

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**RASSAL İŞ SÜRELERİ ALTINDA ÖĞRENME EĞRİSİ ETKİLİ MELEZ AKIŞ
TİPİ ÇİZELGELEME**

YÜKSEK LİSANS TEZİ

Fatih AYDIN

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Kürşad DERİNKUYU

ARALIK 2019

Fen Bilimleri Enstitüsü Onayı

.....
Prof. Dr. Osman EROĞUL
Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığımı onaylarım.

.....
Prof. Dr. Tahir HANALIOĞLU
Anabilimdalı Başkanı

TOBB ETÜ, Fen Bilimleri Enstitüsü'nün 171311019 numaralı Yüksek Lisans Öğrencisi **Fatih AYDIN**'ın ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "**RASSAL İŞ SÜRELERİ ALTINDA ÖĞRENME EĞRİSİ ETKİLİ MELEZ AKIŞ TİPİ ÇİZELGELEME**" başlıklı tezi **17.12.2019** tarihinde aşağıda imzaları olan jüri tarafından kabul edilmiştir.

Tez Danışmanı : **Doç. Dr. Kürşad DERİNKUYU**
TOBB Ekonomi ve Teknoloji Üniversitesi

Jüri Üyeleri : **Prof. Dr. Sinan GÜREL (Başkan)**
Orta Doğu Teknik Üniversitesi

Doç. Dr. Ayşegül ALTIN KAYHAN.....
TOBB Ekonomi ve Teknoloji Üniversitesi

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Fatih AYDIN

ÖZET

Yüksek Lisans Tezi

RASSAL İŞ SÜRELERİ ALTINDA ÖĞRENME EĞRİSİ ETKİLİ MELEZ AKIŞ

TİPİ ÇİZELGELEME

Fatih AYDIN

TOBB Ekonomi ve Teknoloji Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Doç.Dr. Kürşad DERİNKUYU

Tarih: Aralık 2019

Üretim çizelgeleme ile süreçlerin düzenlenmesi, işlerin nerede ve ne zaman yapılacağına belirlenerek iş akışlarının eniyilenmesi amaçlanmaktadır. Çizelgeleme problemleri üretim alanının özelliklerine göre farklılaşmakta olup seri üretim alanlarında çizelgelemeye karşılık gelen terim akış tipi çizelgelemedir. Bu üretim sistemlerinin zamanla farklılaşması ve belirli kaynakların sayısının artırılması ise melez akış tipi sistemlerini oluşturmaktadır. Ele alınan sistemin bir özelliği de iş atlama olarak adlandırılan parçaların akış üzerindeki her aşamada işlem görme zorunluluğu olmamasıdır. Oluşturulması planlanan çizelge ile toplam parça tamamlanma süresinin enazlanması amaçlanmıştır. Çalışmada melez akış tipi çizelgeleme problemine ek olarak uygulama aşamasında gerçek hayatta karşılaşılabilecek zorluklardan sisteme dahil olan yeni parçaların işlem sürelerinin belirsiz olabilmesi ve benzer parçalar üzerinde edinilen tecrübe ile bu parçaların işlenmesi için gereken sürenin zamanla kısalabilmesi durumları ele alınmıştır. Sistemde işlenmiş parçaların üzerindeki öğrenme etkisi incelenmiş ve ayrıştırılmış, çizelgeleme problemine tabi parçaların iş sürelerinin istatistiksel yöntemler ile tahmini gerçekleştirilmiştir. İş atlamalı melez akış tipi çizelgeleme problemi için bir karma tamsayılı matematiksel model önerilmiştir. Problemin zorluğu sebebi ile belirli bir

