

**ÇEŞİTLİLİĞİN YÜKSEK OLDUĞU ÜRETİM
ORTAMLARINDA İTERATİF MODEL DÜZELTMELERİ
İLE İŞ EMRİ STANDART ÜRETİM SÜRELERİNİN
TAHMİNİ**

**PREDICTION OF WORK ORDER STANDARD
PRODUCTION TIMES WITH ITERATIVE MODEL
CORRECTIONS FOR HIGH VARIATY PRODUCTION
ENVIRONMENTS**

ÖZGE YEŞİLYURT

Prof. Dr. MURAT CANER TESTİK

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Endüstri Mühendisliği Anabilim Dalı için Öngördüğü

YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

ÖZET

ÇEŞİTLİLİĞİN YÜKSEK OLDUĞU ÜRETİM ORTAMLARINDA İTERATİF MODEL DÜZELTMELERİ İLE İŞ EMRİ STANDART ÜRETİM SÜRELERİNİN TAHMİNİ

Özge YEŞİLYURT

Yüksek Lisans, Endüstri Mühendisliği Bölümü

Tez Danışmanı: Prof. Dr. Murat Caner TESTİK

Mayıs 2023, 103 sayfa

Bir üretim iş istasyonunda kapasite ve verimlilik analizi yapmak ve kabul edilen normalin dışındaki durumları tespit etmek için öncelikle standart üretim yöntemlerinin ve standart üretim süresinin tanımlanmış olması gerekir. Bu çalışmada havacılık sektörü için üretim yapan, standart üretim süresi belirlemenin zor olduğu, yaklaşık 80 farklı proje için çok çeşitli parçaları işleyen ve parça grubu sürekli değişen bir iş istasyonu ele alınmıştır. Çalışma kapsamında iş emri üretim sürelerinin tahmini için bir yöntem geliştirilmiştir. Önerilen yaklaşımda çalışma yapılacak iş istasyonunun seçim kriteri ve çalışma öncesinde yapılacak mevcut durum analizi açıklanmış, zaman etüdü ile üretim süresi tahmininin modellenmesi ele alınmıştır. Zaman etüdü kapsamındaki gözlemler video kayıt yöntemi kullanılarak toplanmıştır. Gözlemler analiz edilerek, belirlenmiş olan standart üretim aktiviteleri için süreler elde edilmiştir. İş emri standart üretim süresi tahmini için toplamsal bir model oluşturulmuş, model parametrelerinin tahmininde gözlemlerden elde edilen standart süreler ile birlikte üretimi yapılan parçanın çeşitli özelliklerine göre değişkenlik gösteren sürelerin tahmin edilmesi için iki farklı istatistiksel yöntem kullanılmıştır. Bu yöntemlerde kullanılan parça özellikleri bilgisi işletmenin veritabanından elde edilerek analiz öncesinde veri ön işlemeye tabi tutulmuştur. Bu

kapsamda, “Çok Değişkenli Doğrusal Regresyon Yöntemi” ve “CART Yöntemi” karşılaştırmalı olarak denenmiş ve sonuçlar paylaşılmıştır. İş emri standart üretim süresi tahmin modeli kullanılarak elde edilen tahmin süreleri ile üretim gerçekleştirmeleri arasındaki farkın (artıklar) izlenmesi ve tahmin performansının iyileştirilmesi için “Düzeltilmiş Shewhart Kontrol Grafiği” kullanılmıştır. Bu yaklaşım, grafik parametrelerinin bilinmediği ancak tahmin edildiği durumlar için uygundur. İzleme için yapılan analizler “R Studio” yazılımındaki “spcadjust” kütüphanesi kullanılarak gerçekleştirilmiş olup örnek izleme grafikleri verilmiştir. Kurulan başlangıç tahmin modelinin performansının düzeltilmiş kontrol limitleri kullanılarak izlenmesi ile karşılaşılan sinyaller incelenmiştir. Parça çeşitliliğinin çok olması dolayısıyla tüm parçalara ilişkin gözlem yoktur ancak sinyal incelemelerinde modelde yeterince temsil edilmediği ve yüksek tahmin hatasına yol açtığı değerlendirilen parçalara ilişkin gözlemler alınarak yeni bir tahmin modeli kurulmuştur. Bu aşamadan sonra gelecek üretim gerçekleştirmeleri başlangıç modeli ve kurulan yeni model ile karşılaştırılarak sonuçlar yorumlanmıştır. Yaklaşımda önerilen iteratif modelleme ile, model ve kontrol limitleri güncellenerek tahmin performansının artırılması amaçlanmış ve örnek bir uygulama ile sonuçlar verilmiştir. Parça çeşitliliğinin çok olduğu üretim çevrelerinde gerektiğinde modelin yeni gözlemlerle güncellenmesi sağlanarak iş etüdü çalışmalarında zaman ve maliyet kazanımı sağlanmıştır.

Anahtar Kelimeler: Metot Etüdü, Zaman Etüdü, Veri Ön İşleme, Çok Değişkenli Doğrusal Regresyon, CART, Tahmin Modeli, Performans İzleme, Düzeltilmiş Shewhart Kontrol Grafiği.

ABSTRACT

PREDICTION OF WORK ORDER STANDARD PRODUCTION TIMES WITH ITERATIVE MODEL CORRECTIONS FOR HIGH VARIATY PRODUCTION ENVIRONMENTS

Özge YEŞİLYURT

Master of Science, Department of Industrial Engineering

Supervisor: Prof. Dr. Murat Caner TESTİK

May 2023, 103 pages

In order to analyze the capacity and efficiency in a production workstation and to detect the accepted abnormal situations, first of all, standard production methods and standard production time must be defined. In this study, a workstation that manufactures for the aviation industry, where it is difficult to determine a standard production time, that processes a wide variety of parts for about 80 different projects and whose part group is constantly changing, is discussed. Within the scope of the study, a method has been developed for the prediction of work order production times. In the proposed approach, the selection criterion of the workstation to be studied and the current situation analysis to be made before the study are explained, and the modeling of the production time prediction with time study is discussed. Observations within the scope of time study are collected using video recording method. By analyzing the observations, the times for the determined standard production activities are obtained. Work order production time prediction model is created and explained. An additive model was created for the prediction of the work order standard production time, and two different statistical methods are used to predict the standard times obtained from the observations in the

prediction of the model parameters and the times that vary according to the various characteristics of the manufactured part. The part properties information used in the statistical analysis methods are obtained from the tables in the database of the enterprise and the data is pre-processed before the analysis. In this context, "Multivariate Linear Regression Method" and "CART Method" are tested comparatively and the results are shared. The "Adjusted Shewhart Control Chart" is used to monitor the difference (residues) between the prediction times obtained using the work order standard production time prediction model and the production realizations and to improve prediction performance. Analyzes for monitoring are performed using the "spcadjust" library in "R Studio" software, and sample tracking graphics are given. The signals encountered by monitoring the performance of the established initial forecasting model using the adjusted control limits are examined. Due to the large diversity of parts, there are no observations on all parts, but a new prediction model is established by taking observations of parts that are not adequately represented in the model and caused high estimation error in signal examinations. After this stage, the future production realizations are compared with the initial model and the new model established, and the results are interpreted. With the iterative modeling proposed in the approach, it is aimed to increase the prediction performance by updating the model and control limits and the results are given with a sample application. Time and cost savings are achieved in work studies by updating the model with new observations as needed in production environments with a wide variety of parts.

Keywords: Method Study, Time Study, Data Preprocessing, Multivariate Linear Regression, CART, Prediction Model, Performance Monitoring, Adjusted Shewhart Control Chart.

TEŐEKKÜR

Sadece bu alıőmamda deęil, her konudaki ynlendirmeleri, fikirleri, sabrı ve hibir zaman esirgemedięi desteęi iin saygıdeęer hocam Sayın Prof. Dr. Murat Caner TESTİK'e,

Lisansst eęitim srecimde emeęi geen Hacettepe niversitesi Endstri Mhendislięi Blm'ndeki tm hocalarıma,

Grev yaptığım Trk Havacılık Uzay Sanayi'nde, hoőęr ve destekleri ile yanımda olan baőtta Sayın İbrahim Anda OTUK olmak zere tm yneticilerime ve deęerli alıőtma arkadaşlarıma,

Bana olan inanları ve beni yreklendirmeleri ile her zaman destekim olan tm aileme,

Mutluluęumda da, hznmde de hep yanımda olan, sre boyunca desteklerini esirgemeyen sevgili dostlarıma gsterdikleri anlayıőt iin

Sonsuz teőtakkrler...

İÇİNDEKİLER

ÖZET	i
ABSTRACT.....	iii
TEŞEKKÜR.....	v
İÇİNDEKİLER	vi
ŞEKİLLER DİZİNİ	viii
SİMGELER VE KISALTMALAR	x
1. GİRİŞ	12
1.1. Problem Tanımı	13
1.2. Motivasyon	14
1.3. Tezin Organizasyonu	15
2. LİTERATÜR ÖZETİ.....	16
2.1. İş Etüdü	16
2.1.1. Metot Etüdü	16
2.1.2. Zaman Etüdü.....	17
2.1.2.1 Doğrudan Gözlem ile Zaman Etüdü	19
2.1.2.2 Önceden Belirlenmiş Hareket Zamanı Sistemleri (PMTS)	23
3. METODOLOJİ	26
3.1. İteratif Model Düzeltmeleri İle İş Emri Standart Üretim Süresi Tahmini	26
3.2. Veri Tabanlarında Bilgi Keşfi.....	33
3.3 Veri Ön İşleme.....	35
3.4. Veri Madenciliğinde Makine Öğrenmesi Algoritmaları – Denetimli Öğrenme..	37
3.5 Çok Değişkenli Doğrusal Regresyon.....	39
3.6 Karar Ağacı ve CART Algoritması	44
3.7 İstatistiksel Süreç Kontrol Grafikleri ve Shewhart Kontrol Grafiği	48
3.7.1 Model Tahmin Hatalarının Kontrol Grafiklerinin Performansına Etkisi.....	51
4. ANALİZ.....	52
4.1 Çalışma Yapılacak İş İstasyonunun Belirlenmesi	52

4.2 Belirlenen İş İstasyonunun Mevcut Durum Analizi	52
4.3 İş İstasyonundaki Standart Üretim Aktivitelerinin Tanımlanması	53
4.4 İş İstasyonunda Gözlem Yapılması	54
4.5 Gözlemlerin Analiz Edilmesi ve Aktivite Sürelerinin Çıkarılması	54
4.6 İş Emri Standart Üretim Süresi Modelinin Tanımlanması	54
4.7 İş Emri Standart Üretim Süresi Model Parametrelerinin Tahmin Edilmesi	57
4.7.1 Parça Yüzey Çapak Alma Süresinin Tahmini için Çok Değişkenli Doğrusal Regresyon ve CART Yöntemleri	58
4.8 İş Emri Standart Üretim Süresinin Hesaplanması	66
4.9 Tahmin Hatalarının İzlenmesi İçin Düzeltilmiş Shewhart Kontrol Grafiği ve İteratif Model Düzeltmesi	66
5. SONUÇLAR VE GELECEK ÇALIŞMALAR	74
6. KAYNAKLAR	78
EKLER.....	82
EK 1 - Örnek Timer Pro Professional Analizi ve Excel Çıktısı	82
EK 2 - Sabit Parametreler Tahmini İçin Analizler	83
EK 3 - CART Analizi İçin Ayarlar	85
EK 4 - CART En İyi Alternatif Karar Ağacı Uç Düğüm Kuralları	88
EK 5 - 1-55 Arası Gözlemler İçin R Studio Yazılımında Kullanılan “Script” ve “Console” Bilgileri.....	97
EK 6 - 56-103 Arası Gözlemler İçin R Studio Yazılımında Kullanılan “Script” ve “Console” Bilgileri.....	99
EK 7 - 104-130 Arası Gözlemler İçin R Studio Yazılımında Kullanılan “Script” ve “Console” Bilgileri.....	100
EK 8 - Tez Çalışması Orjinallik Raporu.....	Error! Bookmark not defined.
ÖZGEÇMİŞ	103

ŞEKİLLER DİZİNİ

Şekil 2.1 İş Etüdü.....	16
Şekil 2.2 Timer Pro Professional Video Analiz Yazılımı Ara Yüzü	23
Şekil 2.3 Yaygın Olarak Kullanılan 5 MTM Temel Hareketi (Riedel, Brehm, & Pfeifroth, 2022)	24
Şekil 2.4 MODAPTS Eklem Bölgeleri (Assef, Scarpin, & Steiner, 2018)	24
Şekil 3.1 İteratif Model Düzeltmeleri İle İş Emri Standart Üretim Süresi Tahmin Prosedürü Akışı.....	26
Şekil 3.2 KDD Süreci	34
Şekil 3.3 Veri Azaltma Stratejileri (Garcia, Luengo, & Herrera, 2015).....	37
Şekil 3.4 Veri Madenciliği Modelleri	38
Şekil 3.5 Denetimli Makine Öğrenimi Süreci	39
Şekil 3.6 Örnek x ve y Değişkenleri İçin Saçılım Grafiği	40
Şekil 3.7 Örnek x ve y Değişkenleri Arasındaki Doğrusal İlişki	40
Şekil 3.8 İkili Hedef Değişken Y İçin Örnek Karar Ağacı.....	44
Şekil 3.9 Tipik Bir Kontrol Grafiği Örneği	49
Şekil 4.1 CART Metodu Uç Dğümler ve R-sq Değerlerine Göre Alternatif Karar Ağaçları.....	60
Şekil 4.2 En Yüksek R-sq Değerine Sahip 9 Dğümden Oluşan Karar Ağacı	61
Şekil 4.3 CART Model Özeti ve Değişkenlerin Göreceli Önem Yüzdeleri.....	62
Şekil 4.4 Çok Değişkenli Doğrusal Regresyon Yöntemi ile Parça Yüzey Çapak Alma Süresi Tahmin Modeli	63
Şekil 4.5 Çok Değişkenli Doğrusal Regresyon Yöntemi Modeli Artıklar Grafikleri	64
Şekil 4.6 İlk 55 İş Emri İçin Artıklar Grafiği (Tahmin-Gerçekleşme Süresi)	67
Şekil 4.7 İlk 55 İş Emri İçin Shewhart Kontrol Grafiği.....	68
Şekil 4.8 56-103 Arası İş Emirleri İçin Artıklar Grafiği.....	69
Şekil 4.9 56-103 Arası İş Emirleri İçin Shewhart Kontrol Grafiği.....	69
Şekil 4.10 Güncellenen Parça Yüzey Çapak Alma Süresi Tahmin Formülü Minitab Çıktısı	70
Şekil 4.11 104-130 Arası İş Emirleri Model 1 İçin Artıklar Grafiği	71
Şekil 4.12 104-130 Arası İş Emirleri İçin Model 1 Shewhart Kontrol Grafiği	72

Şekil 4.13 104-130 Arası İş Emirleri Güncellenen Model İçin Artıklar Grafiği.....	72
Şekil 4.14 104-130 Arası İş Emirleri Güncellenen Model İçin Shewhart Kontrol Grafiği	73



SİMGELER VE KISALTMALAR

Simgeler

$\hat{y}_i(p)$	İş emri üretim süresi tahmini
\hat{s}_i	İş emri hazırlık süresi tahmini
$\hat{\beta}_i(p)$	İş emri çalışma süresi tahmini
\hat{r}_1	Raspa ile delik çapak alma süresi tahmini
\hat{r}_2	Drill motor ile delik çapak alma süresi tahmini
x_i	İş emrindeki toplam parça adedi
t_i	İş emrindeki çalışma temposu katsayısı
z_j	İş istasyonu için ek pay katsayısı
\hat{a}_k	Hazırlık aktivitesi süresi tahmini
$\hat{b}_l(p)$	Çalışma aktivitesi süresi tahmini
e_i	Artık
S_t	Kontrol altındaki sürece ilişkin izlenecek karakteristik
w	Kalite özelliği
μ_w	Kalite özelliğinin ortalaması
σ_w	Kalite özelliğinin standart sapması
L	Merkez çizgisinden olan uzaklık
g_i	Raspa ile çapak alınması gereken delik sayısı
h_i	Drill motor ile çapak alınması gereken delik sayısı
$\theta_i(p)$	Parça alanı
$\gamma_i(p)$	Parça boyutsal kodu

Kısaltmalar

AID	Otomatik Etkileşim Tespiti
ARL	Ortalama Tespit Uzunluğu
CART	Sınıflandırma ve Regresyon Ağacı
CHAID	Otomatik Ki-Kare Etkileşim Belirleme
KDD	Veritabanlarında Bilgi Keşfi
KNN	K-En Yakın Komşular
LCL	Alt Kontrol Limiti
MARS	Çok Değişkenli Uyumlu Regresyon Uzanımları
MODAPTS	Önceden Belirlenmiş Zaman Standardının Modüler Düzenlemesi
MOST	Maynard Operasyon Sıralama Tekniği
MTM	Metot Zaman Ölçümü
MTM-UAS	Metot Zaman Ölçümü – Evrensel Analiz Sistemi
PMTS	Önceden Belirlenmiş Hareket Zamanı Sistemleri
QUEST	Hızlı, Yansız, Etkin İstatistiksel Ağaç
SLIQ	Araştırmada Denetimli Öğrenme
SPC	İstatistiksel Süreç Kontrolü
SPRINT	Ölçeklenebilir, Parellenebilir Tümevarım Karar Ağacı
SQL	Yapısal Sorgulama Dili
SVM	Destek Vektör Makinesi
UCL	Üst Kontrol Limiti

1. GİRİŞ

Üretilen ürünün ne olduğundan bağımsız olarak, üretim sürecinin takip edilebilmesi için yapılan işlerin standart iş talimatları ile hayata geçiriliyor olması önem taşımaktadır. Emek yoğun işletmelerde, çalışan personelin yetkinliklerinin ne olacağı, bu yetkinlikler ile işin hangi yöntemler kullanılarak nasıl gerçekleştirileceği iş talimatları ile ortaya koyulmaktadır. Bir iş istasyonundan başlanarak tüm üretim hattının iş akışının tanımlanması ile müşteriye ulaşan son ürünün değer akış haritası oluşturulur ve bu yol üzerinde dar boğaz yaratan iş istasyonları ile değer yaratmayan faaliyetler ortaya çıkarılarak gelişmeye açık alanlar belirlenir. Bir işletmenin bugünkü rekabet ortamında mücadele edebilmesi için birincil ihtiyacı, mevcut durumun gerçekçi bir şekilde ortaya koyulmasıdır. Bunun için de üretim alanından ihtiyaç duyulan verilerin doğru yöntemler ile ölçülmesi ve sonuçların değerlendirilerek işletmenin verimliliğini artırıcı aksiyonlar alınması oldukça önemlidir.

Üretim alanlarının verimliliği ele alındığında bir çok farklı açıdan değerlendirme yapılır. Üretim sürecinin gerçekleştirildiği alanın verimli kullanılmasından, üretim kaynaklarının israf edilmemesine, üretilen ürünün ilk defada istenilen kalitede olmasından, kaliteli ürün üretilirken iş gücünün verimli kullanılmasına kadar birçok boyut vardır. Bu boyutlardan biri olan parçanın standart üretim süresi içerisinde üretilmesi ise tüm üretim sürecinin temel yapı taşı olarak göze çarpmaktadır. Bu sebeple öncelikli olarak üretilen parçanın standart üretim süresinin hesaplanması gerekir. Standart üretim süresi belirlenmeyen bir iş istasyonu için verimlilik hesabı yapmak, mevcut kapasiteyi doğru bir şekilde ortaya koymak, dar boğazları doğru belirlemek ve sonunda tüm bu iş istasyonlarının birleşmesi ile ortaya çıkan üretim hattını izlemek mümkün olmayacaktır.

Geçmişten günümüze özellikle seri üretim ile önemi iyice ortaya çıkan üretim sürecinin standartlaştırılması ve üretim sürelerinin belirlenmesi konusu ile ilgili birçok yöntem ortaya koyulmuş ve uygulanmıştır. Bu yöntemlerin her birinin avantajları ve dezavantajları bulunmaktadır. Bu nedenle işletmeler hangi yöntemler ile standart zaman belirlemeleri gerektiğine dikkatle karar vermeli ve kullanıma aldıkları yöntemlerin sürdürülebilirliğini garanti altına almalıdır. Tez kapsamında bu yöntemlerden bahsedilerek örnek bir iş istasyonu için üretim süreleri tahmin modelleri çalışılmıştır. En iyi sonucu veren tahmin modeli kullanılarak, tahmin modelinin performansının

izlenmesini ve sürekli iyileştirme prensibine uygun olarak zaman içerisinde modelin geliştirilebilmesini sağlayan bir metodoloji ortaya koyulmuştur.

1.1. Problem Tanımı

Parça üretim süresi belirlemenin işletmelere maliyeti vardır ve üretim yöntemlerine göre bu maliyetler değişmektedir. Seri üretim yapan bir işletmede faaliyetler ardı ardına tekrarlı bir şekilde yürütüldüğünden ve parça çeşitliliği görece dar olduğundan iş istasyonunda üretim sürecini gözlemek ve doğru sonuçlara ulaşılmasını sağlayacak büyüklükte veri toplamak nispeten kolay olacaktır.

Havacılık sektöründe birçok farklı proje için yapısal parça üretimi yapan bir işletme göz önüne alındığında ise üretim sürecini birebir gözlemek ve ihtiyaç olan büyüklükte veri toplamak oldukça maliyetlidir. Ele alınan problemde yaklaşık 80 farklı projeye yapısal parça üretimi gerçekleştirilmektedir. Bu parçalar farklı tiplerde uçak, helikopter ve insansız hava araçlarına ait parçalar olup parça çeşitliliği oldukça fazladır. İhtiyaç olan parçalar zaman içerisinde projelere göre değişkenlik göstererek boyut, malzeme tipi, geometrik yapı gibi bir çok etkenle birbirinden ayrılmaktadır. Montaj hatlarında kullanılacak parçalar montajın ilk adımı olarak öncelikle ortak bir iş istasyonuna gitmekte ve burada parçaların yüzey işlemleri gerçekleştirilerek montaja hazır hale getirilmektedir.

Çalışmaya konu olan iş istasyonu için mevcut durum analizine göre gelecek bir yıllık ihtiyaç için yaklaşık 4000 farklı parçanın (İhtiyaç miktarları sürekli olarak güncellendiğinden ihtiyaç miktarı yaklaşık olarak verilmiştir.) işleme alınması gerekmektedir. Atölye tipi yerleşime sahip istasyondaki tüm işler teknisyenler tarafından çeşitli el aletleri yardımı ile gerçekleştirilmektedir. Dolayısı ile tezin konusu olan iş istasyonu parça çeşitliliğinin fazla olduğu ve emek yoğun bir iş istasyonudur. İş istasyonuna çalışılması için gelen parçalar, sistemde tanımlı eşsiz bir atölye numarası ile takip edilir. Örneğin, 50 adet A parçası, “12345” numaralı iş emri ile takip edilir. Bir iş emrinde sadece tek tip parça çalışılabilir (Örneğin, sadece A parçası veya sadece B parçası içerebilir, hem A hem de B parçalarını aynı anda içeremez.) ve iş emirleri farklı parça miktarları içerecek şekilde olabilir. (Örneğin, 12345 numaralı iş emrinde 10 adet A parçası varken, 12346 numaralı iş emrinde 5 adet A parçası yer alabilir.) Üretim planlama, parça üretimini bu iş emirleri üzerinden takip etmektedir. Mevcut durumda iş emirlerinin üretim süresi, geçmişteki üretim tamamlanma sürelerinden veya ilk defa üretiliyor ise istasyonda bir parça için ortalama harcanan süreye göre verilmektedir. Bu

durumda çalışan personelin sisteme manuel olarak tanımladığı iş emrine başlama ve iş emirini bitirme süreleri kullanılmakta ve tüm değer yaratmayan işler bu süre içerisinde kaldığından üretim alanının verimliliği ve kapasitesi doğru bir şekilde hesaplanamamaktadır.

Parça çeşitliliğinin oldukça yüksek olduğu ve her geçen gün yeni parça ihtiyacının tanımlandığı bu iş istasyonu için minimum maliyet ve maksimum doğruluk ile iş emri standart üretim sürelerinin tahmin edilmesine ve tahmin performansının izlenerek sürekli olarak geliştirilmesine olanak sağlayan sürdürülebilir bir süre tahmin algoritması kurulması ihtiyacı mevcuttur.

1.2. Motivasyon

Yukarıdaki problem tanımı bölümünde verilen bilgiler ışığında söz konusu iş istasyonundan geçen iş emirlerinin standart üretim süresinin tahmin edilmesi ve sürdürülebilirliğinin sağlanması oldukça zorlu bir süreçtir. Parça çeşitliliğinin çok olması ve her yeni bir parça için gözlem ihtiyacının yinelenmesi gereği, birebir iş emri gözlemi alınması seçeneğini ortadan kaldırmakta ve farklı yöntemler ile iş emri sürelerinin tahmin edilmesi ihtiyacını doğurmaktadır.

Çalışma kapsamında, önce üretim süresi tahmini için kullanılan geleneksel yöntemler açıklanmış ve bu yöntemlere ek olarak istatistiksel yöntemlerden faydalanılarak yenilikçi bir yaklaşım ortaya konmuştur. Düşük maliyet ile yüksek doğruluğa sahip üretim süreleri hesaplamak için kullanılacak iki ayrı istatistiksel analiz yöntemi örnek iş istasyonu üzerinde denenerek sonuçlar paylaşılmıştır. En uygun tahmin modeli seçilerek model performansının takip edilmesini ve zaman içerisinde modelin geliştirilmesini sağlayacak iteratif bir izleme yöntemi önerilmiştir.

Mevcut işleyişteki geçmiş üretim süresine dayanan her türlü çalışmanın daha doğru üretim sürelerinin belirlenmesi ile etkileneceği göz önüne alındığından çalışmanın işletme için geniş kapsamlı bir etki yaratması kaçınılmazdır. Doğru üretim süreleri ile iş istasyonunun kapasitesi, hedefleri, üretim planlamaları, verimlilik analizleri doğru bir şekilde yapılarak israfların görünür kılınması ile geliştirmeye açık alanların ortaya çıkması sağlanacaktır. Geleneksel metotlara ek olarak üretim süresi belirleme çalışması gerçekleştirilecek bir iş istasyonu için istatistiksel analiz yöntemleri kullanılarak her türlü üretim istasyonunda takip edilebilecek bir süre tahmin algoritmasının ortaya koyulması hedeflenmiştir.

1.3. Tezin Organizasyonu

Tezin devamında, 2. bölümde iş etüdü konusunda temel bilgiler verilmiş, tez çalışmasıyla ilgili olacak literatür ele alınmıştır. 3. bölümde iş emri standart üretim süresi tahmin prosedürü önerilerek kullanılan yöntemler hakkında bilgi verilmiştir. 4. bölümde önerilen prosedürün uygulama örneği çalışılarak sonuçlar verilmiştir. Son olarak 5. bölümde yapılan çalışmalar ve elde edilen sonuçlar yorumlanmıştır.



2. LİTERATÜR ÖZETİ

2.1. İş Etüdü

İş etüdü konusu ele alındığında iki ana başlık olan “metot etüdü” ve “zaman etüdü” (iş ölçümü) ayrı ayrı değerlendirilmelidir. Metod etüdü çoğunlukla iş yapış yöntemini araştırmak ve gerekli ise geliştirmek için kullanılır. Metod etüdü, daha kısa hazırlık süresi ile birlikte üretimin tüm adımlarında daha az insan çabası gerektiren, etkili, daha düşük maliyetli, güvenli ve standartlaştırılmış yöntemler ortaya koymayı amaçlar. Daha iyi yöntem, en iyi malzemelerin ve insan gücünün optimum kullanımını içerir ki böylece iş, iyi organize edilmiş bir şekilde yapılır, bu da kaynakların verimli kullanılmasını, kalitenin artırılmasını ve maliyetlerin azaltılmasını sağlar.

Metot etüdü, sahip olunan tüm kaynakların daha verimli kullanılmasını sağlayacak sistematik bir yol olarak görülebilir. Bununla birlikte, zaman etüdü, incelemeler sonucu ortaya koyulan standartlaştırılmış yöntemlerin hayata geçirilmesinde ihtiyaç duyulan gerekli standart üretim zamanını sağlar. Metod etüdü ve zaman etüdünün yalnız araçlar ile birlikte uygulanmasıyla, herhangi bir endüstri daha az maliyetle ve daha iyi kalitede daha fazla çıktı elde edebilir ve dolayısıyla daha yüksek üretkenlik elde edebilir (Kulkarni, Kshire, & Chandratre, 2014).



Şekil 2.1 İş Etüdü

2.1.1. Metod Etüdü

Metot etüdü, tanımlı işleri yapmanın daha etkili yollarını ortaya koyarak ve yöntemleri geliştirerek görünmeyen gereksiz işlerden, önlenemez gecikmelerden ve diğer israf biçimlerinden kurtularak verimliliğin artmasına katkıda bulunur (Rathod, Jadhav, & Babar, 2016).

Kulkarni, Kshire ve Chandratre (2014) metot etüdü gerçekleştirme prosedürünü aşağıdaki şekilde tanımlamıştır:

1. İncelenecek iş seçilir.
2. İş ile ilgili tüm bilgiler kayıt edilir.
3. Kaydedilen bilgiler incelenir.
4. İş yapış yöntemi geliştirilir.
5. Standart uygulama olarak yeni yöntem belirlenir ve uygulamaya alınır.
6. Uygulamaya alınan yöntem takip edilir

İşletmeler ihtiyaçlarına göre bu temel adımları içerecek şekilde adımları çoğaltarak daha detaylı prosedürler oluşturabilir.

2.1.2. Zaman Etüdü

Zaman etüdü, bir işin tamamlanması için gerekli olan 'standart zamanın' tahmin edilmesi çalışmasıdır. Standart zaman kavramı ise, nitelikli ve iyi eğitilmiş bir operatör, normal bir hızda çalışma ve yapılacak işin tanımlı olması koşulları ile ortaya koyulabilir (Meyers & Stewart, 2002).

İngiliz Standart Enstitüsü'ne göre zaman etüdü, belirli bir görevi, ölçüme, iş içeriğine, öngörülen yöntemeye dayalı olarak, gereken izinle, belirli bir performans düzeyinde gerçekleştirmek için, yorgunluk, kişisel ve kaçınılmaz gecikmeleri de hesaba katarak gerekli olan zamanı belirleme tekniğidir. Zaman etüdü, bir görevi tamamlamak için geçen süreyi belirlemede bir zaman tutma cihazı (örneğin, ondalık dakika kronometresi, bilgisayar destekli elektronik kronometre veya video kamera) kullanarak görevin doğrudan ve sürekli olarak gözlemlenmesidir ve genellikle kısa ile uzun süreli tekrarlayan iş döngüleri olduğunda kullanılır (Starovoytova, 2017).

