarılı olduğunu gözlemişlerdir.

Bu iki çalışmada izler sadece ortalama ve standart sapma değişiklikleri ile sınırlı tutulurken kayma, eğilim, devirsel izler gibi farklı türde izleri saptamak için birçok çalışma da yapılmıştır. Örneğin Pham ve Öztemel (11, 12) çalışmalarında bu izleri hem tek tek hem de bir arada – kayma ve devirsel gibi- saptamaya yönelik olarak birden çok ağı eşzamanlı eğiterek kullanmışlardır. Guh ve Hsieh (13) yapay sinir ağlarını sadece izin türünü saptamakla kalmayıp aynı zamanda izin büyüklüğünü de tahmin edecek şekilde eğitmiştir.

Bir yapay sinir ağının saptamaya çalıştığı iz türlerinin sayısı arttıkça izleri saptama yetenekleri azalmaktadır; buna bir çözüm olarak her biri bir iz türünü saptamada uzmanlaşmış birden çok ağıın beraberce kullanılması önerilmektedir (12, 14). Öte yandan saptanmak istenen izin küçüklüğü veya eğitim kümesinin hacminin düşüklüğü ağ performansını olumsuz yönde etkilemektedir.

Yapay sinir ağı araştırmaları tek değişkenli çizelgelere odaklanmakla beraber literatürde çok değişkenli bir çalışmaya rastlanmıştır (15). Bu çalışmada çok değişkenlilik sadece iki değişkenle sınırlandırılmış ve iki değişkenin ortalamaları, varyansları ve kovaryansındaki değişikliklerin saptanması hedeflenmiştir. Çok değişkenli İPK çizelgelerinde değişken sayısı arttıkça ortaya çıkabilecek iz türleri de büyük çeşitlilik ve karmaşıklık göstermeye başlar. Dolayısıyla bu çalışma, zor bir problemin çözümü için ilk teşebbüstür.

Yapay sinir ağları, güçlü iz tanıma (pattern recognition) yetenekleri sayesinde İPK çizelgelerinde ancak gözle fark edilebilecek saptanması zor izleri ayırt edebilmektedir. Böylece uzmana düşen görevi üstlenerek sadece izin yorumunu uzmana bırakmaktadır. Ayrıca bir sürece has iz türlerini öğrenebildikleri için uzmana kolay yorumlanabilir sinyaller vermektedir.

### 4. ÇOK DEĞİŞKENLİ İPK

Bir sürecin performansı genellikle birden fazla kalite değişkenine dayanır. Örneğin bir parçaya matkapla

### 3. ARTIFICIAL NEURAL NETWORK APPLICATIONS

Recently, many studies used artificial neural networks in order to detect patterns more effectively than the conventional approach. The aim of these studies is the automatic diagnosis of the patterns in Figure 1 and their more complex forms. Usually, supervised learning algorithms were adopted. In such studies, neural networks were trained in order to learn specific patterns using a training set, and then, by simulating the process, detection capabilities of the neural networks were measured. These studies investigated performance of  $\bar{X}$ ,  $R$ ,  $S$  and  $CUSUM$  charts.

In a pioneering work, Pugh (9) and Smith (10) used neural networks for detecting deviations in the mean values on  $\bar{X}$  and  $R$  charts, and they observed that the neural networks are more successful than the conventional control limits especially in detecting small deviations in the mean value and variance of observed data.

While the research objective in the above two studies was limited to only changes in the mean value and standard deviations, many other studies considered patterns such as shifts, trends and cycles. Pham and Öztemel (11, 12) trained multiple parallel networks in order to detect single patterns and also multiple patterns – for instance a shift and a cycle together. Guh and Hsieh (13) trained networks not only for detecting existing patterns but also for forecasting their magnitudes.

As the number of different patterns increases, the detection power of a neural network decreases; a proposed solution is to use parallel networks, each of which is specialized for detecting a specific pattern (12, 14). Also, small magnitudes of patterns or small sizes of training samples affect the network performance negatively.