boyutun üzerinde veri kümeleri için matematiksel model ile etkin çözümler elde edilmesi mümkün olmamıştır. Özellikle ilgili veri kümelerinde kullanılmak üzere genel olarak daha kısa sürede daha iyi olurlu çözümler elde edilmesi hedeflenerek Genetik Boş Makine Zamanı Doldurma Algoritması geliştirilmiştir. Geliştirilen meta sezgisel algoritmada iterasyonlar arası geçişlerde genetik algoritmanın çaprazlama, mutasyon ve seçim özellikleri kullanılmıştır. Genetik Boş Makine Zamanı Doldurma Algoritması ile eşzamanlı olarak işlerin kendi arasında çizelgelenme sıraları ve birden çok kaynağa sahip aşamalar için işlerin atandığı kaynaklar belirlenmektedir. Bu atamalar ve sıralama doğrultusunda elde edilen çizelgeler bireylere karşılık gelmektedir ve çizelgelerin toplam parça tamamlanma süreleri bireylerin uygunluk değerleri olarak belirlenmektedir. Parça işlem süreleri üzerinde çizelgeleme başlamadan önce ve çizelge üzerinde ilgili parçadan önce işlenmiş benzer parçalara göre öğrenme etkisi göz önüne alınmıştır. Parça işlem sürelerinin tahmin doğruluğu istatistiksel kontrol metotları ile ve tahmin ile elde edilen işlem sürelerinin oluşturduğu çizelgenin gerçek işlem süreleri ile oluşturulan çizelgeye olan uyumu ile netleştirilmiştir. Genetik Boş Makine Zamanı Doldurma Algoritması'nın etkinliği ise matematiksel model ve algoritmadan elde edilen çözümler kıyaslanarak değerlendirilmiştir.

Anahtar Kelimeler: Çizelgeleme, Melez akış tipi üretim sistemleri, Matematiksel programlama, Genetik algoritma

ABSTRACT

Master of Science

HYBRID FLOW SHOP SCHEDULING WITH LEARNING EFFECT UNDER UNCERTAIN PROCESS TIMES

Fatih AYDIN

TOBB University of Economics and Technology
Institute of Natural and Applied Sciences
Industrial Engineering Science Programme

Supervisor: Assoc.Prof. Kürşad DERİNKUYU

Date: December 2019

Production scheduling is optimizing workflows by organizing and determining when and where a certain task will be completed. Scheduling problems can be classified by the type of production environment and scheduling for mass production systems is under the topic of flow shop scheduling. Hybrid flow shop scheduling is a special case in flow shop scheduling where in some steps of the system, production line is modified by increasing the number of resources. In addition to hybridity, it is not mandatory for parts to be processed in every stage of the system. Developing a schedule with the objective of minimizing the sum of parts' completion times is aimed. The real-life difficulties during the application phase are considered to be uncertainty of processing times of the new parts included in the system and the learning effect on processing times and both aspects are included in the problem. Learning effect on previously manufactured parts is analyzed and learning effect is separated to obtain pure processing times. Processing times for new parts are then calculated from pure processing times with statistical learning methods and learning effect is included later. With the calculated processing times, a mixed integer linear mathematical model for hybrid flow shop scheduling with missing operations is proposed. Because of the size of the problem, it was not possible to obtain effective solutions with mathematical

model for data sets above a certain size. The Genetic Timetable Gap Filling Algorithm has been developed with the aim of achieving better feasible solutions in a shorter period of time, especially for using in bigger data sets. In the developed heuristic algorithm; selection, crossover and mutation properties of genetic algorithm are adopted. The Genetic Timetable Gap Filling Algorithm simultaneously determines the order in which the jobs will be scheduled and the resources to which the jobs are assigned. Learning effect on process times is calculated based on parts produced in the past and parts that are scheduled before. The schedules obtained by assignments and rankings correspond to the individuals of the population and the sum of parts' completion times are determined as the fitness values of the individuals. Estimation accuracy of the processing times is clarified by statistical control methods and the similarity of the schedules created by the estimated processing times is examined with the schedules created with actual processing times. The effectiveness of The Genetic Timetable Gap Filling Algorithm is evaluated by comparing the solutions obtained by mathematical model and the algorithm.