Standart zaman, üretim bölümünde üretilen en önemli bilgi parçalarından biridir ve aşağıdaki problemlere cevaplar geliştirebilmek için kullanılmaktadır (Meyers & Stewart, 2002):

- Satın alınacak takım ve tezgahların sayılarının belirlenmesi
- İstihdam edilecek üretim personelinin sayısının belirlenmesi
- Üretim maliyetlerinin ve satış fiyatlarının belirlenmesi

- Makinelerin, operasyonların ve işi yapacak personellerin daha az stok ile işi zamanında teslim edecek şekilde planlanması
- İş istasyonlarına doğru miktarda iş yüklenmesinin sağlanması
- İş istasyonlarının dengelenmesi (hat dengeleme)
- Bireysel çalışan performansının belirlenmesi
- Olağanüstü takım veya bireysel performansların ödüllendirilebilmesi
- Problemlerin giderilebilmesi için problem yaşanan operasyonların ortaya çıkarılması (dar boğazların çıkarılması)
- Maliyet düşürme fikirlerinin değerlendirilmesi ve en ekonomik yöntemin seçilmesinin fikirlere değil gerçek maliyet analizlerine göre yapılabilmesi
- Yeni ekipman alımlarının doğuracağı maliyetin getireceği fayda karşısında doğru değerlendirilmesi

Metot etüdü halihazırda hayata geçirilmeden zaman etüdü çalışmaları gerçekleştirilmemelidir. İş yöntemi tanımlanana ve standartlaştırılana kadar, işin içeriği ve bunu gerçekleştirmek için gereken süre değişecektir; standart zaman, belirli bir iş yapma yöntemi için geçerlidir ve iş yöntemi değişirse, oluşturulan standart zaman artık o iş için geçerli olmayacaktır (Mital, Desai, & Mital, 2017).

Ölçüm yapılan sürelerde büyük değişkenlik görülmesi şu sebeplerle gerçekleşebilir: (1) çalışanın bilerek döngü süresini artırmaya çalışması, (2) çalışanın kalifiye olmaması, (3) malzeme, alet, ekipmanda veya çalışan tarafından kullanılan yöntemde farklılıkların olması. Bu faktörler, zaman etüdüne devam etmeden önce düzeltilmelidir. Büyük değişkenliklerin nedenlerinin, tekrarlayan işler için tespit edilmesinin nispeten kolay olduğu, ancak çalışan açısından çok fazla beceri ve muhakeme gerektiren işler için kolay olmadığı akılda tutulmalıdır. Bu koşullar altında, yöntemin zamanlamadan önce kesin olarak belirlenmesi çok önemlidir. Ayrıca, zaman etüdü yapılmadan önce malzeme, ekipman ve araçlar incelenmelidir (Mital, Desai, & Mital, 2017).

Bir işin yerine getirilmesi için gerekli olan standart zamanın belirlenmesine tarihsel olarak bakıldığında üç farklı tekniğin kullanıldığı görülmektedir. Bunlar: yargıya dayalı tahmin, tarihsel kayıtlara dayalı tahmin ve mühendislik iş ölçümüne göre süre belirlenmesidir. Yargıya dayalı tahmin, kişisel deneyim (uzman görüşü) ile desteklenerek ortaya koyulur ve direkt önsezi ve tahmin, yarı nicelleştirilmiş deneyime dayalı eğitimli tahmin, ve nicel bilgi ile az çok kesin kriterlerin uzman görüşü ile tahmini şeklinde farklı

aşamalara ayrılmıştır. Tarihsel kayıtlara dayalı tahmin yönteminde üretim standartları (standart zaman), daha önce üretilmiş işlerin kayıtlarına dayanmaktadır. Çalışanın yeni bir işe başlamadan önce bir zaman sayacını veya veri toplama donanımını devreye sokması ve ardından işi tamamladıktan sonra çıkışı yapması yaygın bir uygulamadır. (Genaidy, Mital, & Obeidat, 1989)

Mühendislik iş ölçümleri temel olarak ölçüm yöntemleri ve hesaplama yöntemleri olarak ikiye ayrılabilir. Ölçme yöntemlerinin bazı sınırlamaları vardır ve kullanımları ancak mevcut üretimde mümkündür. Bu durumda, zaman doğrudan kronometrelerle, dolaylı olarak videodan veya istatistiksel olarak gözlemlenen etkinliklerin sıklığından ölçülebilir. Alman kökenli Devlet İş Zamanları Belirleme Komisyonu tarafından geliştirilen REFA'nın (Reichsausschuss Für Arbeitszeterminmittlung-Devlet İş Zamanları Belirleme) zaman etüdü tekniğinde doğrudan zaman ölçümüne yönelik somut metodolojik bir yaklaşım koyularak standart zaman etüdü çalışmalarına ek olarak, plan zamanlar ile hesaplama yöntemlerinden de faydalanılmıştır. Önceden belirlenmiş hareket zaman sistemleri (Predetermined Motion Time System - PMTS) hesaplama yöntemleri olarak kabul edilebilir. Bu yöntemlerin ana faydalarından biri, işyeri fiziksel olarak henüz mevcut değilken, üretim öncesi aşamalarda bunları kullanma olasılığıdır. Ayrıca bu yöntemler, optimizasyon ve rasyonalizasyon için bir araç olarak çok faydalıdır. (Bures & Pivodova, 2015)

2.1.2.1 Doğrudan Gözlem ile Zaman Etüdü

Zaman etüdü, 1880'de “adil günlük çalışma” tanımlamak amacıyla iş içeriğini incelemek ve ölçmek için kronometre kullanan Frederick W. Taylor tarafından geliştirilmiştir. Taylor “Zaman Etüdünün Babası” olarak adlandırılır. Çalışmaları arasında, kendi küreklerini kullanarak yaklaşık iki mil uzunluğundaki kömür, kok ve demir cevheri dağlarından malzeme taşıyan 400 ila 600 kişi üzerinde yaptığı “Taylor Kürek Deneyi” yer alır. Taylor, farklı boyutlarda kürekler olduğunu tespit etmiştir ve hangi küreğin en verimli olduğunu merak etmiştir. Kronometre kullanarak çalışanların yaptığı her aktiviteyi ölçmüştür. Her iş için çeşitli kürek boyutları, işin yapılma süreleri, mola sayısı ve çalışma saatleri gibi çeşitli verileri kaydetmiş ve ortaya koyduğu standart iş ve zamanlar ile iş süresini azaltmış, çalışan sayısından tasarruf sağlamış ve maliyetleri düşürmüştür (Patel, 2015).

Birçok şirket iş sözleşmelerinde doğrudan gözlem ile zaman etüdünü (kronometre ile zaman etüdü) müzakere etmiştir. Kronometre ile zaman etüdü, belirli bir zaman standardı belirlemek için üzerinde anlaşmaya varılan bir yöntemdir. Bu konuda 100 yılı aşkın süredir yapılan çalışmalar ile yöntemin temelleri oldukça sağlamlaştırılmıştır (Meyers & Stewart, 2002).

Uygulama detaylarında farklılıklar görülse de temel olarak bir zaman etüdü çalışması aşağıdaki adımları içerir (Starovoytova, 2017):

1. Zaman etüdü yapılacak işin seçilmesi: İş seçiminde çeşitli öncelikli nedenler olabilir. Örneğin, darboğaz veya tekrarlayan işler, daha uzun çevrim süreli işler, mevcut zamanın doğruluğunu kontrol etmek, iki farklı yöntemin karşılaştırılması, vb.
2. Çalışma yönteminin standartlaştırılması: Standart çalışma yönteminin belirlenerek uygun dokümantasyonla kayıt altına alınması ile doğruluğun mümkün olduğunca en yüksek seviyede tutulması sağlanmalıdır. Bu adım metod etüdü çalışmasını kapsamaktadır.
3. Gözlem alınacak (çalışılacak) operatörün seçilmesi: Performansı ortalama veya ortalamaya yakın olan tutarlı bir çalışanın seçilmesi gözlemlenen sürelerin de normal bir performansta olmasını sağlayacaktır. Ortalama deneyimdeki bir operatör, iş için gerekli yeteneklere sahip, iş ile ilgili her türlü belge, doküman, ekipman ve aletlerin uygun kullanımına hakim, koordineli zihinsel ve fiziksel yetenekleri belirli bir tempoda ortaya koyarak işi gerçekleştirebilen bir çalışan olarak tarif edilebilir. Sürdürülebilir bir performans ortaya koymak için iş birlikçi bir tutum sergiler.
4. İş ile ilgili bilgilerin kayıt altına alınması: Departman bilgisi, proje bilgisi, görevin/işin adı, görevin/işin detayları ve kapsamı, iş ile ilgili mevcut bilgiler, vb. hali hazırda görev/iş ile ilgili mevcut bilgilerin uygun şekilde (örneğin bir kayıt formu ile) kayıt altına alınması.
5. Görevin/işin alt öğelerine ayrıştırılması: Uzun süreli işlerin tek seferlik gözleme dayalı gözlem ve analizi mevcut performansa ve birçok değişkenliğe göre kolay etkilenebilir olacaktır. Bu sebeple işin mümkün olduğunca anlamlı alt parçalara (alt görevlere) ayrılarak gözlemlenmesi ve her bir alt görevin ayrı ayrı zamanlandırılması tercih edilir. Böylelikle gözlem faaliyeti kolaylaşır ve ölçüm daha doğru olur. Ölçülmek istenen işin bütününün alt parçalara bölünmesi işi ihtiyaçlara ve mevcut duruma göre şekillendirirken dikkat edilmesi gereken noktalar alt görevlerin

başlangıç ve bitişlerinin doğru ve net bir şekilde tanımlanarak bütünü korunmasının sağlanmasıdır.

6. Ölçülecek döngü sayısının belirlenmesi: Doğru ortalama süreye ulaşmak için gözlemlenmesi gereken döngü sayısını belirlemek ve ölçmek önemlidir. Bu sayıyı belirlemek için farklı çalışmalar ortaya koyulmuştur. İstatistiksel yöntemler kullanılarak istenen güven aralığında istenen değişkenlik seviyesine ulaşmak için hesaplamalar gerçekleştirilir.

7. Belirlenen alt görevlerin zaman ölçümünün yapılması: Bir zaman tutma aracıyla kapsamı ve sınırları belirlenen iş kayıt altına alınır ve elde edilen süreye gözlem süresi adı verilir. Zaman etüdü geleneksel olarak kronometre ile bağdaştırılmış olsa da günümüzde teknolojinin gelişmesi ile farklı ölçüm ve analiz yöntemleri geliştirilmiştir. Bu yöntemlerden ve yazılımlardan bölüm sonunda bahsedilmiştir.

8. Standart temponun belirlenmesi: İşin temposu (derecelendirilmesi), bir çalışanın verimliliğinin ölçüsüdür. Farklı işçiler işlerini farklı verimliliklerle gerçekleştirirler. Bazı işçiler işlerini çabucak öğrenirler ve çok yüksek bir verimlilik elde ederler, diğerleri ise öyle değildir. Bunun nedeni, farklı hareket hızları, çaba, el becerisi ve tutarlılıktır. Bu nedenle, bir kişinin işi yapması için geçen süre diğerlerinininkiyle aynı olmayabilir. Tempo, bir operatörün çalıştığı hızın ölçüsüdür ve standart derecelendirme olarak 100 ile ifade edilen bir ölçektir. Performans olarak da görülebilmektedir. Tempo doğası gereği öznel bir kavramdır. Genellikle, iş etüdü analisti tarafından süpervizöre danışılarak karar verilir.

9. Normal zamanın hesaplanması: Gözlemlenen süre, işi yapmak için gerekli olan gerçek süre olamaz. Bu nedenle, normal sürenin hesaplanması gerekir. Normal süre, bir işçinin normal hızda çalışırken işin aldığı süredir ve şu şekilde hesaplanır:

$$\text{Normal Süre} = \text{Gözlemlenen süre} \times \text{Tempo}$$


10. Normal süreye ek payların belirlenmesi: Bir işçi tüm vardiya boyunca veya tüm gün kesintisiz çalışamaz. Dinlenmek, tuvalete gitmek, su içmek vb. için zamana ihtiyacı olacaktır. Kullanılan aletin kırılması vb. nedenlerle kaçınılmaz ve öngörülemeyen gecikmeler olabilir. Bu nedenle normal süreye bir miktar fazladan süre eklenir (Starovoytova, 2017). Bu payların belirlenmesinde iş örnekleme tekniği yaygın bir kullanıma sahiptir. Basitçe, bir operatörü veya işlemleri rastgele zamanda gözlemlenmesi ve ardından operatörün veya işlemlerin gözlemlendiği sırada neler olup

bittiğini not etme eylemidir. Belirlenen zaman aralığında ek paylara dahil olan gözlemlerin toplam gözlemlere oranı alınarak yapılan iş içerisindeki ek payların yüzdesi belirlenen güven aralıkları içerisinde hesaplanır (Gunesoglu & Meric, 2007).

11. Standart zamanın belirlenmesi: Standart zaman, normal zaman ve payların toplamıdır ve şu şekilde hesaplanır:

$$\text{Standart Zaman} = \text{Normal Zaman} + \text{Paylar}$$

Zaman etüdü analisti, işi ölçümlemek için çeşitli araçlar kullanabilir. 1940'lı yıllarda kullanılmaya başlayan kronometreler artık günümüzde yerini farklı araçlara bırakmaya başlamıştır. Bilgisayar uygulamalarının ve video kayıt cihazlarının gelişmesi ile birlikte, gözlemin kalem kağıtla formlarda kayıt edilmesi geleneği, yerini dijital kayıtlara bırakmaya başlamıştır. Video kaydı alınan işin zaman ve hareket analizlerinin yapılabileceği uygulamalara örnek olarak Proplanner ve Timer Pro Professional verilebilir (Mital, Desai, & Mital, 2017). Timer Pro Professional (Applied Computer Services, Inc., CO, ABD) da, kaydedilen video görüntüleri kronometre için özel olarak tasarlanmış (kümülatif zamanlamalı) bilgisayar yazılımı ile analiz edilir. Bu yazılım, araştırmacının video görüntüsünü herhangi bir noktada durdurmasına, kaydı kare kare geri sarmasına ve belirli bir işlemin gerçekleştiği anı büyük hassasiyetle seçmesine ve iş parçacıklarını gerekli sınıflandırmalar ile tanımlamasına olanak tanır. Video görüntüleri, saha araştırmasını yapan yetkili zaman etüdü kişisi tarafından analiz edilir ve sonuçlar MS Excel formatında alınabilir (Szewczyk & Sowa, 2017). Timer Pro Professional yazılımı ara yüzü ekran görüntüsü Şekil 2.2'de verilmiştir.




2.1.2.2 Önceden Belirlenmiş Hareket Zamanı Sistemleri (PMTS)

Taylor'ın çalışmalarının ana uygulamalarından biri, operatörlerin üretkenliklerini artırmak için onları sınıflandırarak belirli faaliyetlerde uzmanlaştırılmalarını sağlamaktır. İlk başlarda iş ölçümü, manuel zamanlama kullanılarak, bir operatörün görevini yerine getirmesi için gereken ortalama süreyi belirlemek için kullanılmıştır (Golpîra, 2013).


Taylor'ın çalışmalarının takipçisi olan Henry Ford, 1908'de Ford T modelinin ticarileştirilmesiyle montaj hatlarının ilk kavramlarını ortaya koymuştur. Bu otomobil ile amaçlanan, maliyetleri düşürerek, yirminci yüzyılın endüstriyel prosedürlerinden daha verimli bir konfigürasyona sahip araçların üretilmesiydi (Laird & Sherratt, 2009). Taylor'ın bazı öncülleri, operatör kapasitesi tanımlaması ile çalışma sürelerini değerlendirmek için farklı yöntemler geliştirmiştir. Bu şekilde, önceden belirlenmiş zamanlar ortaya çıkmıştır. Önceden belirlenmiş zaman ve hareket sistemi (Predetermined Motion Time Systems, PMTS), temel hareketler için gerekli sürelerin listelendiği ve bir aktivite için kullanılan süreyi belirlemede kullanılan bir zaman ölçüm prosedürüdür. (Assef, Scarpin, & Steiner, 2018)

PMTS, analistin süreci bileşen eylemlerine ayırmasını, her eyleme zaman değerleri atamasını ve toplam standart zamanı hesaplamak için süreleri toplamasını gerektirir (Golpîra, 2013). Bu alanda, "Method Time Measurement" (MTM), "Maynard Operation Sequence Technic" (MOST), "Universal Analysis System" (MTM-UAS) ve "Modular Arrangement of Predetermined Time Standard" (MODAPTS) gibi PMTS metodolojilerini paylaşan çalışmalar bulunmaktadır (Assef, Scarpin, & Steiner, 2018). MTM çalışmalarında kullanılan 5 temel hareket (uzanma, kavrama, hareket ettirme, pozisyonlama, bırakma) Şekil 2.3'te verilmiştir.



Şekil 2.3 Yaygın Olarak Kullanılan 5 MTM Temel Hareketi (Riedel, Brehm, & Pfeifroth, 2022)

Assef, Scarpin ve Steiner (2018) yaptıkları çalışmada MODAPTS yöntemi ile operasyon aktivitelerini Şekil 2.4’te verilen eklem bölgeleri ile ifade etmiştir. Örneğin, 1 numaralı aktivitede operatör görsel doğrulamaya ihtiyacı olmadan manuel kavrama ve hareket ettirme işi yaparken, 2 numaralı aktivitede görsel doğrulama yaparak parçanın pozisyonlanmasını gerçekleştirmektedir.



Şekil 2.4 MODAPTS Eklem Bölgeleri (Assef, Scarpin, & Steiner, 2018)

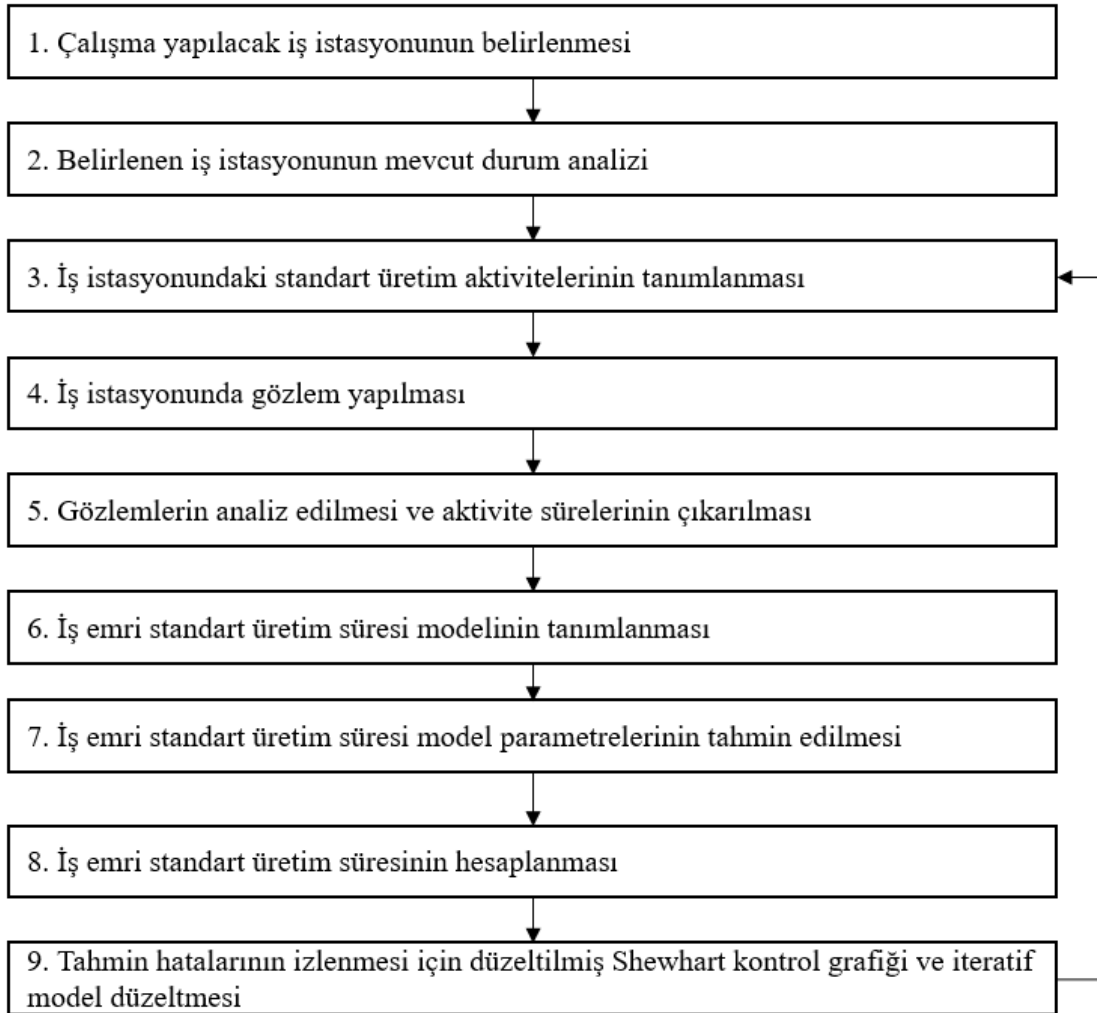
Ölçme yöntemlerinin bazı sınırlamaları vardır. Kullanımı ancak mevcut üretimde mümkündür ve zamanı doğrudan kronometrelerle, dolaylı olarak videodan veya gözlemlenen faaliyetlerin sıklığından istatistiksel olarak ölçebiliriz. Önceden belirlenmiş zaman sistemlerini hesaplama yöntemleri olarak düşünebiliriz. Bu yöntemlerin ana faydalarından biri, işyerinin henüz fiziksel olarak mevcut olmadığı üretim öncesi aşamalarda kullanılabilirlerdir. Ayrıca bu yöntemler, optimizasyon için bir araç olarak çok faydalıdır (Bures & Pivodova, 2013).



3. METODOLOJİ

3.1. İteratif Model Düzeltmeleri İle İş Emri Standart Üretim Süresi Tahmini

Yapılan literatür araştırması ışığında, bir iş istasyonunda çalışılacak iş emrinin üretim süresi tahmini ve tahmin hatalarının izlenmesi ile tahmin modelinin iteratif düzeltilmesi için önerilen prosedür Şekil 3.1’de verilmiştir. Tanımlanan prosedürün adımları bu bölümde açıklanmış ve prosedür izlenerek gerçekleştirilen örnek çalışmanın detayları Bölüm 4’te verilmiştir. Önerilen prosedür ile geleneksel zaman etüdü çalışmaları detaylandırılıp güncel uygulamalar ile zenginleştirilmiş, sürekli gelişim felsefesine uygun olarak performans takibi ile zaman içerisinde geliştirilebilen bir yöntem ortaya koyularak standart bir yapı oluşturulması amaçlanmıştır.



Şekil 3.1 İteratif Model Düzeltmeleri İle İş Emri Standart Üretim Süresi Tahmin Prosedürü Akışı

Adım 1: Çalışma yapılacak iş istasyonunun belirlenmesi

Üretim sürecindeki her bir iş istasyonu için, iş emri bazında hedeflenen üretim süreleri ile üretim planlarının hazırlanması ve gerçekleştirmelerin izlenerek geliştirme çalışmalarının hayata geçirilmesi standart bir süreçtir. İdeal durumda, kullanılan üretim süreleri mühendislik çalışmaları sonucunda hesaplanmış standart üretim süreleri olmalı ve değişen koşullar ile güncellenebilecek bir alt yapıya sahip olmalıdır. Ne yazık ki bu ideal durum hem küçük hem de büyük ölçekteki işletmeler için her zaman geçerli değildir. Standart üretim sürelerinin hesaplanmasının ve çalışmaların sürdürülebilir kılınmasının işletmelere olan maliyetlerinden dolayı üretim süresince tutulan (geçmiş verilere dayanan gerçekleştirme süreleri) zamanların kullanılması oldukça yaygın bir uygulamadır. Üretim zamanlarının mühendislik çalışmaları ile belirlenerek takip edilmesi için harekete geçen bir işletme içinse çalışmalara nereden başlanacağı ve hangi prosedürlerin takip edileceği konuları çalışma maliyetlerinin ortaya çıkmasında ve sonuçların doğruluğunda oldukça etkilidir.

Üretim yapılan sektör, işletmedeki iş istasyonlarının çalışma tipi, üretilen ürün adedi ve çeşitliliği gibi birçok konu izlenecek olan prosedürün seçiminde önemlidir. Tez çalışması kapsamında sunulan prosedür aşağıdaki özelliklere sahip iş istasyonları için oluşturulmuştur:

- İş istasyonunun atölye tipi üretim sistemine sahip olması,
- İş istasyonundaki her bir üretim hücresinde tanımlı tüm üretim aktivitelerinin gerçekleştirilerek parçaların bir sonraki iş istasyonuna sevkinin gerçekleştirilebilmesi,
- İş istasyonunun emek yoğun olması,
- İş istasyonuna gelen parça adedi ve çeşitliliğin fazla olması ve sürekli güncellenmesi,
- İş istasyonuna gelen parçaların tek seferlik, talep geldikçe veya belirli periyotlarla üretilen parçalar olabilmesi.

Adım 2: Belirlenen iş istasyonunun mevcut durum analizi

Çalışma yapılacak iş istasyonu belirlendikten sonra çalışmayı yapacak uzmanın iş istasyonu için mevcut durumun analizini yapması önemlidir. Bunun için temelde incelenecek özellikler aşağıda sıralanmıştır. Bu maddeler işletme özelinde ihtiyaca göre artırılıp azaltılabilir. Ancak çalışmanın doğru ilerlemesi ve sonuçların doğru bir şekilde

analiz edilmesi ile çıktıların/kazanımların ortaya koyulabilmesi adına bu adımın titizlikle incelenmesi ve ortaya koyulması gereklidir.

- İş istasyonunun çalışma koşulları (fiziki koşulların tanımlanması),
- İş istasyonundaki çalışma saatleri (vardiya sayısı vb.),
- İş istasyonunda mevcut koşullarda çalışan/çalışabilecek toplam personel sayısı ve yetenek matrislerinin mevcudiyetinin sorgulanması,
- İş istasyonunda bugüne kadar üretimi gerçekleştirilmiş/gerçekleştirilen proje ve parça bilgisi,
- İş istasyonunda mevcut üretim sürelerinin nasıl elde edildiği ve üretim planlarının nasıl verildiği bilgisi,
- İş istasyonunda üretilen aktif parçaların kabul alınan üretim sürelerinin temin edilmesi,
- İş istasyonunda mevcut üretim planına uyum yüzdesi,
- İş istasyonunda üretim ihtiyacı tanımlanmış olan üretilecek parça listesi,
- İş istasyonunda üretimi tamamlanan ve gelecek istasyona iletilen parçaların kalitesizlik oranları, vb.

Çalışmayı yürütecek olan uzman personelin iş istasyonunda fiziksel olarak bulunarak çalışma koşullarını, yerleşim planını incelemesi, standart üretim aktivitelerini belirlemesi ve gözlem verileri toplamadan önce bu koşulları göz önüne alarak bir plan oluşturması gereklidir. İş istasyonu ile ilgili mevcut durumu tanımlayıcı bilgiler toplandıktan sonra bir sonraki aşamaya geçilebilir.

Adım 3: İş istasyonundaki standart üretim aktivitelerinin tanımlanması

Literatür taramasında da bahsedildiği üzere zaman etüdü çalışmaları gerçekleştirilmeden önce metot etüdü çalışmalarının tamamlanmış olması ön koşuldur. Bu kapsamda, zaman etüdü çalışması yapılmadan önce iş istasyonunda kullanılan iş talimatları incelenmeli, üretim süresince gerçekleştirilecek üretim aktiviteleri tanımlanmalıdır. İmalat süreçlerinde kullanılan üretim dokümanları işletmeden işletmeye farklılık göstermektedir. Bazı üretim dokümanları teknik resimler üzerinden verilirken bazıları yapılacak işi genel olarak tanımlayabilir. Otomotiv gibi sektörlerde kullanıldığı gibi aktivite ve hatta hareket kırılımına inerek adım adım işlemler tanımlanabilir. Dolayısı ile zaman etüdü gerçekleştirecek uzman personel üretim sürecini tanımlayan ve takip eden süreç sahipleri ile süreci incelemeli ve standart süreler tanımlayabileceği aktivite

kırılımlarına bölmelidir. Bunun için mevcut üretim dokümanları incelenir, süreç sahiplerinden ve sürece dahil olan personellerden bilgi toplanır.

Tez çalışmasında ele alınan iş istasyonu için hazırlanan iş emri üretim dokümanları üretim aktiviteleri bazında tanımlı değildir. Bu sebeple, iş emri iş istasyonuna ulaşıp görevli personel tarafından çalışılmaya başlandığı andan gelecek iş istasyonuna gönderilmek üzere giden alanına bırakıldığı süre içerisinde gerçekleştirilen aktiviteler tüm iş emirleri için kapsayıcı olacak şekilde tanımlanmıştır. Ayrıca çalışma sonrasında öngörülemeyen gelecek yeni parçalar için ek üretim aktiviteleri olması durumunda, aktivitenin oluşturulan tahmin modeline kolayca eklenebilmesi ile mevcut modelin geliştirilebilme yeteneği sistemsal olarak garanti altına alınmıştır. Tez çalışmasında ele alınan örnek iş istasyonu için belirlenen üretim aktiviteleri Bölüm 4'te detaylı bir şekilde verilmiştir.

Adım 4: İş istasyonunda gözlem yapılması

Doğrudan gözlem ile zaman etüdü yapılırken kullanılacak farklı kayıt yöntemlerinden literatür araştırması kısmında bahsedilmiştir. Tez çalışması kapsamında iş emri üretim süreçlerinin gözlemleri video kayıt alınarak gerçekleştirilmiştir. Video kayıt yöntemi ile iş emri gözlemi yapılmasının avantajları aşağıdaki şekilde sıralanabilir:

- İş emrindeki parçaların üretimine ait tüm sürecin video ile kayıt altına alınması ile gözlem esnasında bilgi kaybı yaşanmaması,
- Video kaydını gerçekleştiren personellerin video çekim ile ilgili eğitimlerden sonra hızlıca gözlem alabilir yetkinliğe gelmesi ve çekim yapan personelin zaman etüdü yetkinliğine ihtiyaç duyulmaması,
- Videoların birden fazla kez durdur başlat yöntemi ile analiz esnasında detaylıca incelenebilmesi,
- Video kayıtlarının kanıt niteliği oluşturması,
- Tutulan video kayıtlarının başka amaçlarla da kullanılabilir olması (eğitim, vb.)