While neural network approaches are generally focused on univariate charts, there is only one multivariate study found in the literature (15). This study considered only bivariate situations and the aim was restricted to detecting deviations in the mean, standard deviation and covariance. In multivariate SPC, as the number of variables gets larger, variety and complexity of patterns increase. Consequently, this study is a first attempt to solve a hard problem.

By their strong pattern recognition capability, neural networks can detect SPC chart patterns which are hard to distinguish and can only be detected by an expert look. Therefore, they can take over the responsibility of the expert for detecting out-of-control situations, leaving only the interpretation to the process expert. Further, the detected patterns are likely to be easily interpreted by the expert as neural networks can learn process-specific patterns.

### 4. MULTIVARIATE SPC

The performance of a process usually depends on more than one variable. Let's consider the following six

delinen iki delik için şöyle altı değişkenden bahsedilebilir:  $X_1$ =birinci deliğin çapı,  $X_2$ =birinci deliğin x-koordinatı,  $X_3$ =birinci deliğin y-koordinatı,  $X_4$ =ikinci deliğin çapı,  $X_5$ =ikinci deliğin x-koordinatı,  $X_6$ =ikinci deliğin y-koordinatı. Geleneksel olarak bunlardan sadece en önemli görülen değişken (örneğin  $X_1$ ) ölçülür ve tek değişkenli İPK çizelgelerinde izlenir; bu durumda diğer değişkenlerin değerleri ve sürece etkileri göz ardı edilmektedir. Çok değişkenli İPK çizelgeleri birden fazla değişkeni eş zamanlı izler, bunu yaparken de değişkenler arasındaki etkileşimi göz önünde bulundurur.

Bu çizelgelerin kontrol dışı sinyalleri hata nedenlerini gösterecek şekilde yorumlanabilir. Diyelim ki süreç uzmanları,  $X_1$  değişkenindeki kaymanın A, B, C nedenlerinden,  $X_2$  değişkenindeki kaymanın D ve E nedenlerinden kaynaklandığını; ayrıca  $X_2$  ve  $X_5$  beraber artmış ya da azalmışsa bunun da F nedeninden kaynaklandığını bilmektedirler. Bu durumda, örneğin birçok değişkende kayma gözleniyorsa, ancak  $X_2$  ve  $X_5$  değişkenlerinin aynı yönlere hareket ettiği dikkat çekiyorsa, hata nedenlerinden bir tanesi F olabilir. Örneğin F nedeni, parça işlem için sabitlenirken x-ekseninde yanlış yerleştirilmesiyle ilgili olabilir.

Çok değişkenli İPK çizelgeleri ilk kez 1940'larda geliştirilmesine rağmen (16), sanayide yaygın kullanımı 1990'lı yıllarda başlamıştır. Bunun başlıca nedeni, üretimin gittikçe otomatikleşen bilgi kontrollü sistemlerle yapılmaya başlanmasıdır. Bu sistemlerde hataların tasnifi ve bu hatalardan yola çıkarak kaynaklarına inilmesi işgücü-yoğun sistemlerdekinden çok daha kolaydır (1, 17). Otomatikleşen üretim sistemlerinde veri toplanması için de otomatik ve yeni teknolojiyle donatılmış sistemler geliştirilmiştir. Bunlar hızlı ve masrafsız şekilde çok değişkenli ölçüm yapmaktadır. Örneğin imalat sanayiinde, kullanışlı hassas maşar ve ölçüm aletleri, üç-boyutlu koordinat ölçüm cihazları, kameralara veya lazer teknolojilerine dayalı optik sistemler, bilgisayarla bütünleşik şekilde hata teşhisinde kullanılmaktadır (17-20). Kimya sanayiinde de benzer otomatik veri toplama sistemleri geliştirilmiştir (21).

Bol miktarda ve düşük maliyetli çok değişkenli kalite verilerinin toplanmasıyla çok değişkenli İPK uygulamaları da hızla yaygınlaşmıştır. Bu gelişmelere paralel olarak çok değişkenli İPK çizelgeleri üzerine literatüre geçen çalışmalar da büyük hızla artmıştır (22).