Keywords: Scheduling, Hybrid flow shop systems, Mathematical programming, Genetic algorithm

TEŞEKKÜR

Çalışmalarım boyunca değerli yardım ve katkılarıyla beni yönlendiren, birlikte çalışmaktan onur duyduğum kıymetli hocam Doç. Dr. Kürşad DERİNKUYU'ya,

Kıymetli zamanlarını ayırarak tezimi okuyan ve tavsiyelerde bulunan, çalışmamın daha iyi bir noktaya gelmesini sağlayan Prof. Dr. Sinan GÜREL ve Doç. Dr. Ayşegül ALTIN KAYHAN'a,

Değerli tecrübelerinden faydalandığım TOBB Ekonomi ve Teknoloji Üniversitesi Endüstri Mühendisliği Bölümü öğretim üyelerine,

Yüksek lisans eğitimim boyunca bana burs sağlayan TOBB Ekonomi ve Teknoloji Üniversitesi'ne,

Çalışmalarımda ve hayatımda attığım adımlarda her zaman yanımda olup bana inanan arkadaşlarıma,

Bugünlere gelmemi sağlayan, hiçbir zaman sevgi ve desteğini esirgemeyen aileme sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	iv
ABSTRACT	vi
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİL LİSTESİ	x
ÇİZELGE LİSTESİ	xi
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	9
2.1. Çizelgeleme Problemleri.....	9
2.2. Çözüm Yöntemleri.....	12
2.3. Veri Oluşturma - Makine Öğrenmesi Algoritmaları.....	15
2.4. Modelin Uyarlanması – Öğrenme Teorisi ve Eğrileri	19
3. METODOLOJİ	25
3.1. Problem Tanımı	25
3.2. Uygulama Adımları	27
3.2.1. İş süresi tahmini modeli	27
3.2.1.1. Çoklu doğrusal regresyon	28
3.2.1.2. Destek vektör regresyonu.....	28
3.2.1.3. Karar ağacı regresyonu	28
3.2.2. Öğrenme eğrisinin parça iş sürelerine etkisi	29
3.2.3. İş atlamalı melez akış tipi çizelgeleme matematiksel modeli	30
4. SEZGİSEL YAKLAŞIM	37
4.1. Değişkenlerin Kodlanması.....	37
4.2. Çizelge Oluşturma	38
4.3. Seçilim, Çaprazlama ve Mutasyon Fazları	42
4.4. Alternatif Çizelge Oluşturma Yöntemleri.....	42
5. UYGULAMA	45
5.1. İşlem Süresi Verisi Oluşturma.....	46
5.2. Tahmin Edilen İşlem Sürelerinin Doğruluğu.....	49
5.3. Matematiksel Modelin Çözüm Kabiliyetleri	51
5.4. Sezgisel Yaklaşımın Sonuçlarının İncelenmesi.....	52
6. SONUÇ VE ÖNERİLER	57
KAYNAKLAR	63
ÖZGEÇMİŞ	67

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Çizelgeleme problem tipleri.....	10
Şekil 2.2 : Makine öğrenmesi problem tiplerinin sınıflandırılması.....	16
Şekil 2.3 : Regresyon modellerinde uyum durumları.....	18
Şekil 2.4 : Destek vektör regresyonunda en uygun hiperdüzlem ve destek vektörleri	19
Şekil 2.5 : Wright'ın modeline göre parça iş süresi azalışı.....	20
Şekil 2.6 : Plateau modeline göre parça iş süresi azalışı.....	20
Şekil 2.7 : Stanford B modeline göre parça iş süresi azalışı.....	21
Şekil 2.8 : De Jong modeline göre parça iş süresi azalışı.....	22
Şekil 2.9 : S-Eğrisi modeline göre parça iş süresi azalışı.....	22
Şekil 2.10 : Jaber-Glock modeline göre parça iş süresi azalışı.....	23
Şekil 4.1 : Genetik boş makine zamanı doldurma algoritmasının kromozom yapısı.	38
Şekil 4.2 : Genetik boş makine zamanı doldurma algoritması çizelgeleme süreci....	41
Şekil 4.3 : İş ötelemeli genetik boş makine zamanı doldurma algoritmasının kromozom yapısı.....	43
Şekil 4.4 : İş öteleme süreci.....	44
Şekil 5.1 : Matematiksel model ve meta sezgisel algoritma ile elde edilen çizelgelerin karşılaştırması.....	54
Şekil 6.1 : 2. veri kümesine ait sonuçların karşılaştırılması.....	58
Şekil 6.2 : 3. veri kümesine ait sonuçların karşılaştırılması.....	58
Şekil 6.3 : Meta sezgisel algortmada iş atlama işlevinin sonuçlara etkisi.....	59