Tüm bu avantajların yanında bu yöntemin işletmeye sebep olacağı maliyetlerin de göz önüne alınması gereklidir. Video kayıtlarının çekilebilmesi için ek personele, çekim yapılabilmesi için kamera, batarya ve tripod gibi çekim ekipmanlarına, video kayıtlarının dosya boyutlarının büyük olmasından dolayı dosya sunucularında ek depolama alanına ihtiyaç duyulması gibi maliyetler göz önüne alınmalıdır.

Adım 5: Gözlemlerin analiz edilmesi ve aktivite sürelerinin çıkarılması

Video kayıt yöntemi ile toplanan kayıtlar analiz programı yardımı ile zaman etüdü çalışmasını gerçekleştirecek uzman tarafından analiz edilir. İş emrinin üretimi süresince gerçekleştirilen üretim aktivitelerinin işlem süreleri kullanılan yazılım yardımı ile video kayıtlarının izlenmesi yoluyla hesaplanır. Tez çalışmasında bu analizi gerçekleştirmek için Timer Pro Professional yazılımı kullanılmış olup analiz detayları Bölüm 4'te açıklanmıştır.

Adım 6: İş emri standart üretim süresi modelinin tanımlanması

Bölüm 1.1 Problem Tanımı'nda bahsedildiği üzere iş istasyonuna çalışılması için gelen parçalar iş emirleri ile takip edilmektedir. Bir iş emri tek tip bir parçadan oluşmakta ve üretim adedi ihtiyacına göre farklı miktarda parça adetleri içerebilmektedir. Örneğin, 12345 takip numaralı iş emri A parçasından 3 adet içeriyorsa çalışacak personel iş emrini teslim aldığı anda bu 3 adet parçanın işlemlerini tamamlayıp parçaların tamamını (iş emrini) giden alanına bıraktığında iş emri üretimini tamamlamış olur. İstasyona gelen iş emirlerinin içerdiği parça adedi değişkenlik göstereceğinden “parça adedi” tanımlanacak modelde bir parametre olarak bulunmalıdır.

İş emrindeki parçaların üretimini tamamlamak amacıyla gerçekleştirilen üretim aktiviteleri için harcanan süre, iş emrindeki parça adediyle değişebileceği gibi parça adedinden bağımsız da olabilir. Örneğin, iş emrinde 1 adet A parçası da olsa, 100 adet A parçası da olsa, çalışan personel 1 kez iş emri mühürleme (çalışılan iş emrinin tamamlandığı bilgisinin sisteme girilmesi) aktivitesi gerçekleştirecektir. Diğer taraftan, üretim dokümanında parçaya bir adet delik delinmesi istenmişse ve iş emrinde 3 adet parça varsa, çalışan personel iş emrini tamamlamak için 3 kez delik delme işlemi yapacaktır. İş emri üretimi başına 1 kez gerçekleştirilen üretim aktivitelerinin toplam süresi “toplam hazırlık süresi”, iş emrinde yer alan parça özelliklerine göre değişen ve her parça için tekrarlanan aktivitelerin süresi ise “toplam çalışma süresi” olarak ifade edilmiştir.

Literatür araştırması ve işletmeden edilen bilgiler doğrultusunda, iş emri standart üretim süresi aşağıdaki tahmin modeli ile hesaplanır.

$$\hat{y}_i(p) = (\hat{s}_i + \hat{\beta}_i(p)x_i) \times t_i \times z_j$$

Bu modelde,

$\hat{y}_i(p)$: p parçasının üretileceği i . iş emrinin üretim süresi tahminini

\hat{s}_i : i . iş emri için toplam hazırlık süresi tahminini

$\hat{\beta}_i(p)$: i . iş emri için p parçasına bağımlı toplam çalışma süresi tahminini

x_i : i . iş emrindeki toplam parça adedini

t_i : i . iş emrindeki çalışma temposu katsayısını

z_j : iş istasyonu j için belirlenen ek paylar katsayısını

göstermektedir. Çalışma temposu ve ek paylar Bölüm 2.1.2.1’de açıklanmıştır.

Adım 5’te gözlem analizleri ile belirlenen aktivite kısımları aktivite tiplerine göre “hazırlık süresi” ve “çalışma süresi” olarak ayrılarak \hat{s}_i ve $\hat{\beta}_i(p)$ ’nin tahmini için kullanılır.

Toplam hazırlık süresi ve toplam çalışma süresi,

$$\hat{s}_i = \sum_{k=1}^n \hat{a}_k \quad , \quad \hat{\beta}_i(p) = \sum_{l=1}^m \hat{b}_l(p)$$

olarak hesaplanır ve \hat{a}_k ile k . hazırlık aktivitesi süre tahmini, $\hat{b}_l(p)$ ile l . çalışma aktivitesi süre tahmini ifade edilir. Çalışma yapılan iş istasyonundaki hazırlık aktiviteleri adedi n , çalışma aktiviteleri adedi m ile gösterilmektedir.

Oluşturulan bu genel tahmin modeli Bölüm 4’te daha detaylı bir şekilde ele alınarak örnek eşliğinde kullanımı açıklanmıştır.

Adım 7: İş emri standart üretim süresi model parametrelerinin tahmin edilmesi

Adım 6’da verilen iş emri standart üretim süresi modelinde yer alan “iş emrindeki toplam parça adedi”, “çalışma temposu katsayısı” ve “ek paylar katsayısı” parametrelerinin değerleri bilinmektedir. Bununla birlikte, “toplam hazırlık süresi” ve “toplam çalışma süresi” olmak üzere iki kategoriye ayrılan ve üretim aktivite sürelerinden oluşan sürelerin tahmin edilmesi gereklidir. “Toplam hazırlık süresi” içerisinde yer alan aktiviteler üretilecek her iş emrinde standart olarak 1 kez gerçekleştirildiğinden, temel istatistiksel yöntemlere başvurularak (gözlemlerin dağılımlarının incelenmesi ve ortalamasının alınması gibi.) tahmin edilmesi mümkündür. Tez çalışmasında Bölüm 4’te verilen uygulama örneğinde de bu yöntem ile “toplam hazırlık süresi” için toplamsal bir yaklaşım getirilerek tahmin gerçekleştirilmiştir. Parça özelliklerine göre değişkenlik gösteren

aktivite sürelerini içeren parametrelerin tahmini ise daha detaylı bir çalışma gerektirir. Tez çalışmasına konu olan iş istasyonunda da “toplam çalışma süresi” parametresini oluşturan üretim aktiviteleri sürelerinden biri parça özelliklerine göre değişkenlik göstermektedir. Parça çeşitliliği yüksek iş istasyonlarında parça özellikleri ile değişkenlik gösteren aktivite sürelerini tahmin etmek zorlu bir süreçtir. Aktivite süresine etki eden parça özelliklerinin ne olduğunun ve bu özelliklerin aktivite süresine ne ölçüde etki ettiğinin ortaya çıkarılması sonuçların doğruluğu için büyük önem taşımaktadır.

Tez çalışması kapsamında farklı özelliklerdeki aktiviteler farklı istatistiksel yöntemler kullanılarak tahmin edilirken, özellikle parça özelliklerine bağlı değişkenlik gösteren aktivite sürelerinin tahmin edilmesi için kullanılacak iki farklı yöntem (Çok değişkenli doğrusal regresyon ve CART algoritması) uygulanarak karşılaştırmalı sonuçlar ortaya koyulmuştur. Parametre tahminleri Bölüm 4’te detaylı olarak verilmiştir.

Adım 8: İş emri standart üretim süresinin hesaplanması

Adım 7’de istatistiksel yöntemlerle hesaplanan model parametreleri, iş emri standart üretim süresi toplamsal tahmin modeline yerleştirilerek $\hat{y}_i(p)$ hesaplanır. İşletmelerde genellikle üretim verileri şirket sunucularında yer alan veritabanlarında tutulur. Modelin ihtiyaç duyduğu bilgilerin anlık ve güncel olarak sağlanması, hesaplama ve sonuçların raporlanmasının sistematik bir yaklaşımla, düzenli ve otomatik olarak gerçekleştirilebilmesi için Microsoft SQL Server Management Studio yazılımı kullanılmıştır.

Adım 9: Tahmin hatalarının izlenmesi için düzeltilmiş Shewhart kontrol grafiği ve iteratif model düzeltmesi

Üretim planlamada kullanılacak iş emri üretim süreleri sağlandıktan sonra bu süreler planlama sürecine entegre edilir ve planlar yapılır. Örnek çalışmanın yapıldığı iş istasyonunda iş emri üretimine başlandığında ilgili personel iş emrine ilişkin parça işçiliğini başlatır ve bir sonraki parçayı çalışmaya başlayana kadar geçen süre sisteme kaydedilir. Sisteme kaydedilen gerçekleşme süresi ve toplamsal tahmin modeli ile elde edilen tahmin süresinin farkının alınmasıyla elde edilen artıklar kontrol grafikleri kullanılarak izlenir ve modelin verdiği sonuçlar ile gerçekleştirmeler arasında beklenenin dışında bir sapma olması durumunda (artıkların beklenen seviyenin üzerinde bir değişkenlik göstermesi); Adım 3’e geri dönülerek öncelikle standart iş adımları kontrol edilir, standart dışı aktiviteler olması durumunda üretim süreci standart uygulamaları

iyileştirilir veya modelde yeterli seviyede temsil edilemediğinden beklenen üzerinde sapma görülen parça var ise modele dahil edilerek model iyileştirilir ve kontrol grafikleri yeni kontrol limitleri ile tekrar çizilerek izleme sürecine devam edilir. Tahmin performansını izleme aşamasında Gandy ve Kvaløy (2013)'un tahmin hatalarının kontrol grafikleri performansı üzerindeki etkisini hesaba katan yaklaşımı kullanılarak ve bu yaklaşımla oluşturulan grafiklerden elde edilen sinyallerin gerekli ise modelin tahmin kabiliyetini artıracak şekilde girdi olarak kullanılmasıyla sürekli olarak gelişen iteratif bir prosedür oluşturulmuştur. Düzeltilmiş Shewhart kontrol grafiğinin detayları Bölüm 3.7'de verilmiştir.

Yukarıda detayları verilen prosedür kısıtlı kaynaklar ile parça çeşidi ve adedinin çok olduğu ve sürekli güncellendiği bir iş istasyonunda uygulanmak için tasarlanmıştır. Bir kereliğine yapılan geleneksel gözlem çalışmaları bu tür istasyonlarda yetersiz kaldığından sürekli olarak güncellenen ve bu işi yaparken kaynakların etkin kullanılması ile hızlı bir şekilde sonuçlara ulaşılması hedeflenen bir yaklaşımdır. Örneğin 6000 parçanın olduğu bir istasyonda sınırsız kaynak ile parçaların birebir gözlemi alınabilir ve her yeni parçada buna tekrarlanarak devam edilebilir. Fakat gerçek bir işletmede kaynaklar sınırsız değildir ve çoğu zaman bu kadar parça için ayrı ayrı gözlem almak mümkün olmayacaktır. Başlangıç noktasında nispeten az gözlem adetleriyle yaratılan modelin hemen kullanıma alınması ve zaman içerisinde gerek duyuldukça iteratif olarak iyileştirilebilir olması yöntemin avantajlarından biri olarak karşımıza çıkmaktadır. Metodoloji bölümü altında verilen gelecek başlıklarda prosedür boyunca uygulanan teknik metotlar açıklanmış ve önerilen 9 adımlık prosedür Bölüm 4'te örnek çalışma ile detaylarıyla verilmiştir.

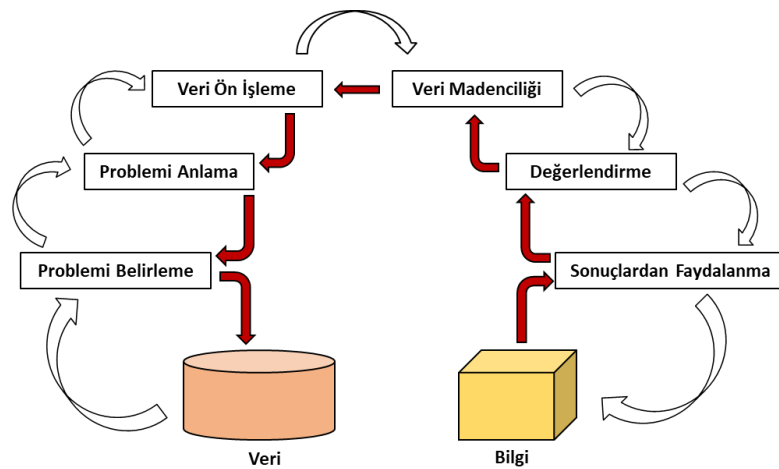
3.2. Veri Tabanlarında Bilgi Keşfi

Veri tabanlarında Bilgi Keşfi ("Knowledge Discovery in Databases", KDD), büyük veri havuzlarının keşif amaçlı analizi ve modellenmesidir. KDD, büyük ve karmaşık veri kümelerinden, geçerli, yeni, kullanışlı ve anlaşılır örüntüleri belirlemeye yönelik organize bir süreçtir. Veri Madenciliği, verileri araştıran, veriler ile kurulan modeli geliştiren ve bilgiler arasında önceden bilinmeyen örüntüleri keşfeden algoritmaların çıkarımını içeren KDD sürecinin temelidir (Maimon & Rokach, 2010).

KDD süreci, araştırmacılar tarafından her biri avantaj ve dezavantajlara sahip farklı farklı aşamalarla ayrıştırılmıştır. Aşağıda, son yıllarda yaygın olarak kullanılan ve bu aşamaları altı adımda sınıflandıran bir bölümlenme verilmiştir (Garcia, Luengo, & Herrera, 2015) :

1. Problemi Belirleme: Uygulama alanının, uzmanlar tarafından elde edilen ilgili ön bilgilerin ve son kullanıcı tarafından izlenen nihai hedeflerin belirlenmesi ve düzenlenmesidir.
2. Problemi Anlama: Yüksek derecede güvenilirlik elde etmek için hem seçilen verinin anlaşılmasını hem de ilgili uzman bilgisini içerir.
3. Veri Ön İşleme: Bu aşama, bir veri tabanındaki hem özelliklerin hem de örneklerin seçilmesi ve çıkarılması dahil olmak üzere veri temizleme (gürültü ve tutarsız verilerin kaldırılması gibi), veri entegrasyonu (birden çok veri kaynağının tek bir kaynakta birleştirilebilmesi), veri dönüştürme (verilerin belirli veri madenciliği görevleri veya toplama işlemleri için uygun formlara dönüştürülmesi ve birleştirilmesi) ve veri azaltma işlemlerini içerir. Bu aşama, tez çalışmasının bu bölümünün odak noktası olacaktır.
4. Veri Madenciliği: Geçerli veri kalıplarını çıkarmak için yöntemlerin kullanıldığı temel süreçtir. Bu adım, en uygun veri madenciliği algoritmasının seçimini içerir. Son olarak, temel parametreleri ve doğrulama prosedürlerini ayarlayarak probleme seçilen algoritmanın uyumu sağlanır.
5. Değerlendirme: Çıkarılan modellerin performansının incelenmesi ve yorumlanması gerçekleştirilir.
6. Sonuçlardan Faydalanma: Son aşama, bilgiyi doğrudan kullanmayı, daha sonraki işlemler için bilgiyi başka bir sisteme dahil etmeyi veya sadece keşfedilen bilgiyi görselleştirme araçlarıyla raporlamayı içerebilir.

Aşağıdaki Şekil 3.2’de görülen KDD sürecindeki veri ön işleme adımı, bir sonraki başlıkta detaylı olarak incelenmiştir.



Şekil 3.2 KDD Süreci

3.3 Veri Ön İşleme

Veri ön işleme, bilgi keşfi sürecindeki en temel aşamadır. Veri madenciliği gibi diğer adımlardan daha az bilinmesine rağmen, veri ön işleme aslında çok sık olarak tüm veri analiz süreci içinde daha fazla çaba ve zaman gerektirir (toplam çabanın $> \%50$ 'si) (Ramírez-Gallego, Krawczyk, García, Wozniak, & Herrera, 2017). Veri ön işleme tüm KDD sürecinin $\%70-80$ 'ini temsil ettiği için KDD'deki en önemli adımlardan biridir (Idri, Benhar, Fernández-Alemán, & Kadi, 2018).

Ham veriler genellikle tutarsızlıklar, eksik değerler, gürültü ve/veya fazlalıklar gibi birçok kusurla birlikte gelir. Bu nedenle, düşük kaliteli veriler sonraki öğrenme algoritmalarının performansını zayıflatacaktır. Uygun ön işleme adımlarını gerçekleştirerek, takip eden otomatik keşiflerin ve kararların kalitesi ve güvenilirliği önemli ölçüde etkilenebilir (Ramírez-Gallego, Krawczyk, García, Wozniak, & Herrera, 2017). Veri ön işlemenin amacı, makine öğrenimi sürecinin daha hızlı ve daha doğru bir şekilde uygulanabilmesi için giriş verilerini temizlemek ve düzeltmek olarak tanımlanmıştır. Bu tanımlarla, veri ön işleme teknikleri, veri madenciliği algoritmalarının veri bilimi problemleriyle daha kolay başa çıkmasını sağlamalıdır. Cordon vd. R Studio yazılımı içerisindeki “smartdata” paketini kullanarak bu pakette yer alan veri ön işleme tekniklerini açıklamışlardır. Bu teknikler; eksik değerlerin işlenmesi, gürültü filtreleme, özellik seçimi, aykırı değer tespiti, uzay dönüşümleri, aşırı örnekleme, ayırıştırma, normalleştirme ve örnek seçimi için ön işleme algoritmalarıdır (Cordon, Luengo, García, Herrera, & Charte, 2019).

Veri ön işleme süreci; veri temizleme, veri entegrasyonu, eksik değerleri işleme, veri dönüştürme, veri azaltma metotlarını içerir (Benhar, Idri, & Fernández-Alemán, 2020).

Veri Temizleme : Veri kalitesini artırmak için verilerdeki hataları ve tutarsızlıkları tespit etmek ve kaldırmakla ilgilidir. Veri temizleme rutinleri uygulandıktan sonra, gürültülü veriler düzeltilir, aykırı değerler düzeltilir veya kaldırılır, eksik değerler doldurulur veya silinir, tutarsızlıklar giderilir ve mükerrer bilgiler ortadan kaldırılır, böylece daha fazla analiz için hazır, doğru ve tutarlı veriler sağlanır (Rahm & Do, 2000).

Maletic & Marcus veri temizleme sürecini aşağıdaki şekilde tanımlar :

- Hata türlerini tanımlama ve belirleme,
- Hata örneklerini arama ve belirleme,

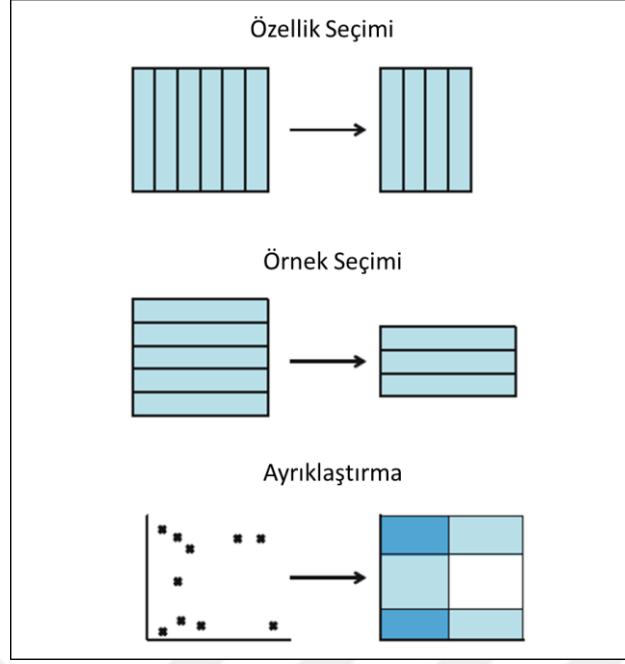
• Hataları düzeltme (Maletic & Marcus, 2010).

Veri Entegrasyonu : Farklı veri kaynaklarından elde edilen verileri tutarlı bir veri kümesinde birleştirme yöntemidir (Jamshed, Khan, Khurram, Inayatullah, & Athar, 2019).

Eksik Değerleri İşleme : Eksik değerlerle başa çıkma yöntemleri ardışık ve paralel olarak kategorize edilir. Ardışık yöntemlerde, bir ön işleme olarak, eksik öznitelik değerleri önce bilinen değerlerle değiştirilir, ardından bilinen tüm öznitelik değerlerine sahip bir veri kümesi için bilgi elde edilir. Paralel yöntemlerde ön işleme yoktur, yani bilgi doğrudan orijinal veri kümelerinden elde edilir (Grzymala-Busse & Grzymala-Busse, 2010).

Veri Dönüştürme : Veri kümesinin veri madenciliği için uygun birleşik bir forma dönüştürülmesini ifade eder. Veri dönüştürme yöntemleri, gürültüyü yumuşatma, veri toplama ve veri normalleştirmeyi içerir. Veri analizi, yönlü, amaca yönelik bir veri toplamaya sahip olarak daha verimli olabilir. Veri özelliklerinin ölçüm birimlerine bağımlılığını önlemek için, verilerin daha okunabilir olan $[0,10]$ gibi daha küçük ortak alanlara düşmesini sağlamak için veriler normalleştirilmelidir. Min-maks normalleştirme, sıfır ortalama normalleştirme ve kesirli ölçek normalleştirme gibi farklı normalleştirme biçimleri vardır. Sinir ağı algoritmaları veya uzaklık ölçülerine (en yakın komşu sınıflandırması gibi) dayalı sınıflandırma algoritmaları için normalleştirme yöntemi daha iyi çalışır. Tüm özellikleri aynı seviyede standart hale getirmek için bir normalleştirme süreci gereklidir (Sun, ve diğerleri, 2018).

Veri Azaltma : Özellikle özelliklerin sayısının çok fazla olduğu alanlarda genellikle çok faydalıdır. Bunun temel amacı, kararlı ve doğru bir model üretmek için değişken kümelerini verilerin bütünlüğünü kaybetmeden ilgili olanlara indirgemektir. Veri azaltma stratejileri, ayrıklaştırmayı ve boyut azaltmayı içerir. Ayrıklaştırma, nicel verileri nitel verilere dönüştüren bir veri işleme prosedürüdür. Boyut küçültme iki görevi içerir: özellik çıkarma ve özellik seçimi. Özellik çıkarma, orijinal öznitelikleri birleştirerek yeni bir indirgenmiş özellik alt kümesi oluşturmayı içerir, özellik seçimi ise ilgili ve optimal olanları seçerek ve yeterli bilgiyi koruyan orijinal özelliklerin sayısını azaltmaya çalışır (Benhar, Idri, & Fernández-Alemán, 2020). Özellik seçimi, örnek seçimi ve ayrıklaştırma işlemlerinin görselleştirilmiş gösterimi Şekil 3.3'te verilmiştir.




Şekil 3.3 Veri Azaltma Stratejileri (Garcia, Luengo, & Herrera, 2015)

3.4. Veri Madenciliğinde Makine Öğrenmesi Algoritmaları – Denetimli Öğrenme

Makine öğrenimi, deneyimle otomatik olarak gelişen ve bir öğrenme sürecini uygulayan bilgisayar sistemleri oluşturma süreci olarak ya da bir çıkarım süreci, model uydurma veya örneklerden öğrenme yoluyla teorinin verilerden otomatik olarak öğrenilmesi olarak tanımlanabilir. İyi olasılık modelleri oluşturarak bir veri gövdesinden yararlı bilgilerin otomatik olarak çıkarılması ve genel bir teorinin olmadığı, çok fazla verinin olduğu alanlar için idealdir. Makine öğrenimi araştırmasının ana odak noktası, otomatik olarak modeller üretmektir ve model, bir sistemin veya kavramın ana işleyişini göstermek için tasarlanmış bir model, plan, temsil veya açıklamadır (Ayodele, Machine Learning Overview, 2010).

Veri madenciliğinde kullanılan modeller, temel olarak Şekil 3.4’de görüldüğü üzere tahmin edici (predictive) ve tanımlayıcı (descriptive) olmak üzere iki ana başlık altında incelenmektedir (Bigus, 1996).

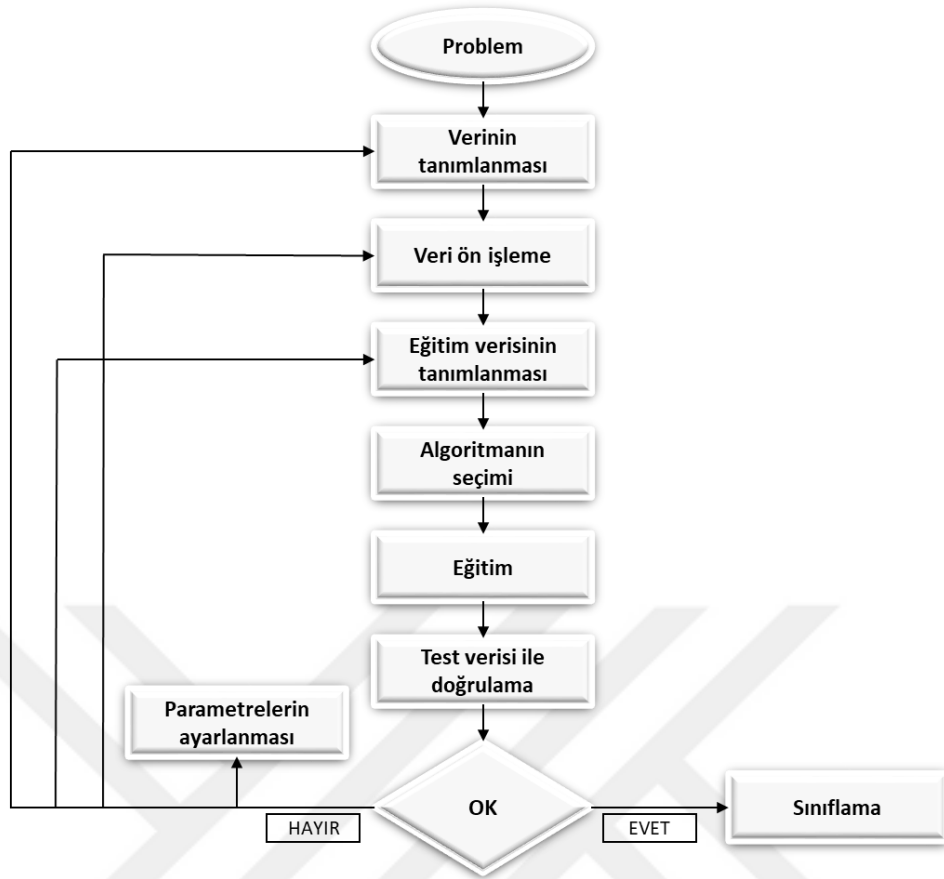


Şekil 3.4 Veri Madenciliği Modelleri

Makine öğrenimi algoritmaları tarafından kullanılan bir veri kümesindeki her örnek, aynı özellik (feature) kümesi kullanılarak temsil edilir. Özellikler sürekli, kategorik ve ya ikili olabilir. Örnekler bilinen etiketler ile verilirse (örneklere karşı gelen çıktılarla) denetimli öğrenme, etiketlenmemiş ise denetimsiz öğrenme olarak adlandırılır (Kotsiantis, Zaharakis, & Pintelas, 2007).

Makine öğrenimi genellikle üç tür problemle ilgilenir: sınıflandırma, regresyon ve kümeleme. Eğitim verilerinin türlerinin ve kategorilerinin yapısına bağlı olarak, uygun makine öğrenimi algoritmasını uygulamak için mevcut "denetimli öğrenme", "denetimsiz öğrenme", "yarı denetimli öğrenme" ve "takviyeli öğrenme" teknikleri arasından seçim yapılması gerekebilir (Ray, 2019).

Denetimli öğrenme, örnek girdi çıktı çiftlerine dayalı olarak bir girdiyi bir çıktıya eşleyen bir işlevi öğrenmenin makine öğrenimi görevidir. Bir dizi eğitim örneğinden oluşan etiketli eğitim verilerinden bir işlev çıkarır. Denetimli makine öğrenimi algoritmaları, harici yardıma ihtiyaç duyan algoritmalarıdır. Girdi veri seti, eğitim ve test veri seti olarak ikiye ayrılır. Eğitim veri kümesi, tahmin edilmesi veya sınıflandırılması gereken çıktı değişkenine sahiptir. Tüm algoritmalar, eğitim veri kümesinden bir tür kalıp öğrenir ve bunları tahmin veya sınıflandırma için test veri kümesine uygular (Mahesh, 2018). Denetimli makine öğrenmesi sürecinin genel yapısı Şekil 3.5’de bir örnek ile verilmiştir (Ayodele, Types of Machine Learning Algorithms, 2010).



Şekil 3.5 Denetimli Makine Öğrenimi Süreci

Veri madenciliğindeki denetimli makine öğrenmesi algoritmaları aşağıda verilmiştir .


- Çok değişkenli doğrusal regresyon (Multiple linear regression)
- Lojistik regresyon (Logistic regression)
- K-en yakın komşular (K-nearest neighbors, KNN)
- Karar ağacı (Decision tree)
- Destek vektör makinesi (Support vector machine, SVM)
- Rastgele orman (Random forest)
- Naive bayes (Kumari, Kumar, Prakash, & S., 2021)

Tez çalışmasında kullanılacak yöntemler gelecek bölümlerde detaylı olarak ele alınmıştır

3.5 Çok Değişkenli Doğrusal Regresyon

Regresyon analizi, değişkenler arasındaki ilişkiyi araştırmak ve modellemek için kullanılan istatistiksel bir tekniktir. Regresyon analizinin bir çok alanda kullanılabilmesi ile en geniş kapsamda kullanım alanına sahip istatistiksel teknik olduğu söylenebilir.

Örneğin, x değişkeninin y değişkeni ile ilişkisi olduğu düşünülerek x 'in belirli değerleri için y 'nin aldığı değerler incelenerek bir saçılım grafiği oluşturulabilir.




Şekil 3.6 Örnek x ve y Değişkenleri İçin Saçılım Grafiği

Şekil 3.6'de verilen örnek saçılım grafiği incelendiğinde x ve y değişkenleri arasında bir ilişki olduğu hatta bu ilişkinin doğrusal bir çizgide olduğunu söylemek mümkündür. Grafikteki noktaların ortasından geçecek şekilde çizilen bir doğru ile bu ilişki Şekil 3.7'de daha net görülebilmektedir. Bu iki değişken arasındaki doğrusal ilişki,

$$y = \beta_0 + \beta_1 x$$

formülü ile ifade edilebilir. Burada, β_0 doğrunun y eksenindeki kesişim noktasını, β_1 ise doğrunun eğimini ifade eder.