Çok değişkenli İPK çizelgelerinin en eski ve temel olanı Hotelling  $T^2$  çizelgeleridir; bu çizelgeler sürecin ortalamasının kontrol dışına çıktığını saptayıp bunu bir kontrol dışı sinyalle belirtir. Hotelling  $T^2$  çizelgelerinin sadece bir üst kontrol sınırı vardır, sınırı geçen noktalar bir kontrol-dışı sinyal olarak değerlendirilir. Çizelgelenen  $T^2$  istatistiği, çok değişkenli gözlemleri tek bir değere indirgeyen bir fonksiyonla elde edilir. Bu fonksiyon, değişkenler arasındaki kovaryans matrisini (etkileşimi) içerir.

İstatistiksel açıdan ortalama sapmalarını saptama gücü çok yüksek olan bu çizelgelerin, diğer taraftan mühendislerce yorumu zordur; çünkü  $T^2$  istatistiğinin pratikte bir anlamı yoktur. Son yıllarda  $T^2$  sinyallerini doğru yorumlayarak hata teşhisini kolaylaştırmak için

variables for two holes drilled on a part:  $X_1$ =diameter of the first hole,  $X_2$ =x-coordinate of the first hole,  $X_3$ =y-coordinate of the first hole,  $X_4$ =diameter of the second hole,  $X_5$ =x-coordinate of the second hole,  $X_6$ =y-coordinate of the second hole. Conventionally, only one of them is regarded as the most important one (e.g.  $X_1$ ), and it is measured and monitored on a univariate SPC chart, while the remaining variables and their effects are ignored. Multivariate SPC charts monitor several variables simultaneously, and also take into account the interactions among the variables.

The out-of-control signals from these charts can be used to identify problem causes. Suppose that process experts know that a shift in  $X_1$  results from causes A, B or C, a shift in  $X_2$  results from causes D or E, and also if  $X_2$  and  $X_5$  shift in the same directions (positive or negative) this results from cause F. In this case, while process data shows many shifts on various variables due to common causes, if significant shifts in  $X_2$  and  $X_5$  are noticeable, and they are also in the same direction, then this is considered as an indication of the cause F affecting the process.

Although, multivariate SPC charts were developed in the 1940s (16), their intensive use in the industry started in the 1990s. The main reason for this was emergence of computer-automated production systems. In these systems, classification of problems and tracking back to sources starting from problems is easier as compared to labor-intensive systems (1, 17). Computer-automated systems also gave rise to automated data collection systems, equipped with high technology. They take multivariate measurements quickly with less cost. For example, precise gages and measurement tools, three-dimensional coordinate measurement machines, vision systems based on cameras and laser technology have been employed in computer-integrated problem diagnosis in these production systems (17, 20). Similar automated data collection systems have also been developed for the process industry (21).

Collection of multivariate quality data in ample amounts with less cost has led to growing number of multivariate SPC applications. Also, multivariate SPC chart studies in the literature have increased rapidly (22).


The oldest and the fundamental multivariate SPC chart is the Hotelling's  $T^2$  chart; this chart monitors the process mean and gives an out-of-control signal when the process mean shifts significantly from its normal behavior. The Hotelling's  $T^2$  chart has only an upper control limit and points exceeding this limit are regarded as an out-of-control signal. The charted  $T^2$  statistic is a function reducing multivariate observations into single value. This function includes the covariance matrix among the variables (effect of interactions).

Although, this chart has a large power of detecting shifts in the mean values, its interpretation by engineers is difficult; because the  $T^2$  statistic does not carry any practical meaning. Recently, various methods have been developed in order to facilitate problem diagnosis by interpreting  $T^2$  signals properly (21, 23, 24). Some of these methods intend to detect the variables that are responsible for the out-of-control signals on the chart (25-30). It is

birçok yöntem geliştirilmiştir (21, 23, 24). Bu yöntemlerin bir kısmı  $T^2$  çizelgelerindeki sinyallerden hangi değişkenlerin sorumlu olduğunu saptamayı amaçlamaktadır (25-30). Bu yöntemlerde sinyale etkisi en çok olan değişken ya da değişken grubunun belirlenmesiyle hata kaynağının doğrudan saptanacağı varsayılmaktadır. Az evvel verilen matkap örneği, hata kaynaklarıyla değişkenler arasında bulunabilecek böyle doğrudan ilişkileri açıklamaktadır.