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 : Akış tipi çizelgeleme problemlerinin çözümünde kullanılan algoritmalar.....	13
Çizelge 5.1 : Regresyon modellerinde kullanılan bağımlı ve bağımsız değişkenler..	46
Çizelge 5.2 : Kolmogorov – Smirnov testi veri ve sonuçları.....	47
Çizelge 5.3 : Durbin – Watson testi veri ve sonuçları.....	47
Çizelge 5.4 : Kurulan regresyon modellerinin tahmin sapmaları.....	48
Çizelge 5.5 : Kurulan regresyon modellerinin R^2 değerleri.....	48
Çizelge 5.6 : Tahmin edilen iş sürelerinin tutarlılık karşılaştırmaları.....	49
Çizelge 5.7 : Makine verimi dahil edildiğinde tahmin edilen iş sürelerinin tutarlılık karşılaştırmaları.....	50
Çizelge 5.8 : Koşulların işlemci süre istatistikleri.....	51
Çizelge 5.9 : Matematiksel model ve meta sezgisel algoritmadan elde edilen sonuçların 2. tip veriler için karşılaştırması.....	53
Çizelge 5.10 : Matematiksel model ve meta sezgisel algoritmadan elde edilen sonuçların 3. tip veriler için karşılaştırması.....	55

1. GİRİŞ

Üretim sistemleri, işletmelerin kaynak veya hammaddeden satışı gerçekleştirilebilecek bir ürün ortaya koyabileceği katma değer sağlayan sistemlerdir. İmalat sektörünün temeli bu sistemler üzerine kurulmuştur. Üretim, sanayi devrimi öncesinde el ile bir ürün ortaya çıkarmak olarak değerlendirilirken; sanayi devrimi ile birlikte üretimin günümüzde bildiğimiz şekle bürünmesindeki ilk adım atılmıştır. Makinelerin üretimde devreye girmesi ile fabrikaların sayısında da artış gözlenmiştir. 1908 yılında Ford'un Model T aracını üretmek için oluşturduğu montaj hattı ilk bütün üretim sistemi olarak değerlendirilmektedir. İlerleyen yıllarda üretim sistemleri yaygın hale geldikçe bu sistemler üzerine maliyet etkinliği, kapasite, kalite gibi konularda başlayan çalışmalar günümüzde de sürmektedir.

Üretim sistemleri, zaman geçtikçe kuruldukları günden daha farklı dinamiklere sahip olabilmektedirler. İlk akla gelebilecek değişimlerden bazıları; sistemden ihtiyaç duyulan üretim adetlerinin artması veya azalması, farklı üretim tekniklerinin ortaya çıkması ve toplam kalite yönetimi altında standartların farklılaşmasıdır. Sistemlerin bu farklılıklara adapte olması gerekmektedir. Günümüzden verilebilecek bir örnek de maliyet etkinliğin ve kalitenin iyileştirilmesi için hız kazanan dijital dönüşüm çalışmalarıdır.