Şekil 3.7 Örnek x ve y Değişkenleri Arasındaki Doğrusal İlişki

Şekil 3.7’de görüldüğü üzere noktalar tam olarak doğru üzerine düşmez. Bu sebeple yukarıda verilen doğrusal ilişki formülünün düzenlenmesi gerekir. Gözlemlenen y değeri ile doğrusal ilişki çizgisi arasındaki fark ε ile ifade edilen istatistiksel hata olarak tanımlanır. Yani modelin verilere tam olarak uymamasını açıklayan rastgele bir değişkendir. Oluşan bu hata x ve y değişkenleri arasındaki ilişkinin haricinde çevresel diğer değişkenlerin etkisiyle orataya çıkabilir. Bu nedenle, x ve y arasındaki ilişkiyi daha doğru ifade eden model,

$$y = \beta_0 + \beta_1 x + \varepsilon$$

şeklinde yazılır ve doğrusal regresyon modeli olarak ifade edilir. Burada,

x : *bağımsız değişken*

y : *bağımlı değişken*

olarak adlandırılır. Bu isimlendirme istatistiksel bağımsızlık kavramıyla karışıklığa sebep olduğu için x değişkenine “tahmin değişkeni”, y değişkenine “yanıt değişkeni” denmektedir. Verilen doğrusal regresyon modeli bir adet tahmin değişkeni içerdiğinden “basit doğrusal regresyon modeli” olarak adlandırılır.

Doğrusal regresyon modeli biraz daha detaylı incelemek için, x tahmin değişkeninin değerini sabitleyebileceğimizi ve karşılık gelen y yanıtının değerini gözlemleyebileceğimizi varsayalım. Bu durumda x sabitse, denklemin sağ tarafındaki rastgele bileşen ε , y 'nin özelliklerini belirler. ε 'nin ortalama ve varyansının sırasıyla 0 ve σ^2 olduğunu varsayalım. Daha sonra, tahmin değişkeninin herhangi bir değerindeki ortalama yanıt,

$$E(y|x) = \mu_{y|x} = E(\beta_0 + \beta_1 x + \varepsilon) = \beta_0 + \beta_1 x$$

olur. Bu ifade, Şekil 3.7’deki dağılım diyagramını inceledikten sonra başlangıçta yazılan ilişkinin aynısını vermektedir. Verilen herhangi bir x değişkeni için y yanıt değişkeninin varyansı,

$$Var(y|x) = \sigma_{y|x}^2 = Var(\beta_0 + \beta_1 x + \varepsilon) = \sigma^2$$

olur. Böylece, gerçek regresyon modeli $\mu_{y|x} = \beta_0 + \beta_1 x$ ortalama değerler çizgisini ifade eder, yani herhangi bir x değerindeki regresyon çizgisinin yüksekliği o x değeri için için y 'nin beklenen değerini verir. Eğim β_1 , x 'teki bir birim değişiklik için y 'nin ortalamasındaki değişiklik olarak yorumlanabilir. Ayrıca, x 'in belirli bir değerinde y 'nin

değişkenliği, modelin hata bileşeninin varyansı σ^2 tarafından belirlenir. Bu, her x 'te y değerlerinin bir dağılımı olduğu ve bu dağılımın varyansının her x 'te aynı olduğu anlamına gelir.

Yanıt değişkeni y birden fazla tahmin değişkeni ile ilişkili olabilir. Bu durumda kurulan,

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon$$

modeli, çok değişkenli regreyon modeli olarak adlandırılır.

β_0 ve β_1 parametreleri bilinmemektedir ve örneklem verileri kullanılarak tahmin edilmelidir. Diyelim ki (y_1, x_1) , (y_2, x_2) , ..., (y_n, x_n) , n veri çifti olsun. Bu veriler, özellikle verileri toplamak için tasarlanmış kontrollü bir deneyden, gözlemsel bir çalışmadan veya mevcut tarihsel kayıtlardan (geriye dönük bir çalışma) elde edilmiş olabilir. β_0 ve β_1 parametreleri tahmini yapmak için en küçük kareler yöntemi kullanılır. Bu yöntemde, y_i gözlemleri ile düz regresyon çizgisi arasındaki farkların karelerinin toplamı minimum olacak şekilde β_0 ve β_1 tahmin edilir. $i = 1, 2, \dots, n$ olmak üzere (y_i, x_i) veri çiftleri için yazılan örnek regresyon modeli aşağıda verilmiştir.

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, i = 1, 2, \dots, n$$

Bu örnek regresyon modeli için en küçük kareler kriteri,

$$S(\beta_0, \beta_1) = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2$$

şeklinde ifade edilir. β_0 ve β_1 en küçük kareler tahmin edicileri $\hat{\beta}_0$ ve $\hat{\beta}_1$

$$\left. \frac{\partial S}{\partial \beta_0} \right|_{\hat{\beta}_0, \hat{\beta}_1} = -2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0$$

ve

$$\left. \frac{\partial S}{\partial \beta_1} \right|_{\hat{\beta}_0, \hat{\beta}_1} = -2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) x_i = 0$$

koşullarını sağlamalıdır. Bu iki eşitliğin basitleştirilmesi ile,

$$n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n x_i = \sum_{i=1}^n y_i$$

$$\hat{\beta}_0 \sum_{i=1}^n x_i + \hat{\beta}_1 \sum_{i=1}^n x_i^2 = \sum_{i=1}^n y_i x_i$$

en küçük kareler yönteminin normal denklemleri elde edilir. Normal denklemleri çözümü,

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \text{ ve } \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

sırasıyla y_i ve x_i için ortalamalar olmak üzere,

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

ve

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n y_i x_i - \frac{(\sum_{i=1}^n y_i)(\sum_{i=1}^n x_i)}{n}}{\sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n}}$$

olarak ifade edilir. Verilen çözüm denklemlerindeki $\hat{\beta}_0$ ve $\hat{\beta}_1$, sırasıyla kesişim noktası ve eğimin en küçük kareler tahmin edicisidir. Böylece,

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$$

denklemini belirli bir x için y 'nin ortalamasının bir nokta tahminini verir. Normal denklemleri çözümündeki $\hat{\beta}_1$ denkleminin paydası x_i 'nin karelerinin düzeltilmiş toplamı ve pay da x_i ve y_i 'nin çarpaz çarpımlarının düzeltilmiş toplamı olduğundan, bu nicelikler aşağıdaki şekilde daha kompakt bir notasyonda yazılabilir:

$$S_{xx} = \sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n} = \sum_{i=1}^n (x_i - \bar{x})^2$$

ve

$$S_{xy} = \sum_{i=1}^n y_i x_i - \frac{(\sum_{i=1}^n y_i)(\sum_{i=1}^n x_i)}{n} = \sum_{i=1}^n y_i (x_i - \bar{x})$$

Bu kompakt form kullanılarak $\hat{\beta}_1$ normal denklemleri çözümü,

$$\hat{\beta}_1 = \frac{S_{xy}}{S_{xx}}$$

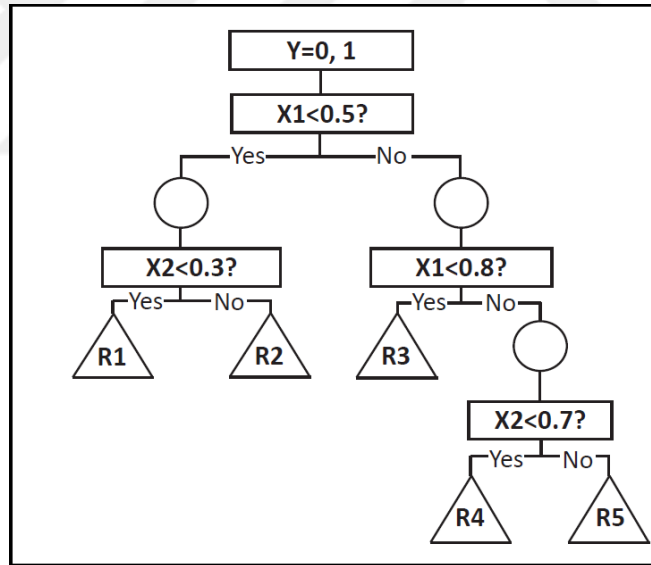
şeklinde yazılır. Gözlemlenen değer y_i ile karşılık gelen tahmin değeri \hat{y}_i arasındaki fark artıktır. Matematiksel olarak i . artık,

$$e_i = y_i - \hat{y}_i = y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i), \quad i = 1, 2, \dots, n$$

olarak ifade edilir. Artıklar, model yeterliliğinin araştırılmasında ve temel varsayımlardan sapmaların tespitinde önemli bir rol oynar (Montgomery, Peck, & Vining, Introduction to Linear Regression Analysis, 2012).

3.6 Karar Ağacı ve CART Algoritması

Bir karar ağacı modelinin ana bileşenleri, düğümler ve dallardır. Karar ağacı ile model oluşturmanın en önemli adımları ise “bölme”, “durdurma” ve “budama”dır. Şekil 3.8’de, tek bir ikili (0 veya 1) hedef değişken Y ve 0 ile 1 arasında değişen iki sürekli değişken, X1 ve X2 içeren basit bir karar ağacı modeli verilmiştir. Karar ağacının ana bileşenleri ve adımları aşağıda özetlenmiştir (Song & Lu, 2015).



Şekil 3.8 İkili Hedef Değişken Y İçin Örnek Karar Ağacı

Düğümler: Üç tür düğüm vardır: (1) Karar düğümü olarak da adlandırılan bir kök düğüm, tüm kayıtların birbirini dışlayan iki veya daha fazla alt kümeye bölünmesiyle sonuçlanacak bir seçimi temsil eder. (2) Şans düğümleri olarak da adlandırılan dahili düğümler, ağaç yapısında o noktada mevcut olan olası seçeneklerden birini temsil eder; düğümün üst kenarı üst düğümüne ve alt kenarı alt düğümlerine veya yaprak düğümlerine

bağlıdır. (3) Uç düğümler olarak da adlandırılan yaprak düğümler, kararların veya olayların bir kombinasyonunun nihai sonucunu temsil eder.

Dallar : Dallar, kök düğümlerden ve iç düğümlerden kaynaklanan tesadüfi sonuçları veya oluşumları temsil eder. Dallar hiyerarşisi kullanılarak bir karar ağacı modeli oluşturulur. Kök düğümden iç düğümlere ve yaprak düğüme giden her yol, bir sınıflandırma karar kuralını temsil eder. Bu karar ağacı yolları, "eğer-o zaman" kuralları olarak da temsil edilebilir. Örneğin, "eğer 1. koşul ve 2. koşul ve ... ve k koşulu meydana gelirse, o zaman j sonucu gerçekleşir" gibi.

Bölme : Düğümleri hedef değişkenin daha saf alt düğümlerine bölmek için yalnızca hedef değişkenle ilgili girdi değişkenleri kullanılır. Hem ayrık girdi değişkenleri hem de (iki veya daha fazla kategoriye ayrılmış) sürekli girdi değişkenleri kullanılabilir. Modeli oluştururken, önce en önemli girdi değişkenlerini tanımlamalı ve ardından kök düğümdaki ve sonraki dahili düğümlerdeki kayıtlar, bu değişkenlerin durumuna göre iki veya daha fazla kategoriye veya "kutuya" bölünmelidir. Ortaya çıkan alt düğümlerin 'safılık' derecesi ile ilgili özellikler, farklı potansiyel girdi değişkenleri arasında seçim yapmak için kullanılır; bu özellikler entropi, Gini indeksi, sınıflandırma hatası, bilgi kazancı, kazanç oranı ve ikileme kriterlerini içerir. Bu bölme işlemi, önceden belirlenmiş homojenlik veya durdurma kriterleri sağlanana kadar devam eder. Çoğu durumda, karar ağacı modelini oluşturmak için tüm potansiyel girdi değişkenleri kullanılmaz ve bazı durumlarda belirli bir girdi değişkeni, karar ağacının farklı seviyelerinde birden çok kez kullanılabilir.

Durdurma : Karmaşıklık ve sağlamlık, istatistiksel bir model oluştururken aynı anda dikkate alınması gereken, modellerin rekabet halindeki özellikleridir. Bir model ne kadar karmaşıksa, gelecekteki kayıtları tahmin etmek için kullanıldığında o kadar az güvenilir olacaktır. Uç bir durum örneği, her bir yaprak düğümdaki kayıtları %100 saf hale getirecek kadar geniş bir alana yayılan çok karmaşık bir karar ağacı modeli oluşturmaktır (yani, tüm kayıtlar hedef sonuca sahiptir). Böyle bir karar ağacı, mevcut gözlemlere fazlasıyla uyar ve her yaprakta az sayıda kayda sahip olur, bu nedenle gelecekteki durumları güvenilir bir şekilde tahmin edemez ve bu nedenle zayıf genellenebilirliğe sahip olur (yani, sağlamlıktan yoksundur). Bunu ve modelin aşırı karmaşık hale gelmesini önlemek için bir karar ağacı oluştururken durdurma kuralları uygulanmalıdır. Durdurma kurallarında kullanılan ortak parametreler şunları içerir: (a) bir yapraktaki minimum kayıt sayısı; (b) bölmeden önce bir düğümdaki minimum kayıt sayısı; ve (c) kök düğümden

herhangi bir yaprağın derinliği (yani adım sayısı). Durdurma parametreleri, analizin amacına ve kullanılan veri setinin özelliklerine göre seçilmelidir.

Budama : Bazı durumlarda, durdurma kuralları iyi çalışmaz. Bir karar ağacı modeli oluşturmanın alternatif bir yolu, önce büyük bir ağaç büyütmek ve ardından daha az ek bilgi sağlayan düğümleri kaldırarak onu en uygun boyuta budamaktır. Birkaç adaydan mümkün olan en iyi alt ağacı seçmenin yaygın bir yöntemi, hata tahmini olan kayıtların oranını (yani, hedefin tahmin edilen oluşumunun yanlış olduğu oran) dikkate almaktır. En iyi alternatifi seçmenin diğer yöntemleri bir doğrulama veri seti kullanmak (yani örnekleme ikiye bölüp eğitim veri setinde geliştirilen modelin validasyon veri setinde test edilmesi) veya küçük numuneler için çapraz doğrulama yapmak (örneğin numuneyi 10 gruba veya "kata" bölmek ve 9 kattan geliştirilen modeli 10'uncu katta test etmek, 10 kombinasyonun tümü için tekrarlamak ve oranların veya hatalı tahminlerin ortalamasını almak). İleri budama ve geriye budama olmak üzere iki tür budama vardır. İleri budama, önemli olmayan dalların oluşumunu önlemek için Ki-kare testleri veya çoklu karşılaştırma düzeltme yöntemleri kullanır. Geriye budama ise, doğrulama veri setine uygulandığında genel sınıflandırmanın doğruluğunu artıracak şekilde dalları kaldırmak için tam bir karar ağacı oluşturulduktan sonra kullanılır (Song & Lu, 2015).

Karar ağaçlarına dayalı olarak geliştirilen birçok algoritma vardır. Bu algoritmalar kök, düğüm ve dallanma kriteri seçimlerinde izledikleri yol açısından birbirlerinden ayrılırlar. Karar ağacı oluşturmak için geliştirilen bu algoritmalar arasında;

- CHAID (Chi-Squared Automatic Interaction Detector : Otomatik Ki-Kare Etkileşim Belirleme),
- CART (Classification and Regression Trees: Sınıflama ve Regresyon Ağaçları),
- MARS (Multivariate Adaptive Regression Splines: Çok Değişkenli Uyumlu Regresyon Uzanımları),
- QUEST (Quick, Unbiased, Efficient Statistical Tree: Hızlı, Yansız, Etkin İstatistiksel Ağaç),
- SLIQ (Supervised Learning in Quest),
- SPRINT (Scalable Parallelizable Induction of Decision Trees)
- ID3, C4.5 ve C5.0

yer almaktadır (Güner, 2014).

CART algoritması, 1984 yılında Breiman vd. tarafından önerilmiştir. Bu algoritma Morgan ve Sonquist'in AID (Automatic Interaction Detection) adlı karar ağacı algoritmasının devamı şeklindedir. Makine öğreniminin denetimli öğrenmesi içinde olan CART, hem kategorik hem de sürekli değişkenleri kullanan sınıflandırma ve regresyon ağacı algoritmasıdır. CART algoritması üç adımdan oluşmaktadır (Yavuz & Çilengiroğlu, 2020):

a. Maksimum ağacın oluşturulması

Ağaç oluşturulması, ilgilenilen kümeyi kendinden daha homojen olan iki alt kümeye bölen bir yapıdır. Veri seti içerisinde yer alan tüm risk faktörleri ağacın kökü tarafından kapsanmaktadır. Ayrıca bu kök, her bir seviyede kendine özgü iki alt düğüm halinde bölünen bir ana düğüm olarak düşünülmektedir. Sonraki adımda, her alt grup bir ana grup olmaktadır. Her bölünme bir alt gruptaki tüm risk faktörlerin benzer sonuç değişkeni değerlerine sahip olacak şekilde seçilen bir açıklayıcının değeri ile tanımlanmaktadır.

En önemli risk faktörü, safsızlık (impurity) ölçütleri (Gini Diversity Index, Twoing, Chi-square, G-square) kullanılarak seçilir. Gini ölçütü her adımda en büyük veri kümesini elde eder. Böylece en iyi bölme durumu elde edilmiş olur. Ayrıca bölme işleminden sonra ilgilenilmeyen kısım tek başına bırakılmış olur. Twoing ölçütü ise, Gini' ye göre daha dengeli bir yapı sunar. Bunun nedeni ise her defasında ana ve alt düğümlerin %50' sini içermeye çalışmasıdır. Bundan dolayı Gini' ye göre daha yavaştır.

b. Ağaç budama

Maksimum ağaç yapıldıktan sonra bu ağaç aşırı öğrenme (overfitting) eğilimi göstermektedir. Yani CART algoritması, herhangi bir durma kuralı olmaksızın sürekli olarak bölünerek büyümektedir. Diğer modelleme yöntemlerinde olduğu gibi ağacın karmaşıklığı ve tahmin gücü arasında denge sağlamak için budama işlemi gerekmektedir. Artık yeni bir bölünmenin gerçekleşmeyeceği durumda, bu sefer, uçtan köke doğru budama işlemi başlatılır. Budama işlemi esnasında maksimum ağaçtan türetilen bir seri daha küçük alt ağaçlar arka arkaya gelen uç dallardan elde edilmekte böylece farklı alt ağaçlar en uygun olanla karşılaştırılmaktadır.

c. Optimum ağacın seçimi

Elde edilmiş alt ağaçlar arasından optimal olan seçilmek zorundadır. Bu seçim işlemi tahmin hatasının değerlendirilmesi üzerine kuruludur. Tahmin hatası ise çapraz geçerlilik testi kullanılarak değerlendirilmektedir. Optimal karar ağacı, her ağaç

budama sonrasında, seçilen bir test verisi kullanılarak belirlenmeye çalışılır (Yavuz & Çilengiroğlu, 2020).

CART Algoritmasının bazı avantajları aşağıda verilmiştir (Crisci, Ghattas, & Perera, 2012) :

- CART, çıktıdaki aykırı değerlerin etkilerine karşı dayanıklıdır. Bu tür gözlemler genellikle ağacın geri kalanını etkilemedikleri düğümlerde izole edilir.
- Ağaçlar karışık değişken tiplerini ve eksik değerleri işleyebilir.
- CART, modelde tanımlanan her açıklayıcı değişken için bir önem indeksi verir.
- CART, karmaşık yapılara sahip veri kümeleriyle başa çıkabilir ve küme karmaşıklığı arttıkça alternatif yöntemlere göre daha güçlüdür.
- CART, X bir zaman serisi veya bir sinyal olduğunda fonksiyonel veri analizi bağlamında da kullanılabilir.


3.7 İstatistiksel Süreç Kontrol Grafikleri ve Shewhart Kontrol Grafiği

İstatistiksel kalite kontrol grafikleri, istatistiksel süreç kontrolü (SPC) kapsamında yaygın kullanılan süreç izleme aracıdır. Kusurlu veya uygun olmayan ürünlerin ortaya çıkmaması için önleyici aksiyonların alınmasına yardımcı olan değişkenlik tanımlamaları ile sürecin kontrol altında tutulmasına yardımcı olur. Kontrol grafikleri ilk olarak 1920'lerde Walter A. Shewhart tarafından geliştirilmiştir.

Kontrol grafikleri, izlenen süreç karakteristiklerinin istikrarlı olmasını sağlamak için süreç değişkenliğinin azaltılmasına yönelik bir problem çözme aracıdır. Süreçteki açıklanamayan değişkenliğin azaltılması ile performansın zaman içerisinde sürekli olarak iyileştirilmesi amaçlanır. Doğal süreç değişkenliğinin belirlenmesi ile süreçte meydana gelebilecek normal dışı değişikliklerin kısa sürede tespit edilebilmesine (sinyal verilmesine) olanak tanır (De Vries & Reneau, 2010).

Şekil 3.9'da tipik bir kontrol grafiği örneği verilmiştir. Grafikte, kontrol altındaki duruma karşılık gelen ve kalite karakteristiğinin ortalama değerini temsil eden bir merkez çizgisi bulunur. Üst kontrol limiti (UCL) ve alt kontrol limiti (LCL) olarak adlandırılan diğer iki yatay çizgi de grafikte gösterilmiştir. Bu kontrol limitleri, süreç kontrol altındaysa neredeyse tüm örneklem noktaları iki çizginin arasında kalacak şekilde seçilir. Noktalar kontrol sınırları içinde olduğu sürece, sürecin kontrol altında olduğu varsayılır ve

herhangi bir işlem yapılması gerekmez. Bununla birlikte, kontrol sınırlarının dışında çizilen bir nokta, sürecin kontrolden çıktığının kanıtı olarak yorumlanır ve bu davranıştan sorumlu olan belirlenebilir nedeni veya nedenleri bulmak ve ortadan kaldırmak için araştırma ve düzeltici faaliyet gereklidir. Nokta dizisinin zaman içinde nasıl geliştiğini görselleştirmenin daha kolay olması için, kontrol tablosundaki gözlem noktalarını düz çizgi ile birleştirmek yaygın bir kullanımdır (Montgomery, 2020).



Şekil 3.9 Tipik Bir Kontrol Grafiği Örneği

Kontrol grafikleri için genel bir model şu şekilde tanımlanabilir:

$$UCL = \mu_w + L\sigma_w$$

$$\text{Merkez çığı} = \mu_w$$

$$LCL = \mu_w - L\sigma_w$$

Bu modelde w ilgilenilen kalite özelliğini ölçen bir istatistik olup, μ_w bu özelliğin ortalamasını, σ_w ise bu özelliğin standart sapmasını simgeler. Bu durumda L merkez çizgisinden olan uzaklığı ifade eden standart sapma birimi olarak ifade edilir ve artı yönlü mesafe üst kontrol limitini oluştururken eksi yönlü sapma alt kontrol limitini oluşturur. Kontrol grafiklerinin bu genel teorisi ilk olarak Walter A. Shewart tarafından önerilmiştir ve bu prensiplere göre geliştirilen kontrol grafiklerine genellikle Shewhart kontrol grafikleri denir (Montgomery, 2020).

Shewhart tarafından geliştirilen kontrol grafikleri, çok çeşitli endüstrilere ve süreçlere uygulanmıştır. Her ne kadar farklı kontrol grafikleri geliştirilmiş olsa da, Shewhart kontrol grafikleri süreçlerdeki değişimleri izlemek için kullanılan en yaygın araçlardır. Bunun en önemli iki nedeni, bu kontrol grafiklerinin basit olması ve çoğu süreç ölçümünün ortalamasının yaklaşık olarak istatistiksel normal dağılımı takip etmesidir (Abbasi, Miller, & Riaz, 2013).

Kontrol grafikleri tasarlanırken kontrol limitlerinin belirlenmesi önemli bir karardır. Kontrol limitleri merkez çizgisinden çok uzağa yerleştirildiğinde belirli bir nedenden kaynaklı olmayan, bir noktanın kontrol limitleri dışında kalma riski (tip I hata) azalmış olur. Diğer taraftan, gerçekten kontrolden çıkmış bir sürece ilişkin noktanın kontrol limitleri içerisinde kalma riski de (tip II hata) artacaktır. Kontrol limitleri merkez çizgisine yaklaştırılırsa da tam tersi bir durum yaşanıp, tip I hata riski artacak ve tip II hata riski azalacaktır. Dolayısıyla, kontrol limitlerinin belirlenmesi, bir kontrol grafiği tasarlanırken alınması gereken kritik kararlardan biridir. Uygulamada iyi sonuçlar vermesinden dolayı genellikle Shewhart kontrol limitlerinde $L = 3$ kullanılır.

Kontrol grafikleri uygulamaya alınırken Faz I ve Faz II olmak üzere iki farklı aşamada oluşturulur. Faz I'de çalışmaya konu olan özellik ile ilgili veri toplanır ve geriye dönük analizi gerçekleştirilir. Verilerin toplandığı süre boyunca sürecin kontrol altında olup olmadığını görmek için deneme kontrol limitleri oluşturulur ve gelecek veriler için güvenilir olup olmadığına karar verilir. Faz I'deki kontrol grafikleri, öncelikle işletme personeline süreci istatistiksel kontrol durumuna getirmede yardımcı olur. Faz II, kararlı koşullar altında toplanan ve kontrol altındaki süreç performansını temsil eden "temiz" bir işlem verisi setine sahip olduktan sonra başlar. Faz II'de, tarihsel olarak birbirini takip eden her gözleme grafikte yer verilerek karşılaştırma yapılır ve süreç izlenir (Montgomery, 2020).

Ortalama tespit uzunluğu (ARL), kontrol grafiklerinin performansını değerlendirmek için kullanılan en yaygın performans metriğidir. Performans, iki ARL değeri ile değerlendirilebilir:

- ARL_0 : süreç kontrol altındayken kontrol grafiği tarafından kontrol dışı bir sinyal verilene kadar grafikte çizilen ortalama nokta sayısıdır.

- ARL_1 : süreç ortalamasında kayma görüldükten sonra kontrol grafiği tarafından kontrol dışı bir sinyal verilene kadar grafikte çizilen ortalama nokta sayısıdır (Abbasi, Miller, & Riaz, 2013).

3.7.1 Model Tahmin Hatalarının Kontrol Grafiklerinin Performansına Etkisi

Kontrol grafiklerine dayalı izlemede yaygın olarak kontrol altındaki sürece ilişkin olasılık dağılımının parametrelerinin bilindiğini varsayılmaktadır. Pratikte bu genellikle, dağılımın kontrol altındaki sürece ilişkin örneklerden tahmin edildiği ve tahmin hatasının göz ardı edildiği anlamına gelir. Tahmin hatasının kontrol grafiklerinin performansı üzerinde önemli bir etkisi vardır. Gandy ve Kvaløy (2013), farklı kontrol grafikleri ve performans ölçümleri için geçerli olan, tahmin hatasını dikkate alan, bootstrap tabanlı bir yöntem sunmuştur. Buna göre, kontrol altındaki sürecin ortalama tespit uzunluğunun belirli bir değerin altında/üstünde olmadığını yüksek olasılıkla garanti etmek için kullanılan kontrol grafiğinin kontrol limitleri ayarlanır.

Gandy ve Kvaløy, farklı performans ölçümleri ve hem parametrik hem de parametrik olmayan bootstrap prosedürleriyle bir dizi farklı grafik için bootstrap yöntemini uygulayan `spcadjust` adlı bir R paketi geliştirmiştir. Tekil tüm gözlemlerin normal dağıldığını varsayarak iki taraflı bir Shewhart kontrol grafiği ele alındığında, kontrol altındaki sürece ilişkin izlenecek karakteristik X 'in ortalama ve standart sapması n tane geçmiş gözlemden X_{-n}, \dots, X_{-1} tahmin edilir. Yeni gözlemler X_1, X_2, \dots için iki taraflı Shewhart grafiğinde gözlemin kontrolde olma durumu şu şekilde tanımlanır:

$$S_t = \frac{X_t - \hat{\mu}}{\hat{\sigma}}, \quad |S_t| > c$$

Kontrol altındaki sürece ilişkin izlenecek karakteristik belirlenen bir c eşik değeri (limit) için $|S_t| > c$ durumunda sinyal verir. Shewhart kontrol grafikleri için yaygın bir seçim, grafik doğru kontrol ortalaması ve standart sapma ile çalıştırılırsa üç standart sapmaya karşılık gelen $c = 3$ 'ü ayarlamaktır. Bölüm 4'te "İteratif Model Düzeltmeleri İle İş Emri Standart Üretim Süresi Tahmin Prosedürü'nün son adımı olan "Tahmin Hatalarının İzlenmesi İçin Düzeltmiş Shewhart Kontrol Grafiği ve İteratif Model Düzeltmesi" başlığında gerçekleştirilen uygulama ile sürecin izlenmesi ve kontrol dışı durumların tespitinin yapılması örnek grafikler ile verilmiştir.

4. ANALİZ

Bu bölümde metodolojide önerilen “İteratif Model Düzeltmeleri İle İş Emri Standart Üretim Süresi Tahmin Prosedürü”nün adımları, analiz ve sonuçları örnek bir çalışma üzerinden gerçekleştirilerek verilmiştir.

4.1 Çalışma Yapılacak İş İstasyonunun Belirlenmesi

Çalışmanın gerçekleştirildiği işletmede birçok farklı üretim tipinde istasyon mevcuttur. Seçilen iş istasyonu atölye tipi üretimin yapıldığı, neredeyse üretim yapılan tüm projelerin detay parçalarının işlem görmek için uğradığı bir iş istasyonudur. Farklı kabiliyetlerdeki tezgahlarda üretilen çoğunlukla metal parçalar ve yardımcı sanayilerden tedarik edilen parçalar montaj hatlarında kullanılmadan önce bu istasyona gelerek çapak alma işlemleri gerçekleştirilir. Çok farklı özelliklerde binlerce farklı parçanın üretiliyor olması ve sürekli olarak yeni parçaların gelmesi, iş emri standart üretim süresi belirlemede geleneksel yöntemlerin yetersiz kalmasına sebep olmaktadır. Bu sebeple tez çalışmasında önerilen prosedürün uygulanması için uygun bir istasyon olarak çapak alma istasyonu belirlenmiştir.