Hata kaynaklarının belli değişkenleri doğrudan etkileyeceği varsayımı her zaman doğru değildir ya da süreçteki hata kaynaklarının sadece bir kısmının etkilerini açıklayabilir. Bu varsayımın doğru olmadığı durumlarda, süreçteki hata kaynaklarının çok değişkenli gözlemlerde ne tür izler bırakacağı süreç uzmanlığına dayanarak belirlenip bu izlerin saptanmasına yönelik yöntemler geliştirilmiştir. Bu izler, değişken ortalamalarının belli yönlerde sapması şeklinde (6, 17, 18, 29-31) ya da  $T^2$  sinyallerinin çizelgede meydana getirdiği Şekil 1'dekine benzer izler şeklinde (32) olabilmektedir.

Genellikle bu çalışmalar zaman boyunca değil, sadece bir parçadan alınan gözlemlerde oluşan izler üzerine yoğunlaşmıştır. Örneğin Espada-Colon vd. (18) baskılı devre kartlarına lehim baskı sürecinde bu tür izlerin nasıl oluştuğunu incelemiştir. Şekil 3, bir baskılı devre kartındaki lehim pozisyonlarını göstermektedir. Toplam 20 pozisyon vardır ve her pozisyondaki lehim miktarı kamera ile ölçülmektedir. Kalite değişkenleri, ölçülen miktarların hedef değerden farkları şeklinde tanımlanmıştır.



assumed that by determining the variable or variables contributing significantly to the signal, the problem source would be directly uncovered. The drilling operation, described previously, explains such direct relationships between the variables and problem sources.

The assumption that some problem sources affect only certain variables is not always valid; it helps to explain only a certain group of sources. When it is not valid, methods are developed for determining patterns left by specific problem sources using process expertise. Once the patterns are identified, charts are used for detecting occurrences of these patterns in the process. These patterns are in the form of deviations in the variable means in specific directions (6, 17, 18, 29-31) or in the form of  $T^2$  chart patterns similar to those in Figure 1 (32).

Generally, these studies focused on patterns on a single part instead of patterns forming along successive time points. Espada-Colon et al. (18) examined how these patterns arise in solder paste printing operation on printed circuit boards. Figure 3 illustrates solder paste positions on a board. There are a total of 20 positions and solder paste amount on each position is measured via a camera. Quality variables are defined as the differences between the measured and the target values.

**Quality Variables:** Difference between the printed solder paste amount and the target amount/

**Kalite Değişkenleri:** Her pozisyondaki lehim miktarlarının hedef değerden farkları

**Quality Vector:**  $\mathbf{x} = (x_1, x_2, \dots, x_{20})'$

$x_i$ : Difference from the target amount at ith position

$x_i$  Negative: Paste amount less than target

$x_i$  Positive: Paste amount more than target

**Kalite Vektörü:**  $\mathbf{x} = (x_1, x_2, \dots, x_{20})'$

$x_i$ :  $i$  pozisyonunda hedef değerden fark

$x_i$  negatif: hedef değerden az lehim

$x_i$  pozitif: hedef değerden çok lehim

**Figure 3.** Solder paste positions on a printed circuit board and quality variables

**Şekil 3.** Baskılı devre kartında lehim pozisyonları ve kalite değişkenleri

Bir parça üzerinde oluşan izler ve bunlara neden olan hata kaynakları, süreç uzmanlarıyla yapılan mülakatlar ve veri analiziyle ortaya çıkarılmıştır. Bu izler Şekil 4'te gösterilmiştir. Her pozisyondaki sapma, sapmanın negatif ya da pozitif yönde olmasına göre içeri ya da dışarı bir okla gösterilmiştir; ok uzunlukları sapmanın miktarı ile orantılıdır. Ardından izin belirginleşmesi için ok uçları doğru parçalarıyla birleştirilmiştir. Şekil 4, Hata Kaynağı A ile ilişkili izin bir vektörle nasıl ifade edileceğini de göstermektedir, vektördeki değerlerin göreceli büyüklükler olması önemlidir.