Değişen dinamikler üretim sistemlerinde belirli aşamalarında farklılaşmaya gidilmesine sebep olabilmektedir. Örneğin bir sistemin daha çok sayıda veya daha yüksek kalitede çıktı verebilmesi için ilave yatırım yoluna gidilebilir. Maliyet etkinlik göz önüne alındığında mevcut sistemin en verimli kullanımı için yapılacak çalışmalar ilave yatırımdan daha öncelikli olabilmektedir. Üretim sistemleri üzerine gerçekleştirilen çalışmaların büyük çoğunluğu mevcut sistemin iyileştirilmesi üzerine gerçekleştirilmiştir. Her sistemde olduğu gibi ölçüm, gelişimin ilk aşaması olup; büyük ölçekli üretim sistemlerinin ölçümü için gereken verinin toplanması önemli bir başlıktır.

Dünyadaki veri miktarının üstel şekilde artışı, pek çok alandaki artan veri toplama kabiliyetinin bir ürünü olup; üretim sektörü de veri toplama yetisi üst düzeyde olan bir alandır. Çok sayıda farklı format, anlam ve kalitede karşımıza çıkabilecek bu veriler; üretim sistemine ait en küçük birimlerin parametrelerinden, çevresel kaynaklı verilere kadar uzanabilir (Davis ve diğ., 2015). Büyük miktardaki verinin artışı ve kullanılabilirliği durumu sıklıkla büyük veri olarak anılmıştır (Lee ve diğ., 2013).

Çalışmada havacılık imalat sektörüne ait bir üretim sistemi ele alınmıştır. Üretim sisteminin yıllar içerisinde farklılık gösteren ürünler ve artan üretim adetleri karşısında mevcut kaynaklar ile mümkün olduğunca sürdürülebilmesi hedeflenmektedir. Çalışma ile sistemdeki makine etkinliklerinde iyileştirme sağlanması amaçlanarak sistemin tüm niteliklerini kapsayan bir çizelgeleme modeli önerilmesi planlanmıştır.

Havacılık, uzun yıllar önce özellikle savaşlarda kullanılan uçurtma, balon gibi araçların geliştirilmesi ile başlamış kabul edilse de; uçak olarak adlandırabileceğimiz ilk araç Wright kardeşlerin attığı adımın sonucu ortaya çıkmıştır. “Flyer 1” olarak adlandırılan uçağın yapımında malzeme seçimi önemli rol oynamıştır. Orville Wright, kardeşi ile geliştirdiği uçağıyla 1903 yılında 12 saniye havada kalarak ilk pilotlu ve motorlu uçuşa imza atmıştır.

Havacılık imalat sektörü ise 1907 yılında ABD Ordusu’nun girişimleri ile başlamıştır. Bu süre içerisinde Avrupa ülkeleri de havacılık konusunda büyük ilerleme kat etmiştir. I. Dünya Savaşı’nın da etkisi ile büyüyen havacılık imalat sektörü; 1918’in sonlarında ABD’de 200.000 kişinin istihdamını sağlamıştır. Küresel havacılık imalat sektörü günümüzde 850 milyar doları aşkın bir değere sahip olup imalat alanındaki gelişmelerin büyük bir kısmı havacılık alanında ortaya çıkmıştır. Havacılık ve havacılık imalat sektörleri tarihte savaşlardan ve uluslararası politik ilişkilerden etkilenen alanlar olup, sektördeki atılımların çoğu savaş dönemlerinde ülkelerin mühendislik alanında birbirine üstünlük kurmaya çalışmasının bir sonucu olarak ortaya çıkmıştır.

Üretim sistemlerinde çizelgeleme, eski tarihlerde üretim faaliyetlerinin kısıtlı oluşu sebebiyle basit olan üretim sistemlerinin çizelgelemesi ile başlamış olup bu sistemlerin çizelgenmesinde sadece işin başlangıç ve bitiş zamanı bilgilerine yer verilmiştir. Çizelgeleme faaliyetlerinin Gantt şeması benzeri formlar ile zaman takibinin yapılması

anlamına geldiđi dönemlerden günümüze pek çok konuda yeni keşifler ve ilerlemeler mevcut olsa da üretimin idaresinin acil ürünlerin zamanında sevkini ancak sistematik olmayan yollar ile sağlamak üzerine kurulduđu sistemler de hala mevcuttur.