4.2 Belirlenen İş İstasyonunun Mevcut Durum Analizi

Çalışma yapılmak üzere seçilen çapak alma istasyonu ziyaret edilmiştir. Yerleşim planı, çalışma akışı, standart aktivitelerin belirlenmesi amacıyla üretim dokümanları incelenmiştir. Çalışma yapılacak olan iş istasyonu ile ilgili genel bilgiler aşağıda verilmiştir:

- Atölye tipi üretim uygulanmaktadır. Her teknisyen kendine ait bir çalışma masasında ve bu hücredeki ekipmanları kullanarak çalışmaktadır. Çalışma yapılacak parça teknisyen tarafından gelen alanından alınmakta ve çalışma masasında işi bitirilip giden alanına bırakılmaktadır.
- İki vardiyalık bir çalışma düzeni mevcuttur.
- Vardiyalarda çalışan sayısı değişmekle birlikte istasyonda toplam 10 teknisyen çalışmaktadır.
- İstasyonda çalışılacak parçaların planları vardiyalık olarak üretim planlama ve kontrol birimi tarafından verilmektedir. Verilen plan süreleri geçmiş parçaların üretim süreleri kullanılarak tanımlanmaktadır. Bu

yöntem literatür özetinde bahsedilen geçmiş kayıtların kullanılarak süre verilmesi yaklaşımıdır.

- Verilen üretim planlarına uyum yüzdeleri genellikle %85 ile %100 arasında değişmektedir.
- Çalışmaların başladığı tarihten itibaren gelecek bir yıl için istasyonda 4073 farklı parça için üretim ihtiyacı tanımlıdır. Bu parçalar için üretim miktarlarına bakıldığında 500613 adet üretilecek parça bulunmaktadır. Üretilecek parçalar 53 farklı projeye aittir. Üretilecek parçalar, miktarlar ve proje bilgileri sürekli olarak güncellendiği için bu veriler mevcut durum analizi yapılan tarih itibari ile alınmıştır.

4.3 İş İstasyonundaki Standart Üretim Aktivitelerinin Tanımlanması

İstasyonda üretilen parçaların üretim talimatları incelenmiş ve istasyondaki başteknisyen ve mühendislerden bilgi alınmıştır. Fiziksel olarak yapılan ziyaretler ve üretim dokümanları yardımı ile aşağıda verilen standart aktiviteler belirlenmiş ve yapılan gözlemlerle bu standart aktiviteler analiz edilmiştir.

İşçilik girme : Üretime başlamadan önce iş emrinde yer alan barkodun sisteme tanıtılarak üretimin başladığının kayıt altına alınması.

Parça taşıma: Üretimi gerçekleştirilecek iş emrinin gelen alanından alınarak çalışma masasına getirilmesi ve üretimi tamamlanan iş emrinin giden alanına bırakılması.

İş emri inceleme: Üretimi yapılacak iş emrine ait üretim dokümanının incelenmesi.

Paketten çıkarma/paketleme: Üretim masasına getirilen iş emrindeki parçaların dışında bulunan plastik veya kağıt ambalajın çıkarılması ve üretim tamamlandıktan sonra parçaların tekrar paketlenmesi.

Drill motor ile delik çapak alma: İş emrinde yer alan parçalardan üzerinde delik bulunanların (bağlayıcı montajı için kullanılan veya farklı sebeplerle açılmış olan delikler) şarjlı drill motor el aleti kullanılarak çapağının alınması.

Raspa ile delik çapak alma: İş emrinde yer alan parçalardan üzerinde delik bulunan fakat şarjlı drill motor el aletiyle çapağı alınamayan daha büyük delik ve boşluklara sahip parçaların raspa kullanılarak delik/boşluk çapaklarının alınması.

Yüzey çapak alma: İş emrinde yer alan parçaların kompleksliğine göre çok çeşitli el aletleri yardımıyla parçanın tüm yüzey çapak alma işlemlerinin gerçekleştirilmesi.

Markalama: Yüzey çapak alma işlemleri tamamlanan (üretimi tamamlanan) iş emrine ait parçaların bilgilerinin parçalara yazılması.

İş emrinin mühürlenmesi: Üretimi tamamlanan iş emrinin iş emri takip sistemine girilerek ilgili iş adımının tamamlandı statüsüne getirilmesi ve iş emrinin gelecek istasyona atanması.

4.4 İş İstasyonunda Gözlem Yapılması

Literatür araştırmasında bahsedilen gözlem yöntemlerinden biri olan video kayıt yöntemi ile iş emri üretimi incelenmiştir. FDR-AX33 4K Ultra HD Sony Handycam kamera ile, gözlem alma konusunda eğitilmiş uzmanlar tarafından seçilen iş emirleri baştan sona kayıt altına alınmıştır. Üretim planı dışında parça üretimi gerçekleştirilmesinin maliyetli olması ve iş istasyonunun yoğun üretim temposu sebebiyle, gözlem alınan iş emirleri çalışmanın yapıldığı tarih aralığında üretilen ve mümkün olduğunca farklı özelliklerde parça içeren iş emirleri arasından seçilmiştir. Bu şekilde üretim ve planlama sürecine maliyet oluşturmadan gözlem alınması sağlanmıştır. Kayıt altına alınan gözlemler bilgisayar ortamına aktarılmış ve böylece gözlem analizleri için gerekli ön çalışmalar tamamlanmıştır.

4.5 Gözlemlerin Analiz Edilmesi ve Aktivite Sürelerinin Çıkarılması

Video kayıtları bulunan gözlemler Timer Pro Professional programı kullanılarak Bölüm 4.3'te verilen standart aktivite kırılımlarına bölünmüştür. Gözlenen her iş emrinde üretilen parçalar için parça başına standart aktivite süreleri saniye bazında hesaplanarak program aracılığı ile MS Excel formatında kaydedilmiştir. Örnek Timer Pro Professional analiz görüntüsü ve MS Excel çıktısı Ek 1'de verilmiştir. Her gözlem için yazılım aracılığıyla durdur başlat yöntemi ile elde edilen aktivite süreleri "Bölüm 4.7 İş Emri Standart Üretim Süresi Model Parametrelerinin Tahmin Edilmesi" başlığında verilen istatistiksel analiz yöntemleri ile aktivitelerin standart aktivite süresi hesaplamasında kullanılmıştır.

4.6 İş Emri Standart Üretim Süresi Modelinin Tanımlanması

Bölüm 3.1 Adım 6'da verilen genel formül kullanılarak aşağıda verilen toplamsal tahmin modeli oluşturulmuştur. Modelde tempo %100 normal alınmıştır. İş istasyonu için

belirlenen ek paylar katsayısı için işletmenin daha önce gerçekleştirdiği iş örnekleme çalışmasının sonucu olan %16 değeri kullanılmıştır (Ek payların kapsamı Bölüm 2.1.2.1 Doğrudan Gözlem ile Zaman Etüdü başlığında verilmiştir.). Gözlemlerin analizi aşamasında metodolojide bahsedilen hazırlık ve çalışma süresini oluşturan aktivitelerin parça boyutları ile değiştiği tespit edilerek doğrulanmış ve de bu sebeple yüzey alanı 1 metrekareden küçük ve büyük parçalar için iki ayrı toplamsal model oluşturulmuştur. Burada genel tahmin modelimiz,

$$\hat{y}_i(p) = (\hat{s}_i + \hat{\beta}_i(p)x_i) \times t_i \times z_j$$

olup \hat{s}_i i . iş emri için toplam hazırlık süresi tahminini, $\hat{\beta}_i(p)$ i . iş emri için p parçasına bağımlı toplam çalışma süresi tahminini göstermektedir. Bölümün başında belirtilen bilgiler doğrultusunda $t_i = 1$ ve $z_j = 1,16$ alınmış olup, toplam hazırlık süresi ve toplam çalışma süresi,

$$\hat{s}_i = \sum_{k=1}^n \hat{a}_k \quad , \quad \hat{\beta}_i(p) = \sum_{l=1}^m \hat{b}_l(p)$$

olarak hesaplanmıştır.

Burada, \hat{a}_k ile i . iş emrine ilişkin k . hazırlık süresi tahmini, $\hat{b}_l(p)$ ile de p parçası için l . işlemin çalışma süresi tahmini gösterilmektedir. Örneğin, yüzey alanı 1 metrekareden küçük parçalar için toplamsal tahmin modeli,

$$\hat{y}_i(p) = ((\hat{a}_1 + \hat{a}_2 + \hat{a}_3 + \hat{a}_4 + \hat{a}_5 + \hat{a}_6) + (\hat{b}_1(p) + \hat{b}_2(p) + \hat{b}_3(p))x_i) \times t_i \times z_j$$

şeklinde ifade edilir. i . iş emri için hazırlık süresi,

$$\hat{s}_i = \sum_{k=1}^6 \hat{a}_k$$

çalışma süresi,

$$\hat{\beta}_i(p) = \sum_{l=1}^3 \hat{b}_l(p)$$

olur. Açıklanan formüldeki hazırlık süresini oluşturan parametreler aşağıda verilmiştir:

\hat{a}_1 : İşçilik girme süresinin tahmini

\hat{a}_2 : İş emri inceleme süresinin tahmini

\hat{a}_3 : İş emri mühürleme süresinin tahmini

\hat{a}_4 : Paketten çıkarma/paketleme süresinin tahmini

\hat{a}_5 : Markalama süresinin tahmini

\hat{a}_6 : Parça taşıma süresinin tahmini

Çalışma süresini oluşturan parametreler ise,

$\hat{b}_1(p)$ = İş emrindeki p parçasında bulunan delik sayısına bağımlı olan raspa ile delik çapak alma süresi tahminini

$\hat{b}_2(p)$ = İş emrindeki p parçasında bulunan delik sayısına bağımlı olan drill motor ile delik çapak alma süresi tahminini

$\hat{b}_3(p)$ = İş emrindeki p parçasına bağımlı yüzey çapak alma süresinin tahminini ifade eder. Sırasıyla, $\hat{b}_1(p)$ ve $\hat{b}_2(p)$,

$$\hat{b}_1(p) = g_i \times \hat{r}_1,$$

$$\hat{b}_2(p) = h_i \times \hat{r}_2$$

olup,

g_i : i . iş emrinde yer alan p parçasındaki raspa ile çapak alınması gereken delik sayısını

h_i : i . iş emrinde yer alan p parçasındaki drill motor ile çapak alınması gereken delik sayısını

\hat{r}_1 : Raspa ile delik çapak alma süresinin tahminini

\hat{r}_2 : Drill motor ile delik çapak alma süresinin tahminini

ifade eder.

Yüzey alanı 1 metrekareden büyük parçalar için ise toplamsal tahmin modeli,

$$\hat{y}_i(p) = ((\hat{a}_1 + \hat{a}_2 + \hat{a}_3) + (\hat{a}_4 + \hat{a}_5 + \hat{a}_5 + \hat{b}_1(p) + \hat{b}_2(p) + \hat{b}_3(p))x_i) \times t_i \times z_j$$

şeklinde ifade edilir.

Yüzey çapak alma süresinin p parçasına bağımlı tahmini $\hat{b}_3(p)$ ayrı bir model olarak ele alınmıştır ve bu amaçla kurulan tahmin modeli Bölüm 4.7'de verilmiştir.

İş emirlerinin izlenmesi için tahmin hataları

$$e_i = \hat{y}_i(p) - y_i(p)$$

kullanılacaktır. $e_i \sim N(0, \sigma_e^2)$ kabul edilmiştir.

4.7 İş Emri Standart Üretim Süresi Model Parametrelerinin Tahmin Edilmesi

Modelde yer alan bazı aktivite parametreleri parçanın özelliklerinden bağımsızdır. Bu süreler hazırlık süresi kapsamında Bölüm 4.6'da açıklanmıştır. Parçanın üzerindeki delik sayılarına bağlı olan delik çapak alma aktiviteleri ise direkt olarak parçanın delik sayısına bağlı olarak ele alındığından aktivite süresi hesaplanırken bir delik başına harcanan süre göz önüne alınarak hesaplanmıştır. Örneğin hazırlık süresi aktivitelerinden olan işçilik girme süresi her bir iş emri için bir kez yapılmaktadır ve alınan gözlemlerden elde edilen işçilik girme süreleri örneklerinin ortalaması alınarak ortalama iş emri girme süresi hesaplanır. Delik çapak alma sürelerinde ise bir delik için harcanan süre göz önüne alınarak, her bir parçadaki 1 delik için harcanan çapak alma süreleri ortalaması hesaplanır. Bölüm 4.5'te Timer Pro Professionals yazılımı kullanılarak her bir gözlem için aktivitelerin süresi hesaplanmıştır. Her bir gözlemden ortaya çıkan aktivite süreleri için Minitab istatistiksel analiz yazılımı kullanılarak örnek ortalamaları alınmış ve ortalama aktivite süreleri hesaplanmıştır. Ortalama değerler alınırken değişkenlik kontrolü yapılmış ve olağan dışı bir duruma rastlanmamıştır. Ayrıca toplamsal model içerisinde sabit olarak kullanılan bu tahmin değerlerinin model değişkenliğine olan etkisi, Bölüm 4.9'da detaylı bir şekilde verilen izleme yöntemi kapsamında dikkate alınmıştır. İş emri üretim aktivitelerinin ortalama değerleri,

$$\hat{a}_1 = 63,29 \text{ saniye}$$

$$\hat{a}_2 = 71,12 \text{ saniye}$$

$$\hat{a}_3 = 104,72 \text{ saniye}$$

$$\hat{a}_4 = 64,33 \text{ saniye}$$

$$\hat{a}_5 = 78,09 \text{ saniye}$$

$$\hat{a}_6 = 48,98 \text{ saniye}$$

$$\hat{r}_1 = 12,61 \text{ saniye}$$

$$\hat{r}_2 = 3,19 \text{ saniye}$$

olarak hesaplanmıştır ve analizde kullanılan Minitab yazılımı sonuçları ise Ek 2’de verilmiştir. Bu parametrelerin dışında kalan ve yüzey çapak alma süresinin p parçasına bağımlı tahmini olan $\hat{b}_3(p)$ ayrı bir model olarak ele alınarak, hem doğrusal regresyon hem de CART yöntemi ile modellenerek karşılaştırılmış ve en iyi sonucu veren doğrusal regresyon modeli kullanılmıştır. Model sonuçları ve karşılaştırmalar Bölüm 4.7.1’de verilmiştir.

4.7.1 Parça Yüzey Çapak Alma Süresinin Tahmini için Çok Değişkenli Doğrusal Regresyon ve CART Yöntemleri

Diğer parametrelerden farklı olarak yüzey çapak alma işlemi farklı özelliklerdeki parçalar için sabit birim süre olarak verilememektedir. Çapak alma işlemi incelendiğinde iş talimatında spesifik bir tanımın olmadığı ve genel bir açıklama ile “çapak alma işleminin gerçekleştirilmesi” olarak geçtiği görülmüştür. Çalışma yapılan iş istasyonundan geçen parçaların işletmenin veri tabanında kayıtlı malzeme bilgileri kullanılarak bir model oluşturulması amaçlanmış ve bunun için veri tabanından kayıtlar elde edilmiştir. Üretimi yapılan her parça için yüzey çapak alma süresini etkileyebilecek ve verisi tutulan ortak özellikler aşağıda verilmiştir:

1. Parçanın hangi projeye ait olduğu
2. Parçanın malzeme tipi
3. Parçanın boyutsal kodu
4. Parçanın tipi (üretim yöntemine göre)
5. Parçanın yüzey alanı (yok ise uzunluk/genişliği)

Metodolojide bahsedilen veri ön işleme yöntemleri kullanılarak tahmin modellerine girdi sağlayacak temiz veri elde edilmesi amaçlanmıştır. Veri ön işleme kapsamında veri tabanından elde edilen veri tablosu için gerçekleştirilen işlemler aşağıda verilmiştir.

- Veri tabanından elde edilen verinin doğruluğunun kontrol edilmesi (doğru tablolardan verilerin doğru bir şekilde aktığının teyit edilmesi),
- Gerekli olmayan sütunların (özelliklerin) çıkarılması (alan bilgileri kapsamında çekilen derinlik bilgisinin çıkarılması)
- Özelliklerin (sütunların) incelenmesi sonucu özelliklerin gruplanması ve ortaklaştırılması (tüm uzunluk birimlerinin mm’ye çevrilmesi)
- Alan bilgisi olmayan parçalar için uzunluk ve genişlik bilgileri kullanılarak alan hesabının cm^2 cinsinden yapılması,

- Boş kalan hücrelerin gözden geçirilerek doğru bilgiler ile doldurulması, bilgiye erişilemiyor ise daha sonra çalışılmak üzere veri setinden çıkarılması.

Tüm bu adımlar gerçekleştirildikten sonra artık modellemeye girdi oluşturabilecek temiz bir veri kümesi elde edilmiştir. Toplamsal tahmin modelinde kullanılmak üzere, parça başına yüzey çapak işlemlerinin süresinin tahmini için hem doğrusal regresyon modeli hem de CART kullanılmış ve sonuçları aşağıda verilmiştir.

CART Yöntemi ile Parça Yüzey Çapak Alma İşlemi Tahmini


Gözlemlerden elde edilen 93 parçanın parça başına yüzey çapak alma süresi ölçümleri yukarıda verilen parça özellikleri kullanılarak CART yönteminde girdi olarak kullanılmış ve parça yüzey çapak alma süresi tahmin modeli Minitab istatistiksel analiz yazılımında oluşturulmuştur. Sonuçlar Şekil 4.1, Şekil 4.2 ve Şekil 4.3'te verilmiştir. Analiz yapılırken varsayılan ayarlar Ek 3'te verilmiştir.

Method

Node splitting	Least squared error
Optimal tree	Within 1 standard error of maximum R-squared
Model validation	10-fold cross-validation
Rows used	93

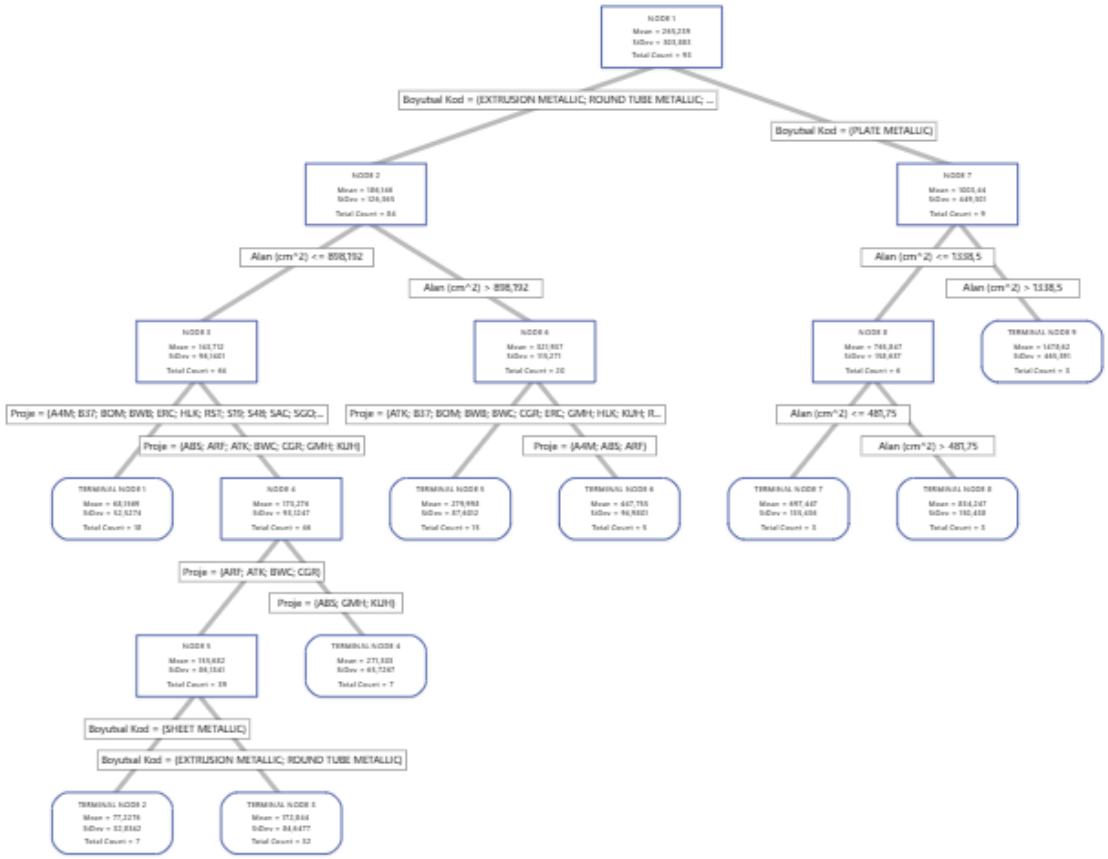
Response Information

Mean	StDev	Minimum	Q1	Median	Q3	Maximum
265,239	305,530	10,917	74,935	198,16	296,115	2136,78



Şekil 4.1 CART Metodu Uç Dğümler ve R-sq Deęerlerine Gre Alternatif Karar Aęaęları

Farklı sayıda uç dğümler için elde edilen Test R-squared deęerleri Şekil 4.1’de verilmiştir. Sonuçlara göre en yüksek R-squared deęeri 9 adet uç dğümden oluşan karar aęacına aittir. Bu alternatif karar aęacı da Şekil 4.2’de görölmektedir.



Şekil 4.2 En Yüksek R-sq Değerine Sahip 9 Düğümde Oluşan Karar Ağacı


Her bir uç düğüm için yaratılan düğüm kuralları Ek 4’te paylaşılmıştır. Yeni bir parçanın yüzey çapak alma süresi tahmin edilmek istendiğinde bu kurallar takip edilerek uygun olan dalın sonundaki uç düğümün ortalaması tahmin değerini verecektir.

Şekil 4.3’e bakıldığında eğitim R-sq değerinin %85,45, test R-sq değerinin %71,81 olduğu görülmektedir. Test için Minitab içerisinde bulunan “k-fold cross validation” kullanılmıştır. Bu sonuçlara göre CART yöntemi ile oluşturulan modelin değişkenliğin %71,81’ni açıklayabileceği öngörülmüştür. Değişkenliğin göreceli önem yüzdelerine göre en önemli değişken “Boyutsal Kod”dur. Boyutsal kod değişkenini önem derecesi azalan sıra ile %77,7 ile “Alan”, %49,6 ile “Proje”, %2,3 ile “Parça Tipi” ve %1,1 ile “Malzeme Tipi” izlemektedir. Bu sonuçlara göre “Parça Tipi” ve “Malzeme Tipi” değişkenlerinin yanıt üzerinde etkisinin olmadığını ve diğer değişkenlerin ise anlamlı etkisinin olduğunu söylemek mümkündür.

Model Summary

Total predictors	5
Important predictors	5
Number of terminal nodes	9
Minimum terminal node size	3

Statistics	Training	Test
R-squared	85,45%	71,81%
Root mean squared error (RMSE)	115,9182	161,3469
Mean squared error (MSE)	13437,0277	26032,8324
Mean absolute deviation (MAD)	75,2655	102,4653
Mean absolute percent error (MAPE)	0,5847	0,7402



Variable importance measures model improvement when splits are made on a predictor. Relative importance is defined as % improvement with respect to the top predictor.

Şekil 4.3 CART Model Özeti ve Değişkenlerin Göreceli Önem Yüzdeleri

Çok Değişkenli Doğrusal Regresyon Yöntemi ile Parça Yüzey Çapak Alma İşlemi Tahmini

CART yönteminde kullanılan 93 adet gözlem çok değişkenli regresyon ile de Minitab istatistiksel analiz yazılımı kullanılarak analiz edilmiş ve sonuçlar Şekil 4.4'te verilmiştir.

Method

Categorical predictor coding (1; 0)

Stepwise Selection of Terms

α to enter = 0,15; α to remove = 0,15

Regression Equation

Yüzey İşlem Süresi (sn) = 139,7 + 0,1046 Alan (cm²) + 0,0 Boyutsal Kod_EXTRUSION METALLIC + 699,6 Boyutsal Kod_PLATE METALLIC - 58,7 Boyutsal Kod_ROUND TUBE METALLIC - 85,1 Boyutsal Kod_SHEET METALLIC

Coefficients

Term	Coef	SE Coef	95% CI	T-Value	P-Value	VIF
Constant	139,7	22,2	(95,6; 183,8)	6,30	0,000	
Alan (cm ²)	0,1046	0,0138	(0,0770; 0,1321)	7,55	0,000	1,16
Boyutsal Kod						
PLATE METALLIC	699,6	53,6	(593,2; 806,1)	13,06	0,000	1,12
ROUND TUBE METALLIC	-58,7	47,0	(-152,1; 34,7)	-1,25	0,215	1,11
SHEET METALLIC	-85,1	38,2	(-161,1; -9,1)	-2,23	0,029	1,15

Model Summary

S	R-sq	R-sq(adj)	PRESS	R-sq(pred)	AICc	BIC
144,082	78,73%	77,76%	2411146	71,92%	1196,25	1210,47


Analysis of Variance

Source	DF	Seq SS	Contribution	Adj SS	Adj MS	F-Value	P-Value
Regression	4	6761196	78,73%	6761196	1690299	81,42	0,000
Alan (cm ²)	1	2480547	28,88%	1184043	1184043	57,04	0,000
Boyutsal Kod	3	4280649	49,84%	4280649	1426883	68,73	0,000
Error	88	1826859	21,27%	1826859	20760		
Lack-of-Fit	81	1306704	15,22%	1306704	16132	0,22	1,000
Pure Error	7	520156	6,06%	520156	74308		
Total	92	8588055	100,00%				

Şekil 4.4 Çok Değişkenli Doğrusal Regresyon Yöntemi ile Parça Yüzey Çapak Alma Süresi Tahmin Modeli

Regresyon modeli oluşturulurken “stepwise” yöntemi kullanılmış olup giriş ve çıkış α değerleri 0,15 olarak minitab yazılımının varsayılan değeri kullanılmıştır. (Yapılan denemelerde giriş ve çıkış değerleri olarak 0,05 ve 0,10 da denenmiş olup regresyon modelinde bir değişikliğe sebep olmadığı görülmüştür.) Regresyon modeli sonuçları

incelendiğinde R-sq(pred) değerinin %71,92 olduğu görülmüştür. Modelde girdi olarak kullanılan değişkenlerden sadece ikisi “Alan” ve “Boyutsal Kod” istatistiksel olarak anlamlıdır. Artıklar için oluşturulan grafikler Şekil 4.5’te verilmiştir. Grafiklere bakıldığında regresyon doğrusundan sapan bir değer olduğu görülmektedir. Bu durum regresyon analizinde sabit varyans varsayımından sapmaya yol açabilecektir ve istatistiksel testlerin sonuçlarının yorumlanmasında dikkate alınmalıdır. Yapılan incelemeler sonucunda bu değer her hangi bir hata ve anormal bir durumdan kaynaklanmadığı tespit edilmiştir. Değer çıkarılmasıyla yapılan analizler incelendiğinde model açıklayıcılığının %1’lik bir artış göstermesine karşılık, modele girdi olarak ilaveten “Parçanın hangi projeye ait olduğu” bilgisini veren proje bilgisini alarak 3 değişkene bağlı bir model oluşturduğu ve R-sq prediction değerini vermediği görülmüştür. Oluşturulan bu modelin sadece gerçekleştirilem gözlemlerdeki proje bilgisine göre olması ve iş istasyonundaki gözlemi olmayan diğer projeler için gözlem ihtiyacını doğurarak harcanacak iş gücünü önemli ölçüde artırması ve anlamlı bir katkı sağlamaması sebebiyle denemeler sonucunda kurulan model ile devam edilmesi ve sapan değer çıkarılmayarak modelde tutulmasına karar verilmiştir. Hem regresyon modeli hem de toplamsal tahmin modelinde yer alan diğer tahmin parametrelerinin değişkenlikleri model performansını izleme aşamasında göz önüne alınarak izleme ve kontrolü bu adımda sağlanmıştır.



Şekil 4.5 Çok Değişkenli Doğrusal Regresyon Yöntemi Modeli Artıklar Grafikleri

CART ve çok deęişkenli doğrusal regresyon modelleri karşılaştırdığında ise %0,11 gibi az bir farkla regresyon modeli daha iyi bir tahmin performansı vermektedir. Bu, tahmin gücü anlamında çok anlamlı bir fark olarak görülmemektedir. Bunun yanı sıra CART modelinde 3 adet girdi deęişkeni bulunurken (Boyutsal kod, Alan, Proje) regresyon modelinde iki adet girdi deęişkeni (Boyutsal kod, Alan) bulunmaktadır. Böylece regresyon modeli yüzey çapak alma işleminin süresini tahmin ederken proje bilgisinden bağımsız olarak çalışacağından kullanılabilirlik ve sürdürülebilirlik bakımından daha uygun bulunmuştur. Ayrıca proje bilgisi sadece eldeki 93 adet gözlemden elde edildiğinden, gözlem setinde olmayan veya her yeni proje için veri toplayıp analiz ederek ağacı geliştirmek gerekeceğinden uzun vadede çok daha maliyetli olacaktır. Bu sebeplerden dolayı Bölüm 4.6’da verilen toplamsal tahmin modelindeki $\hat{b}_3(p)$ (p parçasının yüzey çapak alma süresinin tahmini) parametresi regresyon yöntemiyle hesaplanmış ve parçanın alan ve boyutsal kod (çalışma extrusion metallic, plate metallic, round tube metallic ve sheet metallic olmak üzere 4 farklı boyutsal kod içermektedir) olmak üzere iki farklı deęişken bilgisi üzerine kurularak Şekil 4.4’te verilen tahmin modeli:

$$\hat{b}_3(p) = 139,7 + 0,1046\theta_i(p) + 0,0\gamma_i(p)_1 + 699,6\gamma_i(p)_2 - 58,7\gamma_i(p)_3 - 85,1\gamma_i(p)_4$$

oluşturulmuştur. Burada,

$\theta_i(p) = i.$ iş emrindeki p parçasının cm^2 cinsinden alanı

$\gamma_i(p)_1 = i.$ iş emrindeki p parçasının boyutsal kodunun

extrusion metallic olması, $\gamma_i(p)_1 = \{0,1\}$

$\gamma_i(p)_2 = i.$ iş emrindeki p parçasının boyutsal kodunun

plate metallic olması, $\gamma_i(p)_2 = \{0,1\}$

$\gamma_i(p)_3 = i.$ iş emrindeki p parçasının boyutsal kodunun

round tube metallic olması, $\gamma_i(p)_3 = \{0,1\}$

$\gamma_i(p)_4 = i.$ iş emrindeki p parçasının boyutsal kodunun

sheet metallic olması, $\gamma_i(p)_4 = \{0,1\}$

olarak ifade edilir. $\hat{b}_3(p)$ parametresinin de tahmin edilmesi ile toplamsal model içerisinde yer alan tüm girdi parametrelerinin tahmini elde edilmiş olur.