Patterns that occur on a part and the related problem sources can be discovered through interviews with process experts and data analysis. These patterns are shown in Figure 4: Shifts at each position is displayed by an inward arrow if the variable is negative (less paste) and by an outward arrow if the variable is positive; the length of arrows are proportional to the magnitude of the variables. Then, the arrow heads are combined by lines for stressing the patterns. Figure 4 also illustrates the vector representation of the pattern associated with problem source A; it is important that elements of the vector have

Bu süreçte hata kaynaklarıyla doğrudan ilişkili  $k$  adet yön saptanmıştır. Gözlenen kalite vektöründe bu yönlerde bir sapmanın tespit edilmesi, ilişkili hata kaynağına doğrudan işaret edecektir ( $u_2$  yönü için Hata Kaynağı B ya da C gibi). Bu amaçla geliştirilen yöntemler arasında regresyonla kalite vektörünün yönler cinsinden çözümlenmesi (6, 18); çok değişkenli uzayda yönlerle ilişkili kontrol bölgeleri tanımlanması (17), ve  $T^2$  sinyalinin Scheffe-tipi aralıklarla çözümlenerek anlamlı sapma yönlerinin bulunması (29) sayılabilir. Şekil 4'te bu son yöntem özetlenmiştir. İstatistiksel olarak sapma yönlerinin bulunmasının yanı sıra gözlenen kalite vektörünün grafik gösterimi de yönlerin saptanmasını kolaylaştıracaktır. Şekil 4'te izler için kullanılan ok gösterimi kalite vektörü ( $X$ ) için de kullanılmıştır. Bu gösterim, 2. bölümde bahsedilen pozisyon-boyut diyagramları için iyi bir örnek oluşturur. Her kart için böyle yeni bir pozisyon-boyut diyagramı çizilmesiyle operatör, görsel olarak izler oluşup oluşmadığını kontrol edebilir, ayrıca bilmediği yeni izler keşfetme imkanı da bulur.

relative magnitudes.

In this process,  $k$  directions, directly associated with problem sources, were determined. Detection of a shift of the observed quality vector in these directions would point out the associated problem source directly (for  $u_2$ , Problem Sources B or C, etc.). The following methods have been developed for this purpose: decomposition of quality vector in terms of directions through regression analysis (6-18); defining control regions associated with directions in multivariate space (17); exploring significant shift directions by decomposing the  $T^2$  signal via Scheffe-type intervals (29), Figure 4 illustrates this method. Also, graphical display of the observed quality vector facilitates detecting potential shift directions. In Figure 4, the arrow representation adopted for display of patterns is also used for the quality vector ( $X$ ). This display is a good example for position-dimension diagrams, aforementioned in Section 2. The operator can check visually if any patterns show up on a new position-dimension diagram drawn for each card; these diagrams also help the operator discover unknown new patterns.