Çizelgelemenin ilk yıllarında personel iş yükü üzerinde durulmuş ve personele her günün başında o gün tamamlaması gereken iş emirleri verilmesi konusu ele alınmıştır. Sonrasında üretim faaliyetlerinin birbiriyle çakışmayacak şekilde koordinasyonu konusu gündeme gelmiştir. İlerleyen yıllarda süreçlerin başlangıç zamanları, işlem süreleri, kim tarafından ve hangi makine ile tamamlanacağı bilgilerini içeren formlar kullanılmaya başlanmıştır. Çalışmalara sonlu kapasitenin de dahil edilmesi, sonradan eklenecek iş paketlerinin halihazırda üretim gerçekleştiren bir sistemi nasıl etkileyebileceđi konusunda fikir sahibi olmanın önünü açmıştır.

Bilgisayar tabanlı çizelgeleme ise karşımıza ilk kez 1956 yılında kritik yol metodu (CPM) adıyla proje çizelgeleme alanında çıkmıştır. Bilgisayar tabanlı üretim çizelgelemenin ortaya çıkması daha ilerleyen yıllarda olmuştur. Verinin toplanabilmesi ve işlenebilmesinin yıllar içerisinde kolaylaşması da üretim çizelgelemenin hızla gelişmesinde önemli rol oynamaktadır. Günümüzde veri toplama ve işleme konusundaki ilerlemelere rağmen ürünün imal edilip müşteri ile buluşturulabilmesi kimi alanlarda yeterli görülebilmektedir veya çizelgeleme konusunda çalışmalar gerçekleştirilse de sistemin bütünü entegre edilemediğinden bu çalışmalardan tam verim alınamayabilmektedir.

Ele alınan sistem, havacılık sektörüne ait çok sayıda ürünün imalatının yapılabileceđi kabiliyete sahiptir. İmalatın gerçekleştirildiđi aşamalar temel olarak makine yoğun ve emek yoğun olarak ikiye ayrılmaktadır. Makine yoğun aşamalarda standardizasyon ileri düzeyde olup işlemlerle ilgili sonuçlara parametrik yöntemler ile kolaylıkla ulaşılabilir. Emek yoğun aşamalar ise makineden çok operatörün belirleyici olduđu alanlardır ve aynı parametrik yöntemler ile elde edilecek sonucun doğruluđu makine yoğun aşamalara göre daha zayıf olabilmektedir.

Bu durumlara ek olarak hava aracı üretiminde üretilecek nihai ürünün adetleri farklı sektörlere göre genellikle daha az olduğundan ve ürün daha karmaşık olduğundan sistemden geçen parçalar farklı sektörlere göre daha yüksek çeşitliliğe sahiptir. Bu

nedenle seri üretilen parçaların dahi kimi durumlarda farklı işlemler görmesi kaçınılmazdır.

Üretim sistemlerinin bu tür özelliklere göre bir gruplandırması mevcuttur. Ana ayırım tesis tipi ile yapılmakta olup bu sistemleri barındıran tesisler proses tesisi ve imalathane olarak sınıflandırılmıştır. Sürekli akış ve toplu iş sistemleri proses tesislerinin alt kırılımıdır. İmalathaneler ise üretim ve montaj olarak ikiye ayrılır. Üretim alanında iş tipi üretim, hücreli üretim ve akış hatları bulunurken montaj alanlarında sabit konumda montaj, montaj atölyesi veya montaj hatları ile montaj gerçekleştirilebilir.

Çizelgeleme perspektifinden bakıldığında da aynı tip üretim sistemleri mevcut olmasına rağmen farklı sınıflandırmalar mevcuttur, bu sistemler çizelgeleme literatürüne göre incelendiğinde; en temel iki grupta seri üretimin gerçekleştirildiği ve parçaların minimum düzeyde özelleştirildiği sistemler akış tipi olarak, parçaların özelleştirilmesinin mümkün olduğu ve sistemdeki herhangi bir operasyona herhangi bir sırada girebileceği durumlar iş tipi olarak adlandırılmıştır.