4.8 İş Emri Standart Üretim Süresinin Hesaplanması

Bölüm 4.7’de istatistiksel yöntemlerle hesaplanan model parametreleri, iş emri standart üretim süresi toplamsal tahmin modeline yerleştirilerek $\hat{y}_i(p)$ hesaplanır. Çalışmanın yapıldığı işletmede üretime ve iş emirlerine ait veriler kurumsal veritabanlarında tutulmaktadır. İşletmenin kurumsal veri tabanlarında bulunan ve toplamsal tahmin modelinde iş emri üretim süresini tahmin etmek için kullanılacak verilere ulaşmak için Microsoft SQL Server Management Studio kullanılarak sorgu yazılmıştır. Toplamsal tahmin modelini oluşturan tüm girdiler sorguya aktarılmış ve sonuçlar elde edilmiştir. Ayrıca bir sonraki adım olan izleme aşamasında kullanılan iş emri üretim süresi gerçekleştirmeleri de yine veritabanlarından sorgu ile elde edilerek karşılaştırma için gerekli olan tahmin ve gerçekleşme verileri sağlanmıştır.


4.9 Tahmin Hatalarının İzlenmesi İçin Düzeltilmiş Shewhart Kontrol Grafiği ve İteratif Model Düzeltmesi

Planlama ve üretim süreçlerini zaman içerisinde izlemek ve bunları iyileştirmek amacıyla kontrol grafikleri çalışmada ele alınmıştır. Gerçekleşen ile toplamsal olarak modellenen üretim süreleri arasındaki fark tahmin hatasıdır. Bu kapsamda, bir kontrol grafiği ile tahmin hatalarının izlenmesi önerilmektedir. Tahmin hatalarının belirlenen bir normalden sapmaları kontrol grafiği ile tespit edilerek süreçlerde veya modelde meydana gelebilecek değişiklikler belirlenecektir. Kontrol grafiğinin tasarımında, tahmin hatalarının normalinin tanımlanmasında bunların ortalaması ve varyansı kullanılacaktır. Ancak, ortalama ve varyans tahminlerinin de rastgele değişkenler olması dolayısıyla kontrol grafiği limitlerinin bir ortalama tespit uzunluğu performans metriği değerine göre belirlenmesinde standart uygulamalardan farklı olarak düzeltme gereklidir.

Önerilen iş emri üretim süresi tahmin algoritmasının son adımı olan performans izleme ve gerekli görülmesi durumunda tahmin modelinin iyileştirilmesi adımları geleneksel yaklaşımların aksine iteratif bir yaklaşımla, düzeltilmiş Shewhart kontrol grafiği uygulaması ile ele alınmıştır. Uygulama çalışmasında gerçekleştirilen hesaplar, “R Studio 4.1.2” yazılımı ve “spcadjust” kütüphanesi kullanılarak gerçekleştirilmiştir. Toplamda 130 adet parça üretimi iş emri ile çalışılmış ve sürekli olarak devam edecek olan kontrol ve iteratif iyileştirme sürecinin bir kesiti paylaşılmıştır.

Model 1 Artıkları ve Kontrol Grafiği

Üretimi gerçekleştiren iş emirlerinden ilk 55 adedi tahmin edilmiş ve gerçekleşen süreler ile farkları alınarak her bir iş emri için artıklar elde edilmiştir. İş emri 1-55 arası elde edilen tahmin hataları (artıklar) Şekil 4.6’da gösterilmektedir.

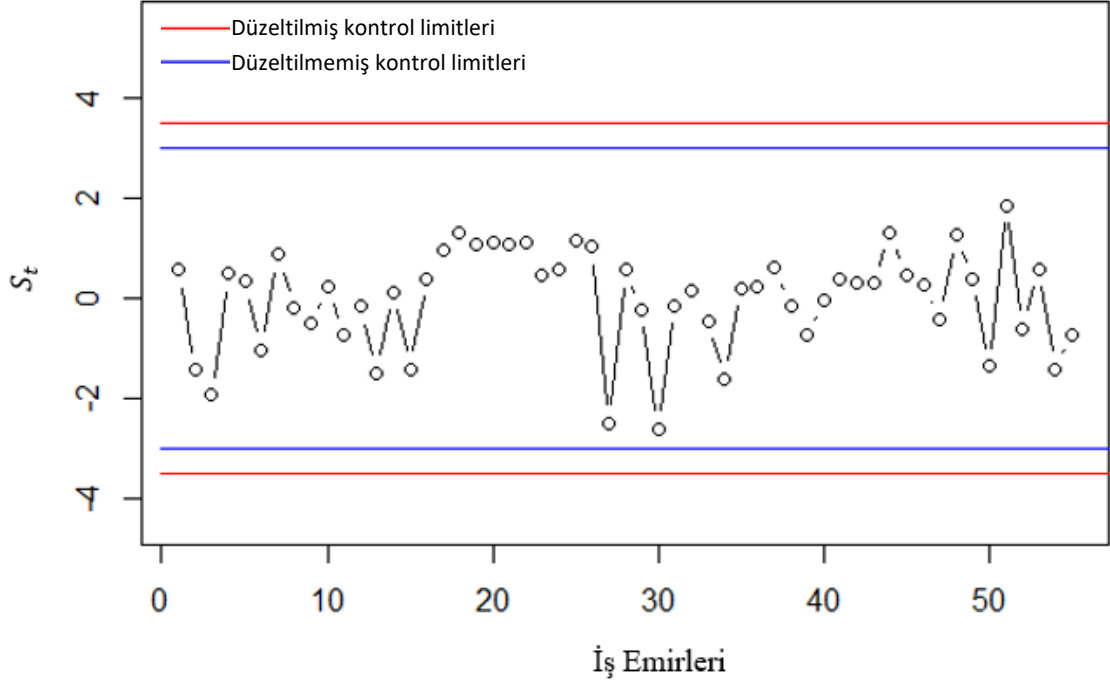


Şekil 4.6 İlk 55 İş Emri İçin Artıklar Grafiği (Tahmin-Gerçekleşme Süresi)

Faz I olarak adlandırılan ilk aşamada tahmin hatalarının normalinin belirlenmesi için bu 55 artık değeri kullanılmıştır. Kontrol grafiğinin belirlenen bir ortalama tespit uzunluğu performansının sağlanması için de (Gandy & Kvaløy, 2017)’un kontrol grafiğinin parametre (tahmin hatalarının ortalaması ve varyansı) tahminlerindeki hatayı hesaba katan yaklaşımı 500 bootstrap tekrarı yapılarak ve %95 güven seviyesinde kullanılmıştır. Hesaplamalara göre, bu yaklaşım dikkate alınmadığında standart 3σ kontrol limitlerinin kullanılması durumunda ortalama tespit uzunluğu 82.22 olacaktır ve bu da kontrol grafiğinin uygulamada sık olarak değerlendirilebilecek yanlış sinyal vereceğine işaret etmektedir. (Gandy & Kvaløy, 2017)’un tahmin hatalarını hesaba katan yaklaşımı ile hesaplama yapıldığında, $3,51 \hat{\sigma}$ kontrol limitleri kullanıldığında ortalama tespit uzunluğu 370 değerine (bu değer genel olarak kabul görmüş olduğu için seçilmiştir) çıkarılabilecek ve böylece yanlış sinyaller azaltılabilecektir. Bu hesaplamalar için R Studio yazılımında kullanılan “Script” ve sonuçlarının yer aldığı “Console” verileri Ek 5’te verilmiştir.


Şekil 4.7’de yer alan grafikte, artıklar ve Shewhart kontrol limitleri düzeltilmiş ve düzeltilmemiş durumları için gösterilmiştir. Düzeltilmiş kontrol limitleri içerisinde yer

alan tahmin hataları normal olarak kabul edilecektir, ancak bu limitlerin dışına çıkacak bir tahmin hatası süreçte veya modelde olağan dışı bir duruma işaret edecektir.

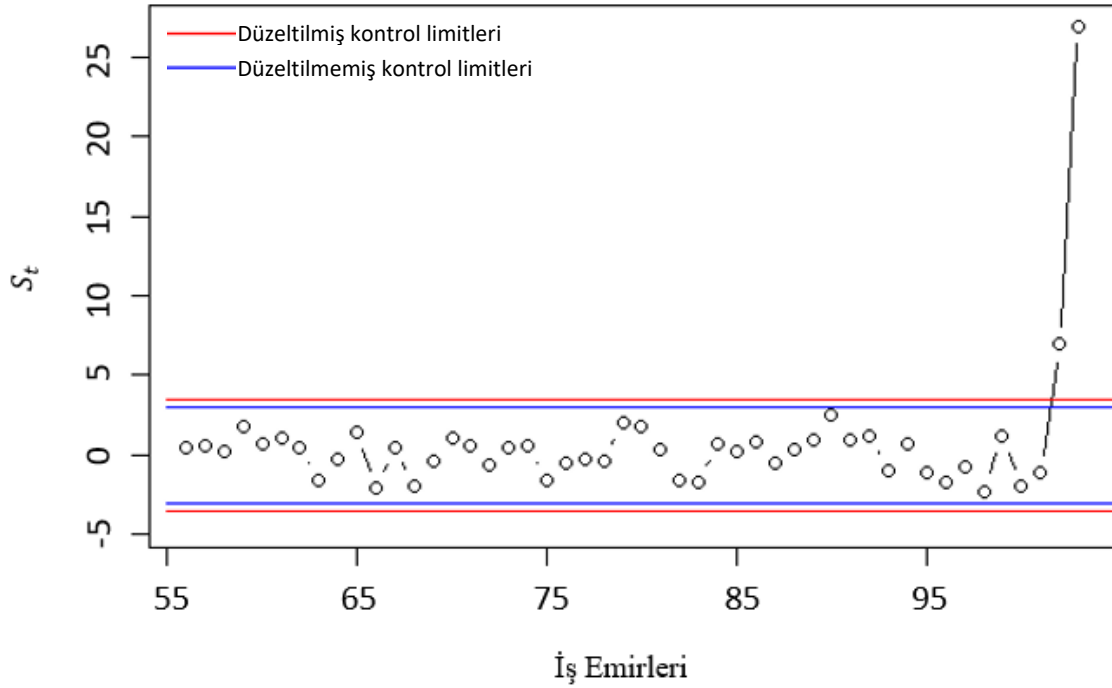


Şekil 4.7 İlk 55 İş Emri İçin Shewhart Kontrol Grafiği

İlk 55 artık ile kontrol grafiği tasarlandıktan sonra, devamındaki iş emirlerinin üretim süreleri bu limitler ile izlenmiştir. 56-103 arası iş emirleri için artıklar ve kontrol grafiği sırasıyla Şekil 4.8 ve Şekil 4.9’da, R Studio script ve console bilgileri Ek 6’da verilmiştir. İzleme başladıktan sonra ilk sinyal 102. iş emrinde, ikinci sinyal de hemen ardından 103. İş emrinde görülmüş ve bu iki iş emri incelenmiştir.



Şekil 4.8 56-103 Arası İş Emirleri İçin Artıklar Grafiği



Şekil 4.9 56-103 Arası İş Emirleri İçin Shewhart Kontrol Grafiği

Yapılan incelemeler sonucunda 102. iş emrinin son bir yıllık üretim süresi ortalamasından yaklaşık %500 gibi bir oranla saptığı ve üretim alanında yapılan değerlendirmeler sonucunda da bu durumun sisteme toplu üretim süresi girilirken hatalı girilmesi sonucu olduğu tespit edilmiştir. Önerilen tahminleme algoritmasında bu sinyal süreç iyileştirme ve standartlaştırma çalışmalarının gerektiğine işaret etmektedir. Bu sebeple 102. iş emrinde yer alan parçaya ilişkin ölçümler yapılarak modelin güncellenmesi ihtiyacı

görülmemiştir. 103. iş emrine ilişkin sinyalin değerlendirilmesi için yine geçmiş ortalama işçilikleri incelenmiş, üretim süresinin doğru, model hatasının yüksek olduğu değerlendirilmiştir. Regresyon modelinde kullanılan “Boyutsal Kod” ve “Alan” bilgilerine bu iş emrine ilişkin parça için bakıldığında, modelde “plate metallic” boyutsal koda sahip parçaların “Alan”larının büyük olduğu ve söz konusu parçanın alanının oldukça küçük olduğu, bu sebeple de modelin bu parçaya ait iş emri süresini tahmin etmede düşük performans gösterdiği değerlendirilmiştir. Dolayısıyla, bu parçaya ilişkin ölçümlerin yapılarak regresyon modelinin güncellenmesi kararlaştırılmış, parçaya ilişkin üretim video kayıt alınarak incelenmiş ve ölçüm regresyon modeline ek bir gözlem olarak koyularak model güncellenmiştir. Güncellenen model Şekil 4.10’da verilmiştir.

Model Summary			
S	R-sq	R-sq(adj)	R-sq(pred)
156,817	74,53%	73,38%	66,59%

Coefficients					
Term	Coef	SE Coef	T-Value	P-Value	VIF
Constant	134,3	24,1	5,57	0,000	
AREA3 (CM2)	0,1127	0,0149	7,56	0,000	1,14
DIMENSIONCODE2					
PLATE METALLIC	629,5	55,4	11,37	0,000	1,11
ROUND TUBE METALLIC	-53,7	51,1	-1,05	0,297	1,11
SHEET METALLIC	-89,9	41,6	-2,16	0,033	1,15

Regression Equation	
PB Yüzey İşlemleri	= 134,3 + 0,1127 AREA3 (CM2) + 0,0 DIMENSIONCODE2_EXTRUSION METALLIC + 629,5 DIMENSIONCODE2_PLATE METALLIC - 53,7 DIMENSIONCODE2_ROUND TUBE METALLIC - 89,9 DIMENSIONCODE2_SHEET METALLIC

Şekil 4.10 Güncellenen Parça Yüzey Çapak Alma Süresi Tahmin Formülü Minitab Çıktısı


Model Güncellemesi Sonrası Kontrol Grafikleri

Gerçekleşen üretim sürelerinin ilk 55 tanesi ile kontrol limitleri belirlenmiş, sonraki 48 iş emri bu limitler kullanılarak izlenmiş ve toplamda 103 iş emri verisinden 102. ve 103. iş emirleri için kontrol dışı durum sinyali alınarak yukarıda belirtilen çalışmalar gerçekleştirilmiştir. 103. İş emrinde yer alan parça özellikleri ile regresyon modeli


güncellendikten sonra eldeki toplamda 101 adet kontrol altındaki duruma ilişkin artıklar kullanarak kontrol limitleri tekrar hesaplanmıştır.

İlk kurulan model sonucu ortaya çıkan artıklardan hesaplanan kontrol limiti genişliği $3,51\hat{\sigma}$ iken güncellenmiş model sonucu ortaya çıkan artıklardan hesaplanan yeni limit genişliği $3,445\hat{\sigma}$ olmuştur. Güncelleme öncesi daha geniş bir aralıkta kontrol içi durum izlenirken artık daha dar bir aralıkta incelenmeye başlanmıştır.


104-130 arası iş emirlerinin izleme sonuçları hem başlangıç modeli (model 1) ile (Şekil 4.11 ve Şekil 4.12) hesaplanan kontrol limitleri kullanılarak, hem de güncellenen regresyon modeli sonrasında (Şekil 4.13 ve Şekil 4.14) elde edilen yeni artıklar ve kontrol limitleri ile sunulmuştur. R Studio script ve console bilgileri Ek 7’de verilmiştir.



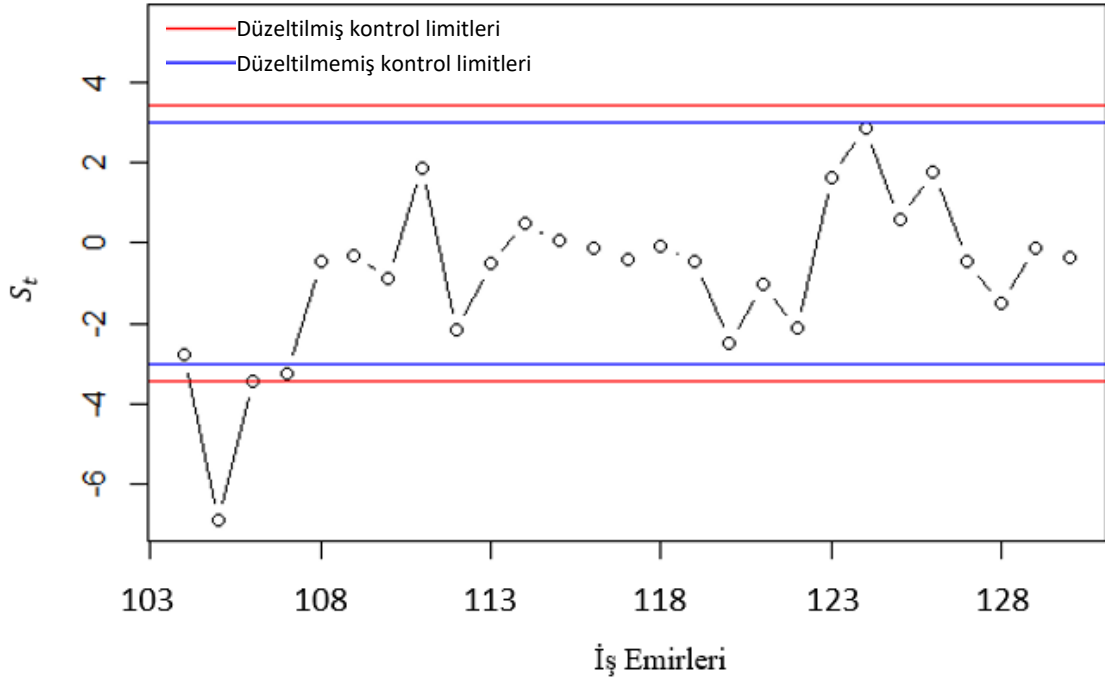
Şekil 4.11 104-130 Arası İş Emirleri Model 1 İçin Artıklar Grafiği



Şekil 4.12 104-130 Arası İş Emirleri İçin Model 1 Shewhart Kontrol Grafiği



Şekil 4.13 104-130 Arası İş Emirleri Güncellenen Model İçin Artıklar Grafiği



Şekil 4.14 104-130 Arası İş Emirleri Güncellenen Model İçin Shewhart Kontrol Grafiği

Şekil 4.12'deki eski model ile kurulan kontrol grafiğine bakıldığında 105., 106., 107. ve 124. iş emri için kontrol limitleri dışında kaldığı ve sinyal durumu olduğu görülmektedir. Şekil 4.14'te ise 103. gözlem ile güncellenen yeni model sonrası kurulan kontrol grafiğindeki yeni limitler ile bu sinyallerden sadece 105. gözlemin sinyal olarak kalmaya devam ettiği görülmüştür. Modelin kapsayıcılığının artması ile birlikte kontrol dışı kalan gözlemlerden ikisi kontrol limitleri içerisine girmiş ve süreç kontrolü artırılmıştır. Yapılan örnek çalışmadaki 105. gözlem incelendiğinde aynı parça için geçmiş iş emirleri ortalamasından uzak olduğu ve standart olmayan üretim işlemleri sebebiyle ortaya çıktığı sonucuna varılmış, bu sebeple de güncellenen modeli geliştirmek için kullanılmamıştır.

Üretim süreci devam ettikçe karşılaşılan her sinyalin incelenmesi ve gerekli ise modelde yeterince temsil edilemeyen parçalara ilişkin ölçümlerin zaman içerisinde modele eklenmesi ile ölçüm maliyetleri düşürülebilecek, tahmin performansı sürekli olarak iyileştirilebilecektir.

5. SONUÇLAR VE GELECEK ÇALIŞMALAR

Tez kapsamında yapılan çalışmada parça adedinin çok ve parça tipinin değişken olduğu, emek yoğun çalışma istasyonları için “İteratif Model Düzeltmeleri İle İş Emri Standart Üretim Süresi Tahmin Prosedürü” önerilerek benzer ihtiyaca sahip işletmeler için üretim süresi tahmininde izlenebilecek bir yol haritası oluşturulmuştur.

Prosedürün uygulanabileceği iş istasyonunun hangi özelliklere sahip olması gerektiği ve iş istasyonu belirlendikten sonra bu iş istasyonunda gerçekleştirilecek mevcut durum analizi yapılan örnek ile açıklanmıştır. İşletmeler burada verilen bilgileri ihtiyaçlarına göre çeşitlendirip geliştirebilir fakat temelde beklenen özelliklerin göz önünde bulundurulması önemlidir. Çalışmanın gerçekleştirilebilmesi için seçilen iş istasyonundaki üretim aktivitelerinin standart olarak tanımlanması, prosedürün devamındaki adımların uygulanabilmesi için zorunluluktur. Bu nedenle uzmanlar tarafından iş istasyonu detaylı incelenmeli ve uygulama örneğindeki gibi hiç bir üretim aktivitesi dışarıda kalmayacak şekilde kapsayıcı olmalıdır.

Metot ve zaman etüdünün literatürdeki yöntemleri açıklanmış ve geleneksel yöntemler günümüz teknolojisi ile bir araya getirilerek güncel bir yaklaşım ile çalışılmıştır. Gözlemler kamera aracılığıyla kayıt altına alınmış ve kayıtların analizinde kullanılabilecek bir analiz programı verilmiştir. Bu analiz programı zaman etüdü çalışmasından kullanılabilecek bir çok farklı aracı içerdiğinden benzer çalışmaları yapacak uzmanlara ışık tutacaktır. Yapılan uygulamada kayıtlar içerisindeki standart üretim aktivitelerinin süreleri analiz yazılımı aracılığı ile saniye bazında elde edilmiştir. Tüm bu kayıtların gelecekteki ihtiyaçlar için kullanılmak üzere işletmenin kurumsal hafızasında yer alması da bir başka faydadır.

Önerilen prosedür ile kurulan genel tahmin modelinin tüm parametreleri, hem metodoloji bölümünde hem de örnek çalışmanın yapıldığı analiz bölümünde detaylıca açıklanmıştır. Genel tahmin modelinde yer alan “tempo”, çalışmanın yapıldığı iş istasyonundaki gözlemlerin gerekli yetkinliğe sahip standart çalışma ortaya koyabilecek teknisyenler ile çalışılması sayesinde %100 normal olarak alınabilmiştir. Benzer uygulamayı gerçekleştirecek uzmanlar gözlemlenen işlerde normalin üstünde veya altında bir performans olup olmadığını belirleyebilecek bilgi düzeyinde olmalıdır. Tempoda oluşan ve dikkate alınmayan sapmaların tahmin modelinin performansı üzerinde olumsuz bir etkisi olacaktır. Genel tahmin modelinde yer alan bir diğer parametre olan “ek paylar”ın

kapsamının ne olduđu metodoloji bölümünde anlatılmış ve uygulamada işletmenin kabul ettiđi deđer baz alınmıştır. Ek paylar birçok işletme tarafından kolaylıkla göz ardı edilebilen ve standart dışı aktivitelerden oluşması nedeniyle performansı doğrudan etkileyen önemli bir parametre olarak karşımıza çıkar. Standart zaman belirleme çalışmalarında ek payların belirlenmesi ayrı bir çalışmanın konusu olup titizlikle ele alınmalıdır. Nasıl ki temponun doğru tespit edilememesinin model performansı üzerinde direkt olarak negatif bir etkisi varsa aynı şekilde ek payların doğru belirlenmemesi de bu etkiyi yaratır.

Çalışma kapsamında üretim süreleri “hazırlık süresi” ve “çalışma süresi” olarak iki kategoride ele alınarak kapsamaları örnekler ile açıklanmıştır. Tahmin modeli oluşturmak için belirlenen standart aktivitelerin hangi kategoride yer alacağını belirlemek önemlidir. Oluşturulan genel tahmin modelinde yer alan standart aktivite sürelerinin tahmin edilmesinde parçanın özelliklerinden bağımsız olarak gerçekleştirilen aktiviteler için örnekler üzerinden örneklem ortalaması yöntemi ile analiz yapılarak ilk aşamada kurulan model için bu ortalama süreler kullanılmıştır. Herhangi bir sebepten dolayı uygulamalarda bir farklılık olması halinde bu ortalama sürelerin güncellenmesi gerekecektir. Örneğin iş istasyonunun yerleşim planlarındaki değişimlerde yürüme mesafeleri değişeceğinden yürüme içeren faaliyetlerin süresinde değişiklik olması kaçınılmazdır. Bu nedenle çalışmanın yapıldığı istasyondaki her türlü değişiklik izlenmeli ve gerekli ise güncelleme yapılmalıdır. Diğer taraftan parçanın özelliklerine bağılı olarak iş emri üretim süresinde değişiklik görüldüğü durumlarda daha kompleks istatistiksel analiz araçları gerekmektedir. İş emrinde yer alan parçaların özelliklerine bağılı olan üretim aktiviteleri için tez kapsamında iki farklı tahmin yöntemi denenmiş ve yöntemlerin tahmin performansı karşılaştırmalı olarak verilmiştir. Çalışmadaki örnek uygulamada “parça yüzey çapak alma süresi”, çok değişkenli doğrusal regresyon ve CART yöntemleri ile tahminlenerek karşılaştırmalar sonucunda regresyon yönteminin kullanılmasına karar verilmiştir. Tahmin performansları %0,11 gibi bir farkla neredeyse aynı olsa da regresyon yönteminin daha az girdi ile bu tahmini veriyor olması maliyet açısından daha verimli bulunmuştur. Gelecekte farklı işletmelerde uygulama yapılması durumunda regresyon yöntemi ile CART yönteminin yine karşılaştırmalı analizi yapılmalı ve ihtiyaçlara göre en verimli ve doğru tahmin yapabilen seçilmelidir. Örnek uygulamada regresyon yönteminin tercih edilmiş olması prosedürün regresyon yöntemini önerdiği anlamına gelmemekte, aksine önerilen prosedür karşılaştırma yapmayı temel almaktadır.

Oluşturulan genel tahmin modeline, parametrelerin yerleştirilmesi ile elde edilen toplamsal tahmin modeli kullanılarak artık üretimi gerçekleştirilecek iş emirlerinin üretim süresi tahmin edilebilir durumdadır. Bu aşamada, tahminlerin ve üretim gerçekleştirmelerinin anlık ve kolay olarak gerçekleştirilebilmesi önemlidir. Örnek çalışmada bu amaçla Microsoft SQL Server Management Studio kullanılmış olup hem tahmin süresi hesabı hem de gerçekleşme süresinin elde edilmesi, sorgular sonucu oluşturulan raporlar ile sağlanmıştır. Benzer uygulamalar yapılmak istendiğinde işletmenin kullandığı üretim takip sistemi ve veritabanı özelinde farklı platformlar kullanılarak takip sistemi geliştirilebilir.

Tahmin süreleri ve gerçekleştirmeler elde edildiğinde önerilen prosedürün son adımı olan “Tahmin Hatalarının İzlenmesi İçin Düzeltilmiş Shewhart Kontrol Grafiği ve İteratif Model Düzeltmesi” adımına geçilerek kurulan başlangıç tahmin modelinin performansını sürekli olarak izleyip artıracak iteratif bir yaklaşım ortaya koyulmuştur. Üretimi gerçekleştiren ilk 55 iş emrindeki artıklar ile Gandy ve Kvaløy’un tahmin hatalarını hesaba katan yaklaşımı kullanılarak Shewhart kontrol grafiği oluşturulmuştur. Tahmin hatalarının hesaba katılması ile Shewhart grafiğinde yer alan kontrol limitleri düzeltilerek daha doğru ortalama sinyal tespiti uzunluğu veren bir kontrolde olma durumu tanımlanmıştır. İlk 55 iş emri ile oluşturulan kontrol limitleri sonrasında 56.-103. iş emirleri için kullanılarak 102. ve 103. iş emirlerinde grafik ile tespit edilen kontrol dışı sinyalleri incelenmiştir. Sinyal veren iş emirlerinin incelenerek modelin geliştirilmesine ihtiyaç olup olmadığının belirlenmesi önemli bir adımdır. Üretim gerçekleştirmelerine etki eden birçok öngörülemeyen değişken olabilir. Standart dışı bir uygulama veya beklenmeyen bir durumdan kaynaklı olarak gerçekleşme sürelerinde hatalar olabilir. Bu gibi durumlarda alınan sinyal ile zaman kaybetmeden ilgili iş emri için araştırmalar yapılabilecek ve eğer öngörülemeyen olağan dışı bir durum var ise bir daha ortaya çıkmaması adına iyileştirme aksiyonları alınabilecektir. Nitekim örnek uygulamadaki 102. iş emrinde de benzer bir durum tespit edilmiş ve modelde iyileştirme ihtiyacı olmadığına kanaat getirilmiştir. 103. iş emri incelendiğinde ise olağandışı bir duruma rastlanmamış ve modelin bu iş emrinin süresini tahmin etmede yetersiz kaldığı görülmüştür. Modelin iyileştirilmesi için bu iş emrinde yer alan parçanın gözleminin alınarak parça özelliklerine bağlı olan ve en yüksek değişkenliğe sahip parametrenin süresini tahminleyen regresyon modelinin güncellenmesi sağlanmıştır. Çalışmanın başında 93 adet gözlem verisi elde edilen regresyon modeli, bu gözlemin de eklenmesi

ile 94 parça ile tekrar kurulmuş ve sonuçlar paylaşılmıştır. Güncellenen regresyon modelinin açıklayıcılığı (R-sq değeri) daha düşük görünse de modele girdi olarak henüz alınmayan ve yeterli açıklanamayan bir çok parça olabileceğinden kapsayıcılık anlamında ilk modele göre daha güçlü olduğu bilinmektedir. Nitekim güncellenen regresyon modeli kullanılarak kontrolde olan 1-101. iş emirleri yeniden tahminlenerek yeni artıklar üzerinden kurulan kontrol grafiğinde yeni limitler öncekine göre daha dar bir aralığa sahip olmuştur (ilk model ile kurulan limitler $\pm 3,51 \hat{\sigma}$ iken güncellenen model ile $\pm 3,445 \hat{\sigma}$ ’dır). Oluşturulan yeni kontrol limitleri ile devamında üretilen iş emirleri (104-130. iş emirleri) izlendiğinde, güncelleme yapılmadığı durumda 4 adet sinyal alınırken güncellenerek daha dar limitler içerisinde izlenen durumda sadece 1 adet sinyal alınmıştır.

Model performansının düzeltilmiş limitler ile izlenmesi ve elde edilen sinyaller ile iş emri tahmin modelinin iteratif olarak iyileştirilmesi sayesinde yüksek parça çeşitliliğinde birbir gözlem zorluğunun üstesinden gelinerek işletmelere zaman etüdü çalışmalarında fayda sağlayacağı düşünülmektedir. Kapasite, üretim hedefleri, verimlilik analizlerinin doğru yapılabilmesi, standart süre belirleme yönteminin sürdürülebilirliğinin sağlanması, üretim gerçekleştirmelerinin takip edilebilmesi, çalışma maliyetlerinin kabul edilir seviyelerde tutularak israfların görünür kılınması gibi birçok motivasyon, önerilen yöntem ile hayata geçirilebilir hale gelmiştir. Tez kapsamında detayları verilmeyen ve genel tahmin modelinde yer alan “tempo” ve “ek paylar”ın belirlenmesinin gelecekteki çalışmalarda ele alınması benzer çalışmaları yapmak isteyen işletmeler için faydalı olacaktır.