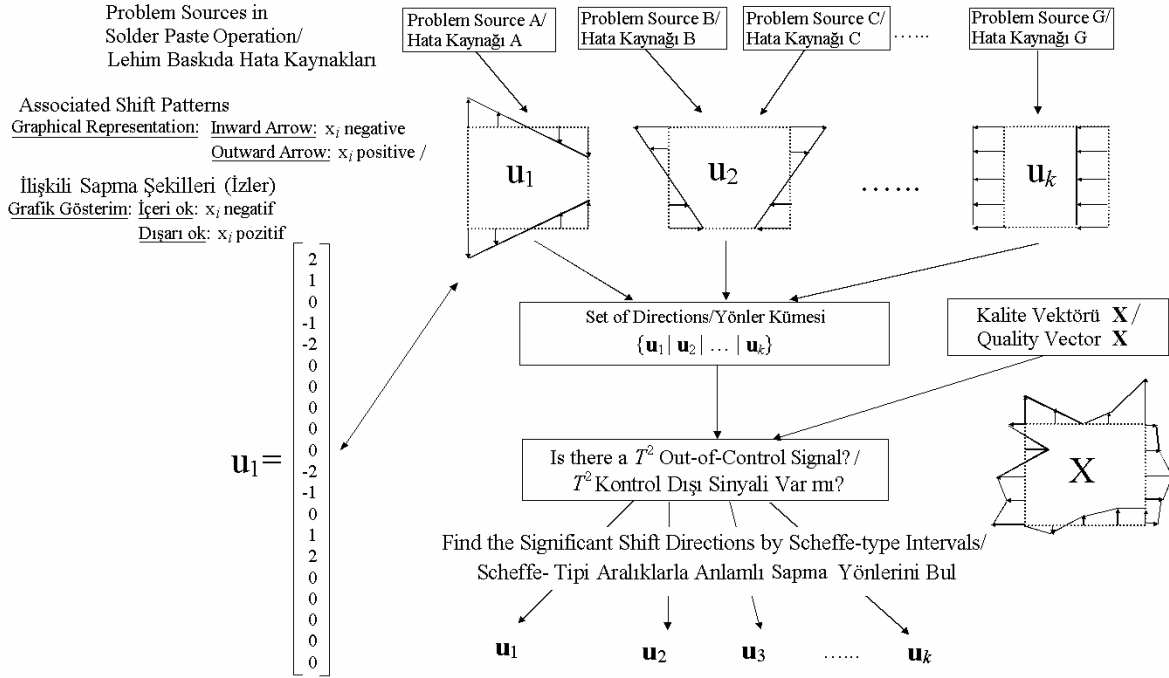


Figure 4. Detection of patterns contributing to a  $T^2$  signal by Scheffe-type intervals in Solder Paste Printing Operation  
Şekil 4. Lehim baskı sürecinde  $T^2$  sinyalinde etkili izlerin Scheffe-tipi aralıklarla bulunması

Özellikle değişken sayısının çok olduğu durumlarda başvurulan bir diğer yöntem temel bileşenler analizidir. Bu yöntem değişken sayısını yorumlanabilir bir miktara indirgemekte; elde edilen temel bileşenler süreç problemlerine işaret edebilmektedir (19, 23, 24, 33, 34). Öyle ki bazı süreçlerde değişken sayıları yüzlerle ifade edilebilmektedir. Örneğin bir otomobil kaportası ya da uçak kanadından üç boyutlu koordinat

Another method used in multivariate SPC when the number of variables is large is the principal component analysis. This method reduces the number of variables to a manageable number; so that the principal components can indicate process problems (19, 23, 24, 33, 34). In some processes there are hundreds of quality variables. For instance, coordinate measurement machines take hundreds of 3-dimensional coordinate measurement on an automobile



ölçüm cihazlarıyla yüzlerde koordinat ölçümü alınmaktadır. Böyle bir durumda tek tek her değişkenle ilgilenmek yerine değişkenliğe en çok etki eden 5-6 adet temel bileşeni izlemek hata kaynaklarını saptamayı kolaylaştırabilmektedir.

## 5. SONUÇ

Tek değişkenli İPK çizelgelerinin geleneksel uygulamasında anormal izler muhtemel bir hataya işaret olarak kabul edilir ve operatör ve mühendislerce hata kaynağı bulunup giderilir. Bu izlerin hangi hata kaynaklarıyla ilişkili olabileceğinin saptanması operatör ve mühendislere bırakılır, ancak bu kolay bir iş değildir. 1990 sonrası geliştirilen yapay sinir ağına dayalı yöntemler, tek değişkenli çizelgelerde izleri daha etkin şekilde ve otomatik olarak saptamayı amaçlamaktadır.