6. KAYNAKLAR

1. Abbasi, S., Miller, A., & Riaz, M. (2013). Nonparametric Progressive Mean Control Chart for Monitoring Process Target. *Quality and Reliability Engineering International*, 29(7), 1069-1080.
2. Assef, F., Scarpin, C. T., & Steiner, M. T. (2018). Confrontation Between Techniques of Time Measurement. *Journal of Manufacturing Technology Management*, 29(5), 789-810.
3. Ayodele, T. O. (2010). Machine Learning Overview. Y. Zhang içinde, *New Advances in Machine Learning* (s. 9-18). Vokuvar: In-Teh.
4. Ayodele, T. O. (2010). Types of Machine Learning Algorithms. Y. Zhang içinde, *New Advances in Machine Learning* (s. 19-48). Vokuvar: In-Teh.
5. Benhar, H., Idri, A., & Fernández-Alemán, J. (2020). Data Preprocessing for Heart Disease Classification: A Systematic Literature Review. *Computer Methods and Programs in Biomedicine*, 1-30.
6. Bigus, J. P. (1996). *Data Mining With Neural Networks: Solving Business Problems from Application Development to Decision Support*. McGraw Hill.
7. Bures, M., & Pivodova, P. (2013). Comparison of the Predetermined Time Systems MTM-1 and BasicMOST in Assembly Production. *International Conference on Industrial Engineering and Engineering Management* (s. 546-550). Bangkok: IEEE.
8. Bures, M., & Pivodova, P. (2015). Comparison of Time Standardization Methods on the Basis of Real Experiment. *Procedia Engineering*, 100, 466-474.
9. Cordon, I., Luengo, J., Garcia, S., Herrera, F., & Charte, F. (2019). Smartdata : Data preprocessing to achieve smart data in R. *Neurocomputing*, 1-13.
10. Crisci, C., Ghattas, B., & Perera, G. (2012). A Review of Supervised Machine Learning Algorithms and Their Applications to Ecological Data. *Ecological Modelling*, 240, 113-122.
11. De Vries, A., & Reneau, J. (2010). Application of statistical process control charts to monitor changes in animal production systems. *Journal of Animal Science*, 88(suppl_13), E11-E24.

12. Gandy, A., & Kvaløy, J. (2013). Guaranteed Conditional Performance of Control Charts via Bootstrap Methods. *Scandinavian Journal of Statistics*, 40(4), 647-668.
13. Gandy, A., & Kvaløy, J. (2017). spcadjust: An R Package for Adjusting for Estimation Error in Control Charts. *The R Journal*, 9(1), 458.
14. Garcia, S., Luengo, J., & Herrera, F. (2015). *Data Preprocessing in Data Mining*. Springer.
15. Genaidy, A. M., Mital, A., & Obeidat, M. (1989). The Validity of Predetermined Motion Time Systems in Setting Production Standards for Industrial Tasks. *International Journal of Industrial Ergonomics*, 3(3), 249-263.
16. Golpîra, H. (2013). Estimating Duration of Projects Manual Tasks Using MODAPTS plus Method. *International Journal of Research in Industrial Engineering*, 2(1), 12-19.
17. Grzymala-Busse, J. W., & Grzymala-Busse, W. J. (2010). Handling Missing Attribute Values. O. Maimon, & L. Rokach içinde, *Data Mining and Knowledge Discovery Handbook* (s. 33-51). London: Springer.
18. Gunesoglu, S., & Meric, B. (2007). The Analysis of Personal and Delay Allowances Using Work Sampling Technique in the Sewing Room of a Clothing Manufacturer. *International Journal of Clothing Science and Technology*, 19(2), 145-150.
19. Güner, Z. B. (2014). Veri Madenciliğinde CART Ve Lojistik Regresyon Analizinin Yeri: İlaç Provizyon Sistemi Verileri Üzerinde Örnek Bir Uygulama. *Sosyal Güvençe*, 6, 53-99.
20. Idri, A., Benhar, H., Fernández-Alemán, J., & Kadi, I. (2018). A Systematic Map of Medical Data Preprocessing in Knowledge Discovery. *Computer Methods and Programs in Biomedicine*, 69-85.
21. Jamshed, H., Khan, S. A., Khurram, M., Inayatullah, S., & Athar, S. (2019). Data Preprocessing: A preliminary step for web data mining. *3C Tecnología. Glosas de*, 206-221.
22. Kotsiantis, S. B., Zaharakis, I. D., & Pintelas, P. E. (2007). Machine Learning: A Review of Classification and Combining Techniques. *Artificial Intelligence Review*, 26, 159-190.

23. Kulkarni, P. P., Kshire, S. S., & Chandratre, K. V. (2014). Productivity Improvement Through Lean Deployment & Work Study Methods. *International Journal of Research in Engineering and Technology*, 3(2), 429-434.
24. Kumari, A. D., Kumar, D. P., Prakash, D. S., & S., D. K. (2021). Supervised Learning Algorithms: A Comparison. *Kristu Jayanti Journal of Computational Sciences*, 1, 01-12.
25. Laird, R. A., & Sherratt, T. N. (2009). The Economics of Evolution: Henry Ford and the Model T. *Oikos, Wiley Online Library*, 119(1), 3-9.
26. Mahesh, B. (2018). Machine Learning Algorithms - A Review. *International Journal of Science and Research (IJSR)*, 381-386.
27. Maimon, O., & Rokach, L. (2010). Introduction to Knowledge Discovery and Data. O. Maimon, & L. Rokach içinde, *Data Mining And Knowledge Discovery Handbook* (s. 1-15). London: Springer.
28. Maletic, J. I., & Marcus, A. (2010). Data Cleansing: A Prelude to Knowledge Discovery. O. Maimon, & L. Rokach içinde, *Data Mining and Knowledge Discovery Handbook* (s. 269-298). London: Springer.
29. Meyers, F. E., & Stewart, J. R. (2002). *Motion and Time Study for Lean Manufacturing*. Columbus, Ohio: Pearson Education, Inc.
30. Mital, A., Desai, A., & Mital, A. (2017). *Fundamentals of Work Measurement: What Every Engineer Should Know*. Boca Raton: Taylor&Francis Group.
31. Montgomery, D. (2020). *Introduction to Statistical Quality Control*. United States of America: John Wiley & Sons, Inc.
32. Montgomery, D., Peck, E., & Vining, G. (2012). *Introduction to Linear Regression Analysis* (5th Edition b.). United States of America: John Wiley & Sons, Inc.
33. Patel, N. (2015). Reduction in Product Cycle Time in Bearing Manufacturing Company. *International Journal of Engineering Research and General Science*, 3(3), 466-471.
34. Rahm, E., & Do, H. H. (2000). Data Cleaning: Problems and Current Approaches. *IEEE Data Engineering Bulletin*, 23(4), 3-13.

35. Ramírez-Gallego, S., Krawczyk, B., García, S., Wozniak, M., & Herrera, F. (2017). A Survey on Data Preprocessing for Data Stream Mining: Current Status and Future Directions. *Neurocomputing*, 39-57.
36. Rathod, A. S., Jadhav, R. G., & Babar, A. B. (2016). An Overview of Method Study and Study of Different Recording Techniques. *International Journal of Science and Research (IJSR)*, 5(8), 1484-1491.
37. Ray, S. (2019). A Quick Review of Machine Learning Algorithms. *International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (Com-IT-Con)* (s. 35-39). Faridabad: IEEE.
38. Riedel, A., Brehm, N., & Pfeifroth, T. (2022). Hand Gesture Recognition of Methods-Time Measurement-1 Motions in Manual Assembly Tasks Using Graph Convolutional Networks. *Applied Artificial Intelligence An International Journal*, 36(1), 4.
39. Song, Y.-y., & Lu, Y. (2015). Decision Tree Methods: Applications for Classification and Prediction. *Shanghai Archives of Psychiatry*, 27(2), 130-135.
40. Starovoytova, D. (2017). Time-study of Rotary-Screen-Printing Operation. *Industrial Engineering Letters*, 7(4), 24-34.
41. Sun, W., Cai, Z., Li, Y., Liu, F., Fang, S., & Wang, G. (2018). Data Processing and Text Mining Technologies on Electronic Medical Records: A Review. *Journal of Healthcare Engineering*, 1-9.
42. Szewczyk, G., & Sowa, J. M. (2017). The Accuracy of Measurements in a Time Study of Harvester Operations. *New Zealand Journal of Forestry Science*, 47(24), 1-10.
43. Yavuz, A., & Çilengiroğlu, Ö. V. (2020). Lojistik Regresyon ve CART Yöntemlerinin Tahmin Edici Performanslarının Yaşam Memnuniyeti Verileri için Karşılaştırılması. *European Journal of Science and Technology*, 18, 719-727.

EKLER

EK 1 - Örnek Timer Pro Professional Analizi ve Excel Çıktısı

The screenshot displays the Video Timer Pro Professional software interface. The main window shows a video feed of a worker in a factory setting, performing a task. The software interface includes various controls and a task analysis table on the right side. The table lists tasks with their IDs, descriptions, durations, and start/stop times.

ID	Task Name	Start Time	Stop Time
1	SOIR MÜHÜRLEME	38,506001	38,506001
2	YARDIMCI EKİPMAN/MALZEME HAZIRLIK	16,584999	55,091000
3	YÜZEY ÇAPAK İŞLEMLERİ	1673,107056	1728,197998
4	DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	30,620001	1728,197998
5	RASPA İLE DELİK ÇAPAK İŞLEMLERİ	80,683998	1758,817993
6	DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	47,921001	1839,501953
7	RASPA İLE DELİK ÇAPAK İŞLEMLERİ	74,357002	1887,422974
8	DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	45,682999	1961,780029
9	RASPA İLE DELİK ÇAPAK İŞLEMLERİ	24,295000	2007,463013
10	BİLGİ ALIŞVERİŞİ	185,554001	2031,758057
11	RASPA İLE DELİK ÇAPAK İŞLEMLERİ	44,103001	2217,312012
12	DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	50,783001	2261,415039
13	RASPA İLE DELİK ÇAPAK İŞLEMLERİ	82,082001	2312,197998
14	DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	22,903000	2394,280029
15	DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	30,608000	2417,183105
16	RASPA İLE DELİK ÇAPAK İŞLEMLERİ	69,637001	2447,791016
17	DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	27,452999	2517,427979
18	RASPA İLE DELİK ÇAPAK İŞLEMLERİ	42,460999	2544,881104
19	DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	34,095001	2587,342041
20	RASPA İLE DELİK ÇAPAK İŞLEMLERİ	44,509998	2621,437012
21	MARKALAMA	92,601997	2665,947021
22	İŞ EMRİ MÜHÜRLEME	100,427002	2758,549072

A	B	C	D	E	F
ID	AKTİVİTE	AKTİVİTE TÜRÜ	Seconds	Start Time	Stop Time
1	1 SOIR MÜHÜRLEME	PLANLI AKTİVİTE	38,506001	,0000	38,506001
2	2 YARDIMCI EKİPMAN/MALZEME HAZIRLIK	PLANLI AKTİVİTE	16,584999	38,506001	55,091000
3	3 YÜZEY ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	1673,107056	55,091000	1728,197998
4	4 DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	30,620001	1728,197998	1758,817993
5	5 RASPA İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	80,683998	1758,817993	1839,501953
6	6 DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	47,921001	1839,501953	1887,422974
7	7 RASPA İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	74,357002	1887,422974	1961,780029
8	8 DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	45,682999	1961,780029	2007,463013
9	9 RASPA İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	24,295000	2007,463013	2031,758057
10	10 BİLGİ ALIŞVERİŞİ	STANDART OLMAYAN İŞ	185,554001	2031,758057	2217,312012
11	11 RASPA İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	44,103001	2217,312012	2261,415039
12	12 DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	50,783001	2261,415039	2312,197998
13	13 RASPA İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	82,082001	2312,197998	2394,280029
14	14 DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	22,903000	2394,280029	2417,183105
15	15 DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	30,608000	2417,183105	2447,791016
16	16 RASPA İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	69,637001	2447,791016	2517,427979
17	17 DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	27,452999	2517,427979	2544,881104
18	18 RASPA İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	42,460999	2544,881104	2587,342041
19	19 DRILL MOTOR İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	34,095001	2587,342041	2621,437012
20	20 RASPA İLE DELİK ÇAPAK İŞLEMLERİ	PLANLI AKTİVİTE	44,509998	2621,437012	2665,947021
21	21 MARKALAMA	PLANLI AKTİVİTE	92,601997	2665,947021	2758,549072
22	22 İŞ EMRİ MÜHÜRLEME	PLANLI AKTİVİTE	100,427002	2758,549072	2858,976074

EK 2 - Sabit Parametreler Tahmini İçin Analizler

İşçilik girme

Statistics

Variable	N	N*	Percent	CumPct	Mean	SE Mean	StDev	Variance	Sum of Squares
İşçilik Girme (sn)	94	0	100	100	63,29	2,58	24,98	623,77	434495,39
Variable	Minimum	Q1	Median	Q3	Maximum	Range	Skewness		
İşçilik Girme (sn)	21,84	45,37	55,76	80,11	130,77	108,93	0,55		

Parça taşıma

Statistics

Variable	N	N*	Percent	Mean	SE Mean	StDev	Variance	Minimum	Q1	Median
Toplam Parça Taşıma	23	0	100	48,98	4,04	19,37	375,13	13,33	37,30	51,24
Variable	Q3	Maximum	Range	Skewness						
Toplam Parça Taşıma	60,63	90,70	77,37	0,01						

Planlama inceleme

Statistics

Variable	N	N*	Percent	Mean	SE Mean	StDev	Variance	Minimum	Q1	Median
Planlama İnceleme	18	0	100	71,12	7,87	33,37	1113,88	27,92	47,32	68,74
Variable	Q3	Maximum	Range	Skewness						
Planlama İnceleme	88,04	156,10	128,18	1,07						

Paketten çıkarma/paketleme

Statistics

Variable	N	N*	Percent	Mean	SE Mean	StDev	Variance	Minimum	Q1
Toplam Paketten çıkarma/Paketle	42	0	100	64,33	4,54	29,45	867,04	18,52	44,21
Variable	Median	Q3	Maximum	Range	Skewness				
Toplam Paketten çıkarma/Paketle	61,92	86,01	146,67	128,15	0,51				

Drill motor ile delik çapak alma

Statistics

Variable	N	N*	Percent	Mean	SE Mean	StDev	Variance	Minimum	Q1	Median
Delik Başına Süre	85	0	100	3,964	0,215	1,987	3,947	1,003	2,696	3,478
Variable	Q3	Maximum	Range	Skewness						
Delik Başına Süre	4,461	10,760	9,757	1,71						

Raspa ile delik çapak alma

Statistics

Variable	N	N*	Percent	Mean	SE Mean	StDev	Variance	Minimum	Q1	Median
Delik Başına Süre	36	0	100	15,62	1,94	11,65	135,78	2,74	8,16	12,61
Variable	Q3	Maximum	Range	Skewness						
Delik Başına Süre	21,71	62,83	60,08	2,20						

Markalama

Statistics

Variable	N	N*	Percent	Mean	SE Mean	StDev	Variance	Minimum	Q1	Median	Q3
Markalama	59	0	100	78,09	5,28	40,59	1647,37	9,00	44,57	78,62	112,81

Variable	Maximum	Range	Skewness
Markalama	169,47	160,47	0,16

İş emrinin mühürlenmesi

Statistics

Variable	N	N*	Percent	Mean	SE Mean	StDev	Variance	Sum of Squares	Minimum
SOIR Mühürleme	110	0	100	104,72	3,89	40,79	1663,82	1387661,85	35,31

Variable	Q1	Median	Q3	Maximum	Range	Skewness
SOIR Mühürleme	75,35	94,57	134,04	206,18	170,87	0,64



EK 3 - CART Analizi İçin Ayarlar

CART® Regression

Response: 'Yüzey İşlem Süresi (sn)'

Continuous predictors:
'Alan (cm^2)'

Categorical predictors:
Proje 'Malzeme Tipi' 'Boyutsal Kod' 'Parça Tipi'

Select

Validation... Options... Graphs...
Results... Storage...

Help OK Cancel

CART® Regression: Validation

Validation method: K-fold cross-validation

Randomly assign rows of each fold
Number of folds (K): 10
Base for random number generator: 12345

Assign rows of each fold by ID column
ID column:

Store ID column for K-fold cross-validation

Select

Help OK Cancel

CART® Regression: Options

Node splitting method: Least squared error

Criterion for selecting optimal tree:

- Maximum R-squared
- Within K standard errors of maximum R-squared; K = 1

Number of surrogates for a predictor with missing values: 10

Minimum number of cases to split an internal node: 3

Minimum number of cases allowed for a terminal node: 3

Maximum tree depth:

Maximum number of terminal nodes: 1024

Weights:

Select

Help OK Cancel

CART® Regression: Graphs

Residuals for plots: Regular

- Tree diagram
- R-squared vs number of terminal nodes plot
- Variable importance chart
 - Display: All important variables
- Fitted vs actual response value plot
- Boxplot of residuals

Terminal node order: Ascending mean squared error

- Mean squared error vs terminal node plot
- Boxplot of response by terminal node
- Residual vs terminal node plot

Help OK Cancel

CART® Regression: Results ×

- Method
- Response information
- Model summary
- Percent error statistics due to K% largest residuals; K =

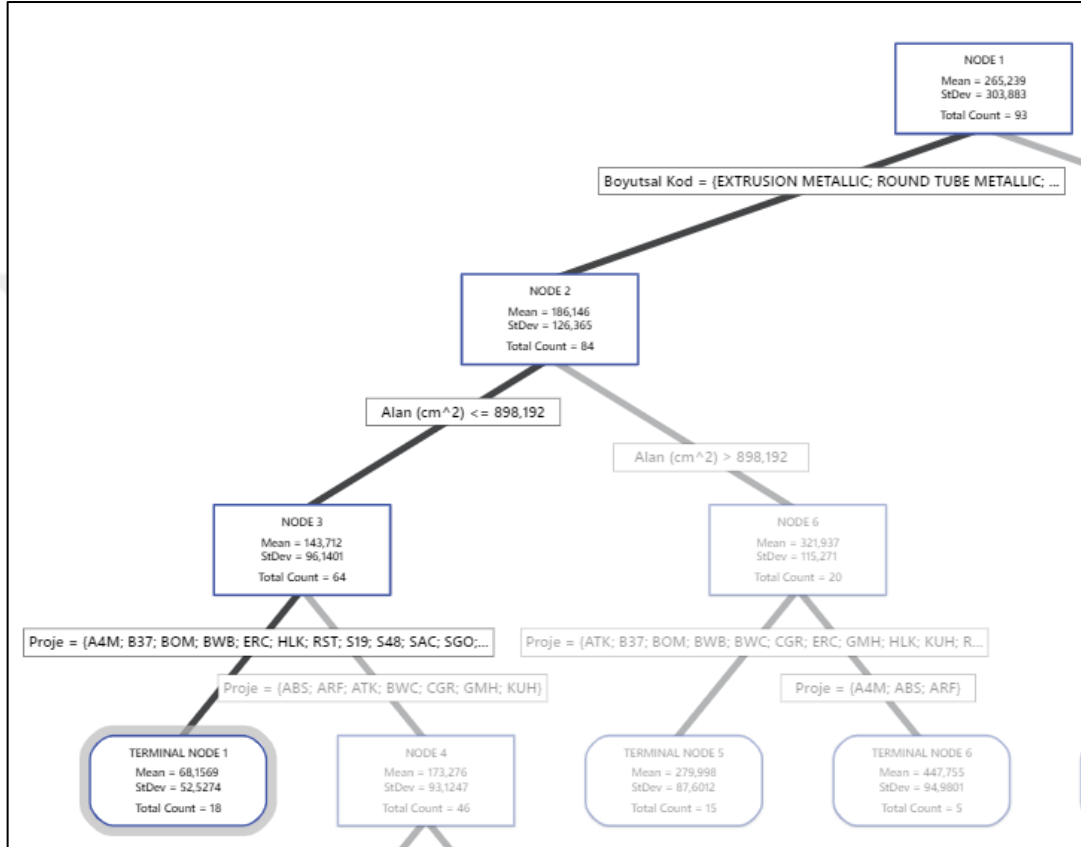
Terminal node type: ▼

- Response fits and error statistics by K terminal nodes; K =
- Criteria for classifying subjects into K terminal nodes; K =

EK 4 - CART En İyi Alternatif Karar Ağacı Uç Düğüm Kuralları

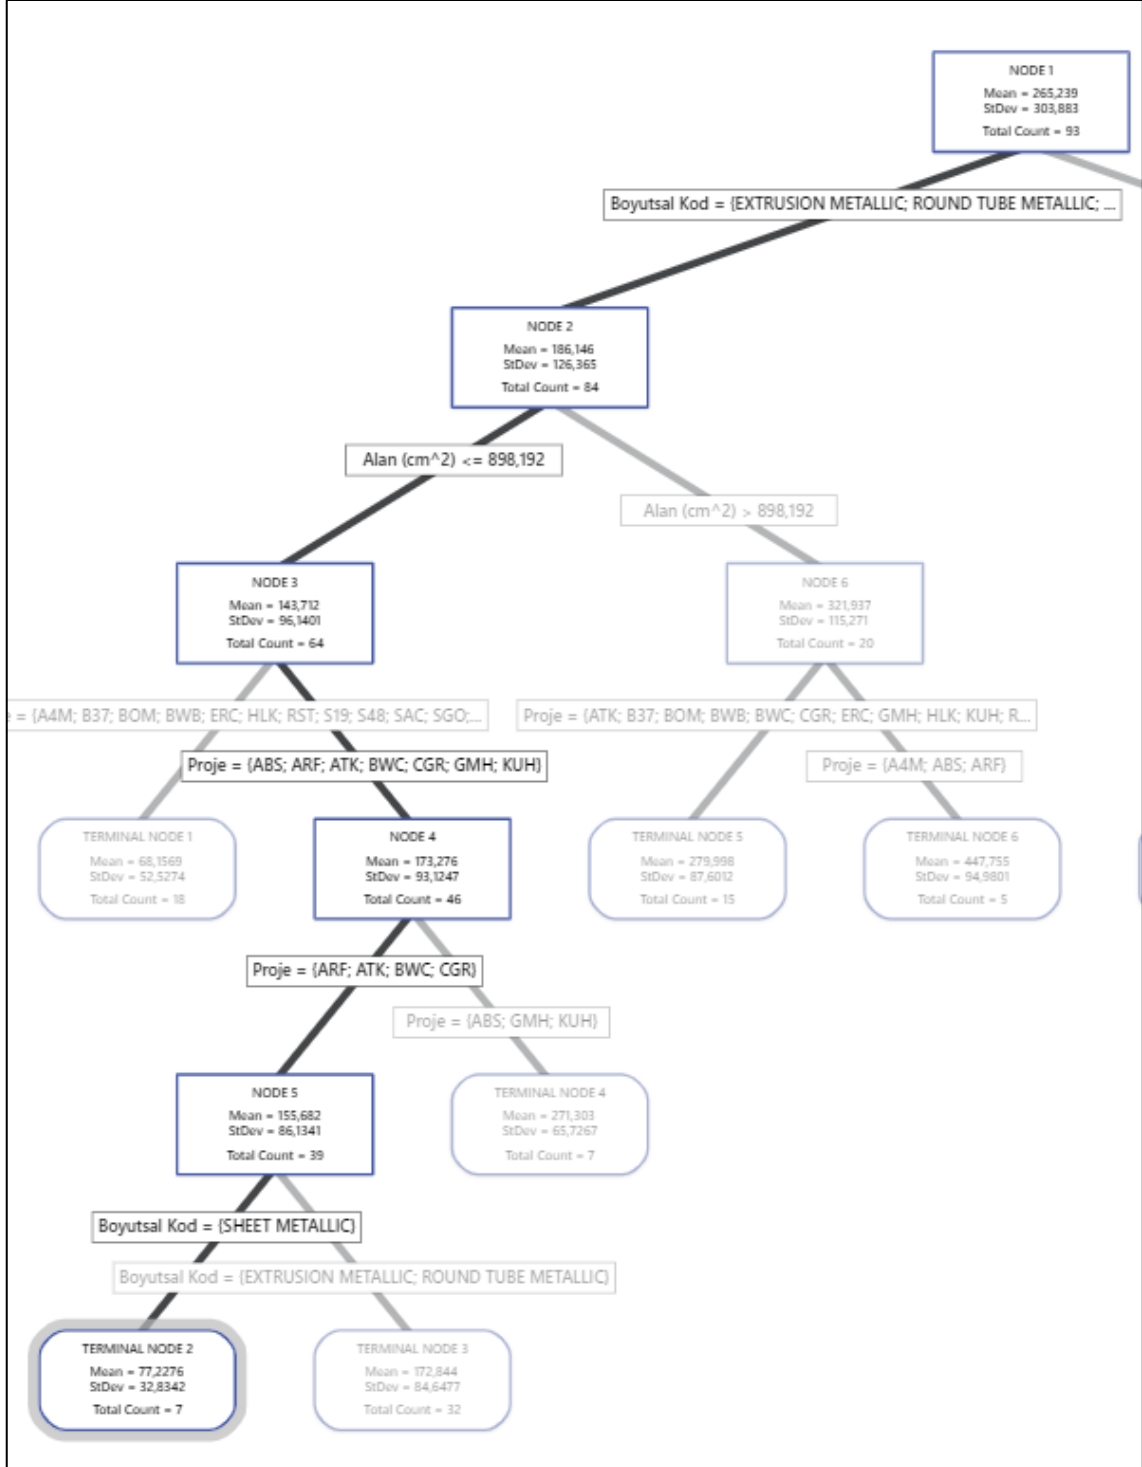
Uç Düğüm 1

Alan (cm²) ≤ 898,192; Boyutsal Kod = {EXTRUSION METALLIC; ROUND TUBE METALLIC; SHEET METALLIC}; Proje = {A4M; B37; BOM; BWB; ERC; HLK; RST; S19; S48; SAC; SGO; THB; YHH}



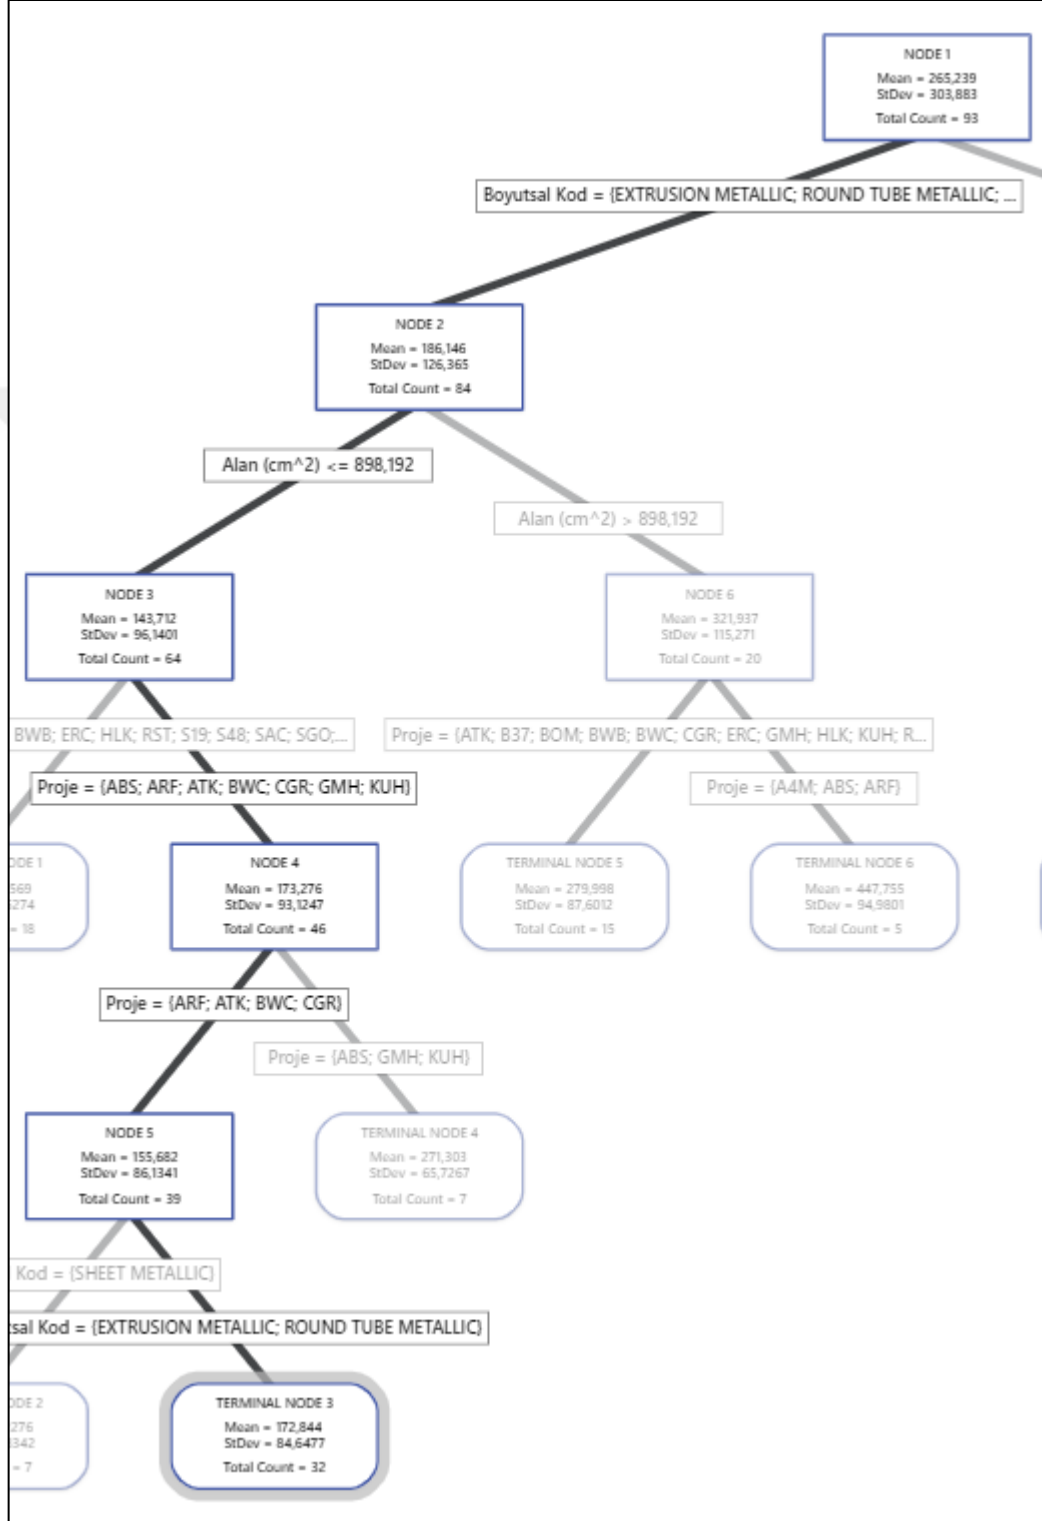
Uç Düğüm 2

Alan (cm²) ≤ 898,192; Boyutsal Kod = {SHEET METALLIC}; Proje = {ARF; ATK; BWC; CGR}