Diğer taraftan, bir parçadan alınan çok değişkenli gözlemler, çok daha zengin içerikli iz türlerini saptayabilme olanağı vermektedir. Çünkü, farklı hata kaynakları bir parçadan alınan gözlemlerde farklı izler oluşturmaktadır, bu imkan tek bir değişken için söz konusu değildir. Bu izler gerek grafik yöntemlerle, gerek regresyon ve temel bileşenler analiziyle, gerekse Hotelling  $T^2$  çizelgelerine ek olarak geliştirilen yöntemlerle saptanmaya çalışılmaktadır. Ancak bu çalışmalar ve sanayii uygulamaları, tek değişkenli çizelgelerdeki aksine olgunluk kazanmamıştır ve hata teşhisine yönelik pek çok fırsatı barındırmaktadır. 1990 sonrasında yapılan çalışmalar bu konuda umut vermektedir.

## KAYNAKLAR/REFERENCES

1. Montgomery, D. C., *Introduction to Statistical Quality Control 4<sup>th</sup> ed.*, Wiley & Sons, New York (2001).
2. Pearson, R. K., "Exploring process data", *Journal of Process Control*, 11: 179-194 (2001).
3. Western Electric, "Statistical Quality Control Handbook", *Western Electric Corporation*, Indianapolis, IN (1956).
4. Hoyer, R. W., Ellis, W. C., "A graphical exploration of SPC", *Quality Progress*, 5: 65-73 (1996).
5. Seder, L. A., "Golden oldies from industrial engineering- diagnosis with diagrams", *Quality Engineering*, 2: 503-530 (1990).
6. Barton, R. R., Gonzalez-Barreto, D. R., "Process oriented basis representations for multivariate process diagnostics", *Quality Engineering*, 9: 107-118 (1996).
7. Zaciewski, R. D., Nemeth, L., "The multi-vari chart: an underutilized quality tool", *Quality Progress*, 81-83 (October 1995).
8. Zorriassatine, F., Tannock, J. D. T., "A review of neural networks for statistical process control", *Journal of Intelligent Manufacturing*, 9: 209-224 (1998).
9. Pugh, G. A. "A comparison of neural networks to SPC charts", *Computers & Industrial Engineering*, 21: 253-255 (1991).
10. Smith, A. E., "X-bar and R control chart interpretation using neural computing", *International Journal of Production Research*, 32: 309-320 (1994).

body or on an airplane wing. In such cases, monitoring 5-6 principal components, instead of monitoring all variable one by one, considerably facilitates detecting problem sources.

## 5. CONCLUSIONS

In conventional applications of univariate SPC charts, abnormal patterns are considered to be an indication of a problem, and the source of the problem is detected and eliminated by the operator or the engineer. Determination of the particular problem source associated with the observed pattern is left to the operator or the engineer, but it is not a easy task. Methods based on artificial neural networks, developed after the 1990s, aim to detect the patterns on univariate SPC charts automatically and more effectively.

On the other hand, multivariate observations taken from a part give the opportunity for identifying pattern types with much richer information about problem sources. Because, different problems sources produce different patterns on observations taken from a single part, which is not possible with a single variable. So far, methods developed for detecting such patterns include graphic methods, regression and principal component analyses, used in conjunction with the  $T^2$  charts. However, neither these methods nor their industrial applications have matured yet, as compared to univariate charts; therefore, their application provides many opportunities for problem diagnosis. Recent studies after 1990 raise hopes in this direction.