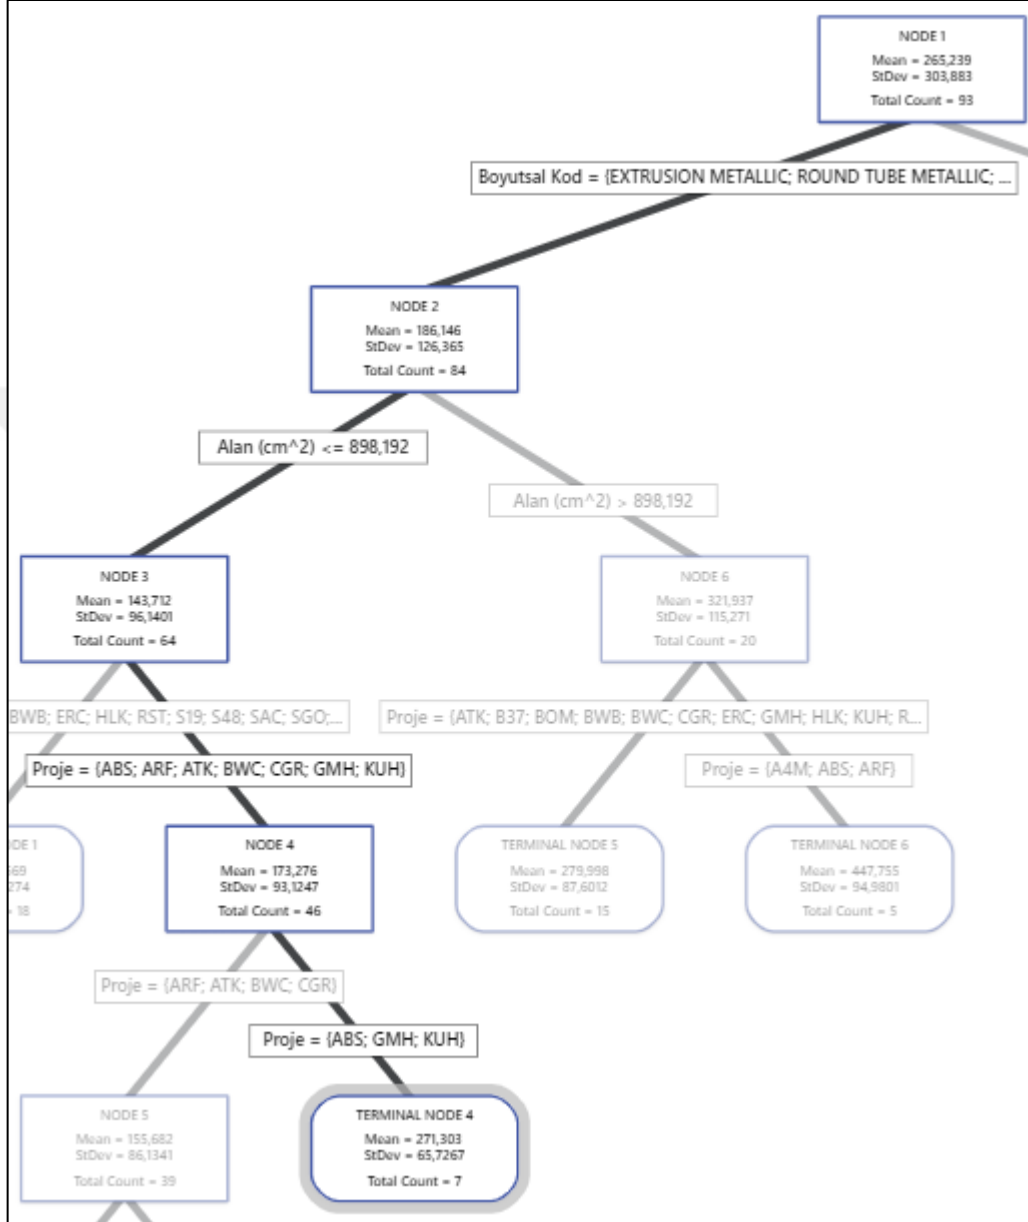
Uç Düğüm 3

Alan (cm²) ≤ 898,192; Boyutsal Kod = {EXTRUSION METALLIC; ROUND TUBE METALLIC}; Proje = {ARF; ATK; BWC; CGR}



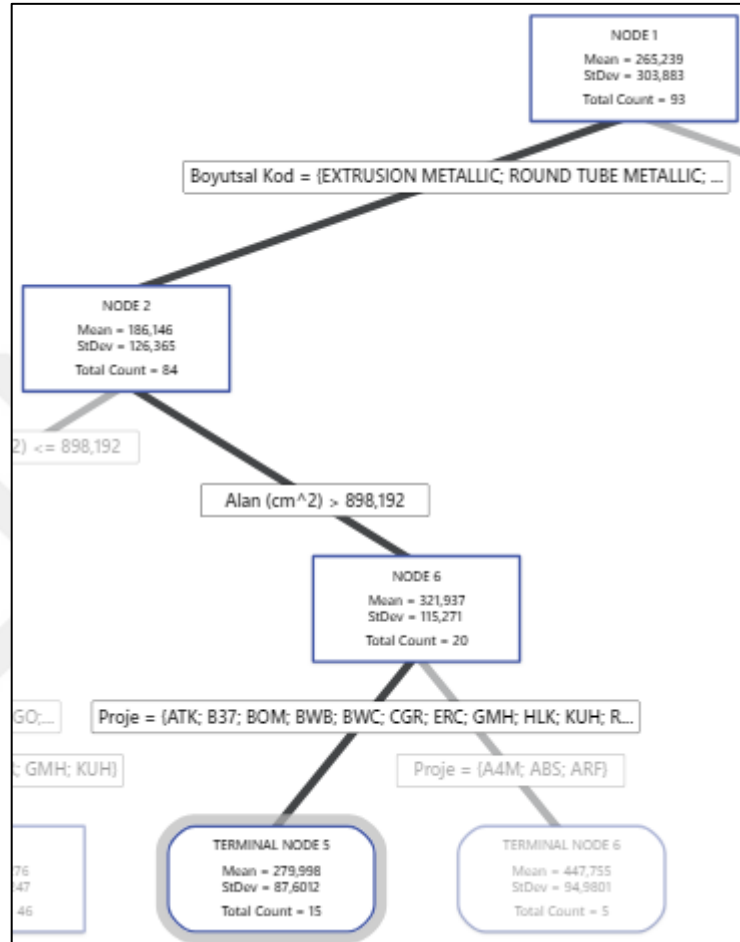
Uç Düğüm 4

Alan (cm²) ≤ 898,192; Boyutsal Kod = {EXTRUSION METALLIC; ROUND TUBE METALLIC; SHEET METALLIC}; Proje = {ABS; GMH; KUH}



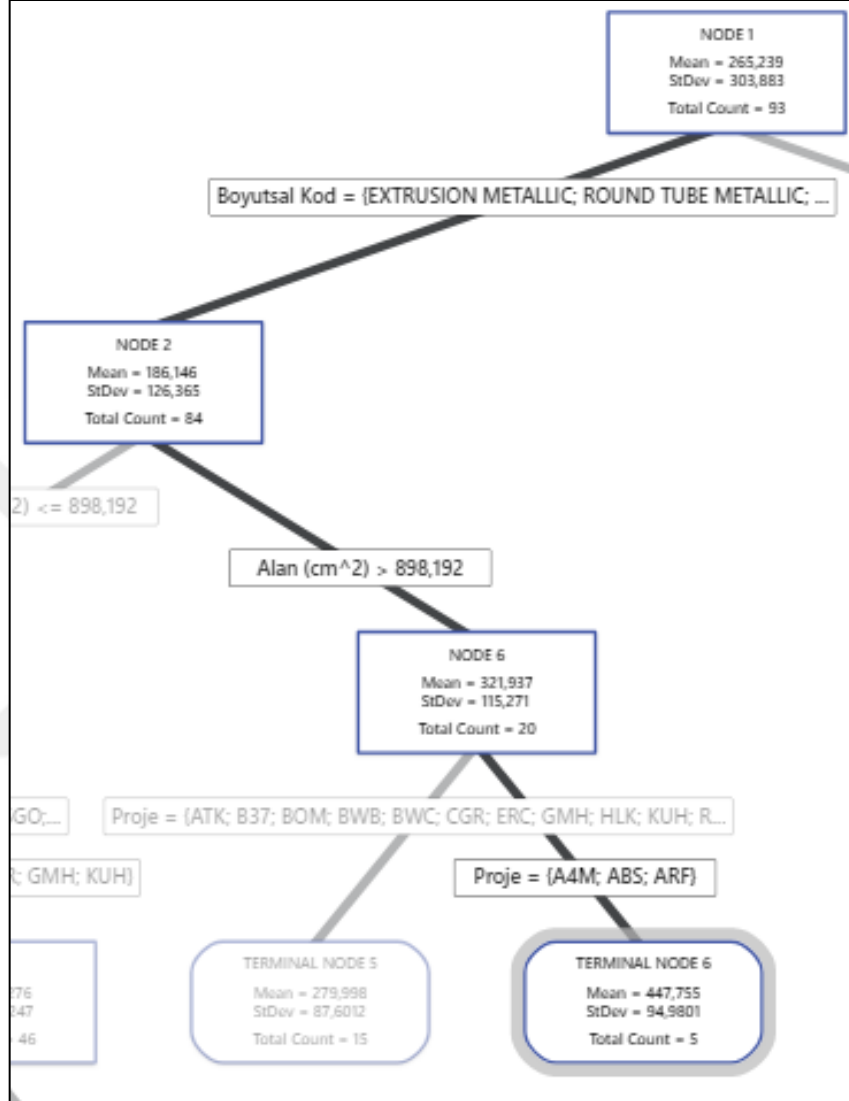
Uç Düğüm 5

Alan (cm²) > 898,192; Boyutsal Kod = {EXTRUSION METALLIC; ROUND TUBE METALLIC; SHEET METALLIC}; Proje = {ATK; B37; BOM; BWB; BWC; CGR; ERC; GMH; HLK; KUH; RST; S19; S48; SAC; SGO; THB; YHH}



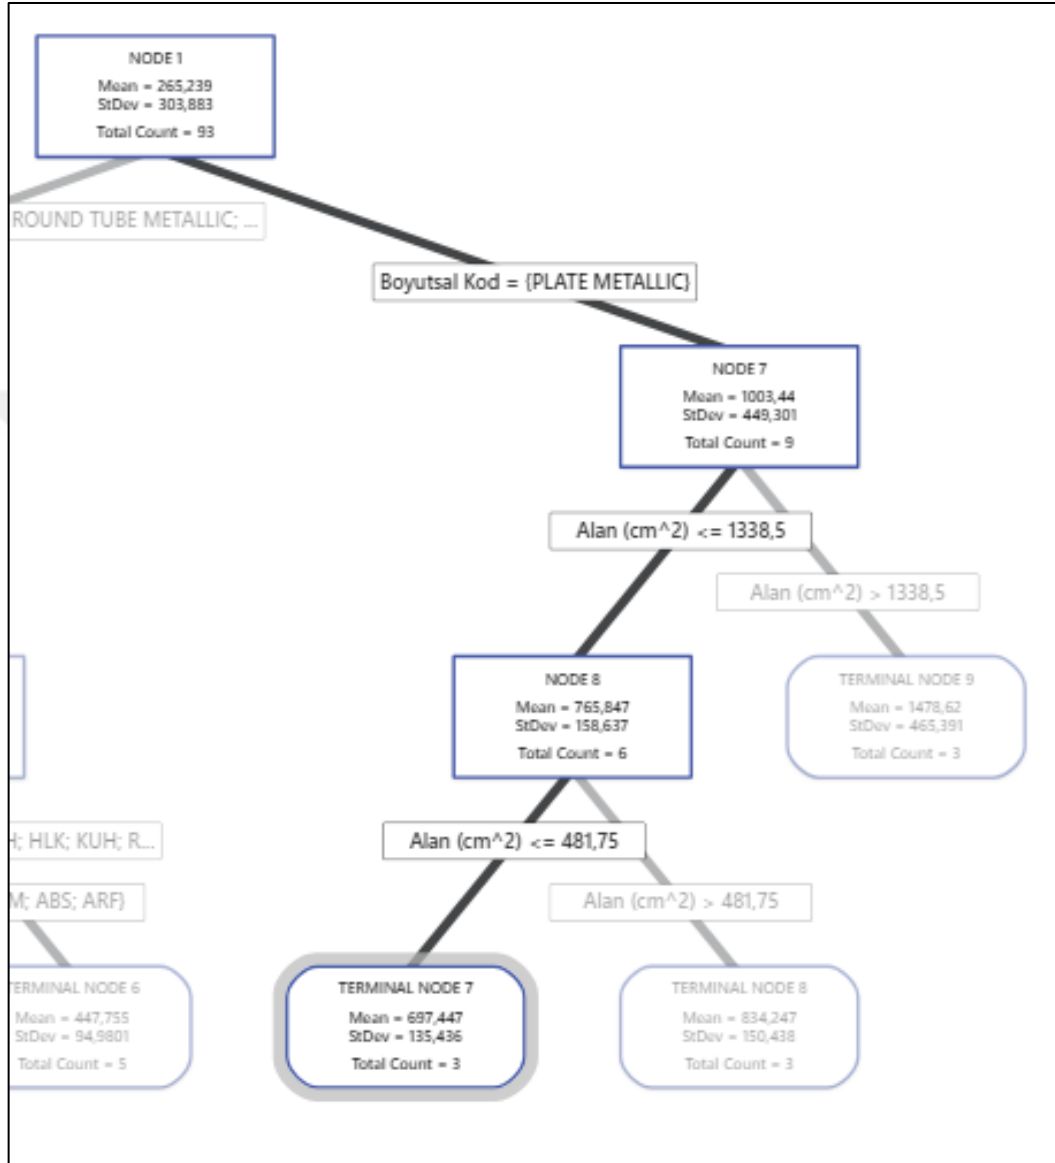
Uç Düğüm 6

Alan (cm²) > 898,192; Boyutsal Kod = {EXTRUSION METALLIC; ROUND TUBE METALLIC; SHEET METALLIC}; Proje = {A4M; ABS; ARF}



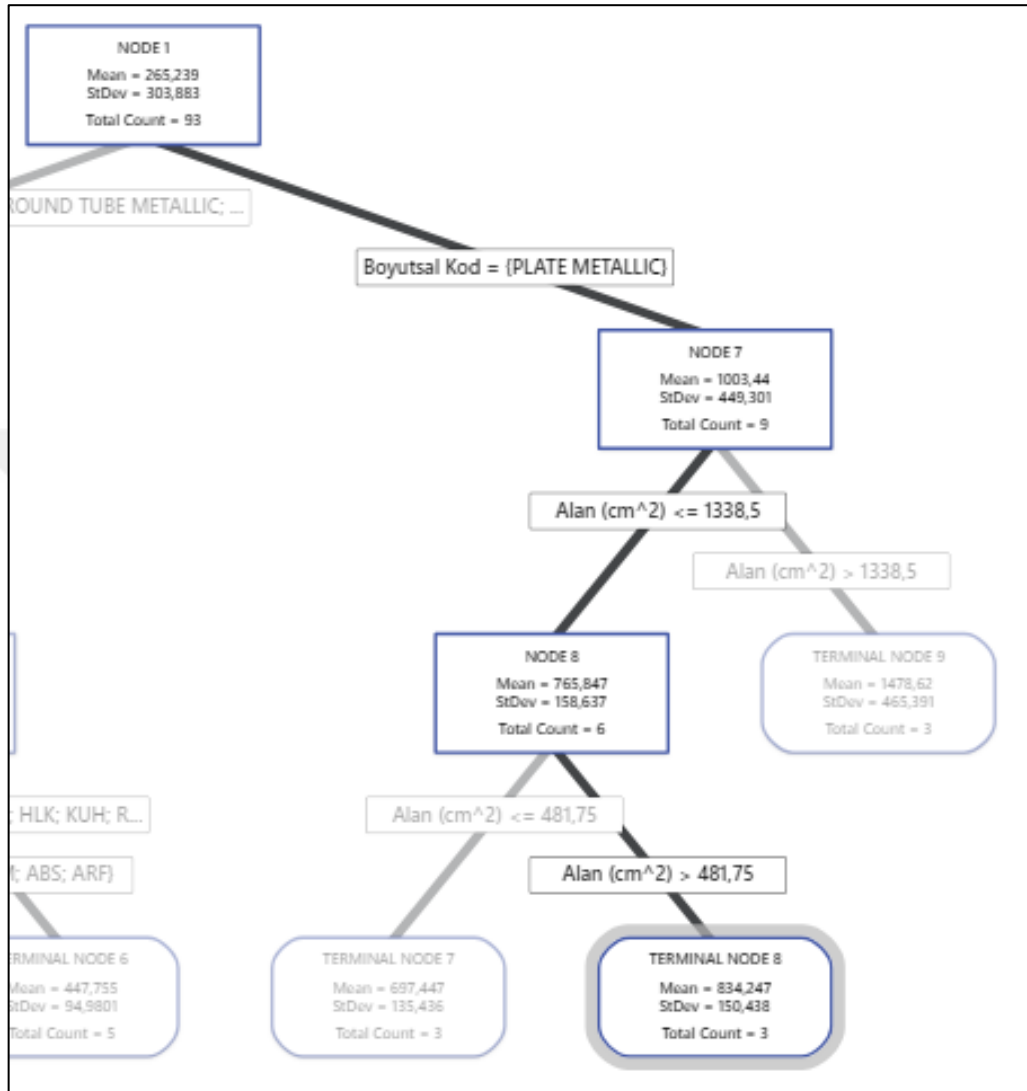
Uç Düğüm 7

Alan (cm²) ≤ 481,75; Boyutsal Kod = {PLATE METALLIC}



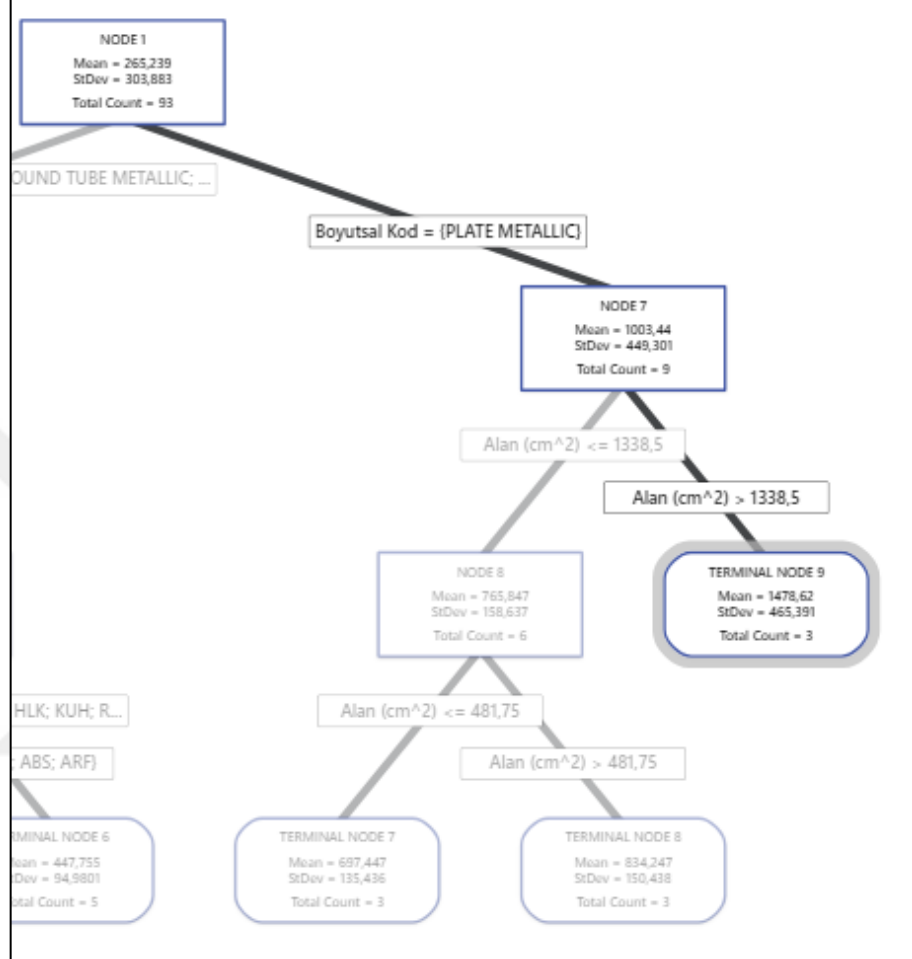
Uç Düğüm 8

$481,75 < \text{Alan (cm}^2) \leq 1338,5$; Boyutsal Kod = {PLATE METALLIC}



Uç Düğüm 9

Alan (cm²) > 1338,5; Boyutsal Kod = {PLATE METALLIC}



EK 5 - 1-55 Arası Gözlemler İçin R Studio Yazılımında Kullanılan “Script” ve “Console” Bilgileri

R Script

```
library(spcadjust)

chartShew <- new("SPCShew", model = SPCModelNormal(), twosided = TRUE)

X <- Artiklar_1 $`Artiklar`[1:55]

xihat <- xiofdata(chartShew, X)

str(xihat)

SPCproperty(data = X, nrep = 500, property = "ARL", chart = chartShew,
            params = list(threshold = 3), quiet = TRUE, covprob=c(0.95))

cal <- SPCproperty(data = X, nrep = 500, property = "calARL", chart = chartShew,
                 params = list(target = 370), quiet = TRUE, covprob=c(0.95))

cal

newX <- Artiklar_1 $`Artiklar`[1:55]

S <- runchart(chartShew, newdata = newX, xi = xihat)

par(mfrow=c(1,2),mar=c(4,5,0.1,0.1))

plot(newX,xlab="t")

plot(S,ylab=expression(S[t]),xlab="t",type="b",ylim=range(S,cal@res+2,cal@raw,-
cal@res-1,-cal@raw))

lines(c(0,100),rep(cal@res,2),col="red")

lines(c(0,100),rep(cal@raw,2),col="blue")

lines(c(0,100),-rep(cal@res,2),col="red")

lines(c(0,100),-rep(cal@raw,2),col="blue")
```

Console

```
> library(spcadjust)
> chartShew <- new("SPCShew", model = SPCModelNormal(), twosided = TRUE)
> X <- Artiklar_1 $`Artiklar`[1:55]
> xihat <- xiofdata(chartShew, X)
> str(xihat)
List of 3
```

```

$ mu: num -0.0628
$ sd: num 0.686
$ m : int 55
> SPCproperty(data = X, nrep = 500, property = "ARL", chart = chartShew,
+             params = list(threshold = 3),
+             quiet = TRUE, covprob=c(0.95))
95 % CI: A threshold of 3 gives an in-control ARL of at least 82.22.
Unadjusted result: 370.4
Based on 500 bootstrap repetitions.
> cal <- SPCproperty(data = X, nrep = 500, property = "calARL",
+                  chart = chartShew,
+                  params = list(target = 370),
+                  quiet = TRUE, covprob=c(0.95))
> cal
95 % CI: A threshold of 3.51 gives an in-control ARL of at least 370.
Unadjusted result: 3
Based on 500 bootstrap repetitions.
> newX <- Artiklar_1 $ `Artiklar` [1:55]
> S <- runchart(chartShew, newdata = newX, xi = xihat)
> par(mfrow=c(1,2),mar=c(4,5,0.1,0.1))
> plot(newX,xlab="t")
> plot(S,ylab=expression(S[t]),xlab="t",type="b",
+      ylim=range(S,cal@res+2,cal@raw,-cal@res-1,-cal@raw))
> lines(c(0,100),rep(cal@res,2),col="red")
> lines(c(0,100),rep(cal@raw,2),col="blue")
> lines(c(0,100),-rep(cal@res,2),col="red")
> lines(c(0,100),-rep(cal@raw,2),col="blue")

```

EK 6 - 56-103 Arası Gözlemler İçin R Studio Yazılımında Kullanılan “Script” ve “Console” Bilgileri

R Script

```
newX <- Artiklar_1 `$Artiklar`[56:103]

S <- runchart(chartShew, newdata = newX, xi = xihat)

par(mfrow=c(1,2),mar=c(4,5,0.1,0.1))

plot(newX,xlab="t")

plot(S,ylab=expression(S[t]),xlab="t",type="b",ylim=range(S,cal@res+2,cal@raw,-
cal@res-1,-cal@raw))

lines(c(0,100),rep(cal@res,2),col="red")

lines(c(0,100),rep(cal@raw,2),col="blue")

lines(c(0,100),-rep(cal@res,2),col="red")

lines(c(0,100),-rep(cal@raw,2),col="blue")
```

Console

```
newX <- Artiklar_1 `$Artiklar`[56:103]
> S <- runchart(chartShew, newdata = newX, xi = xihat)
> par(mfrow=c(1,2),mar=c(4,5,0.1,0.1))
> plot(newX,xlab="t")
> plot(S,ylab=expression(S[t]),xlab="t",type="b",ylim=range(S,cal@res+
2,cal@raw,-cal@res-1,-cal@raw))
> lines(c(0,100),rep(cal@res,2),col="red")
> lines(c(0,100),rep(cal@raw,2),col="blue")
> lines(c(0,100),-rep(cal@res,2),col="red")
> lines(c(0,100),-rep(cal@raw,2),col="blue")
```

EK 7 - 104-130 Arası Gözlemler İçin R Studio Yazılımında Kullanılan “Script” ve “Console” Bilgileri

İlk Kontrol Limitleri için R Script

```
newX <- Artiklar_1 `$Artiklar`[104:130]

S <- runchart(chartShew, newdata = newX, xi = xihat)

par(mfrow=c(1,2),mar=c(4,5,0.1,0.1))

plot(newX,xlab="t")

plot(S,ylab=expression(S[t]),xlab="t",type="b",ylim=range(S,cal@res+2,cal@raw,-
cal@res-1,-cal@raw))

lines(c(0,100),rep(cal@res,2),col="red")

lines(c(0,100),rep(cal@raw,2),col="blue")

lines(c(0,100),-rep(cal@res,2),col="red")

lines(c(0,100),-rep(cal@raw,2),col="blue")
```

Console

```
newX <- Artiklar_1 `$Artiklar`[104:130]
> S <- runchart(chartShew, newdata = newX, xi = xihat)
> par(mfrow=c(1,2),mar=c(4,5,0.1,0.1))
> plot(newX,xlab="t")
> plot(S,ylab=expression(S[t]),xlab="t",type="b",ylim=range(S,cal@res+
2,cal@raw,-cal@res-1,-cal@raw))
> lines(c(0,100),rep(cal@res,2),col="red")
> lines(c(0,100),rep(cal@raw,2),col="blue")
> lines(c(0,100),-rep(cal@res,2),col="red")
> lines(c(0,100),-rep(cal@raw,2),col="blue")
```

Güncellenmiş Model İle Hesaplanan Yeni Artıklar ile Yeni Kontrol Limitleri için R Script

```
library(spcadjust)

chartShew <- new("SPCShew", model = SPCModelNormal(), twosided = TRUE)

X <- Artiklar_2 `$Artiklar`[1:101]

xihat <- xiofdata(chartShew, X)

str(xihat)

SPCproperty(data = X, nrep = 500, property = "ARL", chart = chartShew,
```

```

params = list(threshold = 3), quiet = TRUE, covprob=c(0.95))

cal <- SPCproperty(data = X, nrep = 500, property = "calARL", chart = chartShew,
                  params = list(target = 370), quiet = TRUE, covprob=c(0.95))

cal

newX <- Artiklar_2 `$Artiklar`[104:130]

S <- runchart(chartShew, newdata = newX, xi = xihat)

par(mfrow=c(1,2),mar=c(4,5,0.1,0.1))

plot(newX,xlab="t")

plot(S,ylab=expression(S[t]),xlab="t",type="b",ylim=range(S,cal@res+2,cal@raw,-
cal@res-1,-cal@raw))

lines(c(0,100),rep(cal@res,2),col="red")

lines(c(0,100),rep(cal@raw,2),col="blue")

lines(c(0,100),-rep(cal@res,2),col="red")

lines(c(0,100),-rep(cal@raw,2),col="blue")

```

Console

```

> library(spcadjust)
> chartShew <- new("SPCShew", model = SPCModelNormal(), twosided = TRUE)
> X <- Artiklar_2 `$Artiklar`[1:101]
> xihat <- xiofdata(chartShew, X)
> str(xihat)
List of 3
 $ mu: num -0.0346
 $ sd: num 0.76
 $ m : int 101
> SPCproperty(data = X, nrep = 500, property = "ARL",
+             chart = chartShew,params = list(threshold = 3),
+             quiet = TRUE, covprob=c(0.95))
95 % CI: A threshold of 3 gives an in-control ARL of at least 126.6.
Unadjusted result: 370.4
Based on 500 bootstrap repetitions.
> cal <- SPCproperty(data = X, nrep = 500, property = "calARL",
+                   chart = chartShew,params = list(target = 370),
+                   quiet = TRUE, covprob=c(0.95))
> cal
95 % CI: A threshold of 3.445 gives an in-control ARL of at least 370.
Unadjusted result: 3
Based on 500 bootstrap repetitions.
> newX <- Artiklar_2 `$Artiklar`[104:130]
> S <- runchart(chartShew, newdata = newX, xi = xihat)
> par(mfrow=c(1,2),mar=c(4,5,0.1,0.1))
> plot(newX,xlab="t")
> plot(S,ylab=expression(S[t]),xlab="t",type="b",
+       ylim=range(S,cal@res+2,cal@raw,-cal@res-1,-cal@raw))
> lines(c(0,100),rep(cal@res,2),col="red")

```

```
> lines(c(0,100),rep(cal@raw,2),col="blue")  
> lines(c(0,100),-rep(cal@res,2),col="red")  
> lines(c(0,100),-rep(cal@raw,2),col="blue")
```