11. Pham, D. T., Öztemel, E., "Control chart pattern recognition using neural networks", *Journal of Systems Engineering*, 2: 256-262 (1992).
12. Pham, D. T., Öztemel, E., "Control chart pattern recognition using learning vector quantization network", *International Journal of Production Research*, 32: 721-729 (1994).
13. Guh, R. S., Hsieh, Y. C., "A neural network based model for abnormal pattern recognition of control charts", *Computers & Industrial Engineering*, 36: 97-108 (1999).
14. Cheng, C. S., "A neural network approach for the analysis of control chart patterns", *International Journal of Production Research*, 35: 667-697 (1997).
15. Zorriassatine, F., Tannock, J.D.T., O'Brien, C., "Using novelty detection to identify abnormalities caused by mean shifts in bivariate processes" *Computers & Industrial Engineering*, 44: 385-408 (2003).
16. Hotelling, H., *Multivariate quality control, illustrated by the air testing of sample bombsights*, in: Techniques of Statistical Analysis, ed. C. Eisenhart, M. W. Hastay and W. A. Wallis, **Mc-Graw Hill**, New York (1947).
17. Birgören, B., "Multivariate statistical process control for quality diagnostics and applications to process oriented basis representations", Ph.D. Thesis, *The Pennsylvania State University*, State College, PA (1998).
18. Espada-Colon, H. I., Gonzalez-Barreto, D. R. "Component registration diagnosis for printed circuit boards using process-oriented basis elements", *Computers & Industrial Engineering*, 33: 389-392 (1997).
19. Singh, R., Gilbreath, G. "A real-time information system for multivariate statistical process control", *International Journal of Production Economics*, 75: 161-172 (2002).
20. Gong, L., Jwo, W., Tang, K., "Using on-line sensors in statistical process control", *Management Science*, 43: 1017-1028 (1997).
21. Mason, R. L., Young, J. C., "Multivariate statistical process control with industrial applications", *ASA-SIAM*, Philadelphia, PA (2001).
22. Bakır, M. A., Karaca, S., "Çok değişkenli kalite kontrol yaklaşımlarının bir değerlendirmesi", *İstatistik Araştırma Dergisi*, 1: 67-85 (2002).
23. Stoumbos, Z. G., Reynolds, M. R. Jr., Ryan, T. P., Woodall, W. H., "The state of statistical process control as we proceed into the 21<sup>st</sup> century", *Journal of the American Statistical Association*, 95: 992-998 (2000).
24. Fuchs, C., Kenett, R. S., *Multivariate Quality Control: Theory and Applications*, **Marcel Dekker**, New York (1998).
25. Murphy, B. J., "Selecting out of control variables with the  $T^2$  multivariate quality control procedures", *The Statistician*, 36: 571-583 (1987).
26. Doganaksoy, N., Faltin, F. W., Tucker, W. T., "Identification of out-of-control quality characteristics in a multivariate manufacturing environment", *Communication in Statistics - Theory and Methods*, 20: 2775-2790 (1991).
27. Mason, R. L., Tracy, N. D., Young, J. C., "Decomposition of  $T^2$  for multivariate control chart interpretation", *Journal of Quality Technology*, 27: 99-108 (1995).
28. Nedumaran, G., Pignatiello, J. J., "Diagnosing signals from  $T^2$  and  $\chi^2$  multivariate control charts", *Quality Engineering*, 10: 657-667 (1998).
29. Birgören, B., "Çok boyutlu kalite kontrolde  $T^2$  sinyallerinin Scheffe tipi aralıklarla yorumlanması", *İstatistik Sempozyumu 2000 Bildiriler Kitabı*, 347-358 (2000).
30. Maravelakis, P. E., Bersimis, S., Panaretos, J., S. Psarakis, "Identifying the out of control variable in multivariate control", *Communications in Statistics-Theory and Methods*, 31: 2391-2408 (2002).
31. Apley, D. W., Lee, H. Y., "Identifying Spatial Variation Patterns in Multivariate Manufacturing Processes: A Blind Separation Approach", *Technometrics*, 45: 220-234 (2003).

32. Mason, R. L., Chou, Y., Sullivan, J. H. Stoumbos, Z. G., Young, J. C., "Systematic patterns in  $T^2$  charts", *Journal of Quality Technology*, 35: 47-58 (2003).
33. Runger, G. C., Alt, F. B., Montgomery, D. C., "Controlling multiple stream processes with principle components", *International Journal of Production Research*, 34: 2991-2999 (1996).
34. Kano, M., Hasebe, S., Hashimoto, I., Ohno, H., "A new multivariate statistical process monitoring method using principal component analysis", *Computers and Chemical Engineering*, 25: 1103-1113 (2001).

*Received/ Geliş Tarihi: 22.01.2004    Accepted/Kabul Tarihi: 14.06.2004*