Probleme konu sistem, bünyesinde her iki tipten de özellikler barındırmakta olup akış tipinin iki temel alanda özelleştirilmiş hali olarak tanımlanmıştır. Bu alanlar;

- Bir işlemin gerçekleştirilebildiği birden çok makine olması durumu,
- Her parçanın her işleme tabi olma zorunluluğu olmaması durumu

Problemin gereklerine göre şekillenen çizelgeleme probleminde, sistemde yer alan parçaların tamamlanma sürelerinin toplamının en küçüklenmesi amaçlanmıştır. Tamamlanma sürelerinin toplamının en küçüklenmesi amacının seçilmesi, sistemdeki tüm makinelerin toplam çalışma sürelerinin de etkin şekilde yönetilebilmesi içindir. Tipik bir çizelgeleme probleminin temel girdileri; sistemde bulunan makineler, aşamalar ve eşleşmeleri, sistemde işlenmesi planlanan parçalar ve bu parçaların hangi makine veya aşamaları ziyaret etmesi gerektiği, bu parçaların her süreç için işlem süreleri, parçaların hazır olma ve teslimat süreleri olarak özetlenebilir.

Problemin girdilerinden biri olan parça işleme süreleri bulunmadan çizelgeleme yapılması mümkün değildir. Fakat ele alınan sistemin çok sayıda farklı parça tipi

barındırması ve bu parçaların üretim adetlerinin düşük olması sebebiyle çizelgelemesi planlanan parçaların ilk kez üretilecek olması söz konusu olabilmektedir. Bir parça ilk kez üretilmeyecek olsa dahi sistemin yüksek kişiselleştirme olanakları sebebiyle bir parçanın belirli bir konfigürasyonu için geçmiş işlem süresi bilgisi bulunmayabilmektedir.

Çizelgeleme probleminin parametrelerinden birini oluşturacak parça işlem sürelerinin, parçaların fiziksel ve kimyasal özelliklerine göre mevcut durumda parça işlem süresi ve özellikleri bilinen parçalardan oluşan bir öğrenme kümesinden faydalanarak istatistiksel makine öğrenmesi yöntemleri ile tahmin edilmesi yoluna gidilmiştir. İşlem süreleri gibi sürekli değerlere sahip olabilecek verinin tahmini için regresyon modelleri incelenmiştir. Modele dahil edilecek parametrelerin seçimi tamamlandıktan sonra oluşturulan regresyon modellerinde aşırı uyum veya yetersiz uyum durumları incelenmiş ve bu sebeplerle tahmin performansında düşüş yaşanmasının önüne geçilmesi hedeflenmiştir.

Parça işlem sürelerinin tahmininde öğrenme eğrisi etkisi ele alınmıştır. Benzer sektörler için gerçekleştirilen öğrenme eğrisi çalışmaları değerlendirilerek ve mevcut sistemde işlem süresi bilinen parçaların zamanla işlem süresi azalışları incelenerek sisteme uygun öğrenme modeli ve bu öğrenme modelinin parametreleri belirlenmiştir. Parça işlem sürelerinin tahmininde kullanılan test kümesindeki tüm parça işlem süreleri öğrenme etkisinden arındırılmıştır ve işlem süresi tahminleri öğrenme etkisi yok sayılarak hesaplanmıştır. Tahmin edilen işlem sürelerine ilgili parçaların üretilmesi planlanan zaman aralığına göre öğrenme etkisi sonradan dahil edilmiştir.

Öğrenme etkisi hesaplanırken parçalar gösterdikleri benzerliklere göre gruplanmış ve aynı gruptaki parçalar tek bir eğride ele alınmıştır. Bir parçanın üretilmesi, aynı gruptan başka bir parçanın üretim süresine pozitif yönde etki etmektedir. Çizelgelenecek parçaların işlem süreleri, çizelgenin başlangıç anında öğrenme eğrileri üzerinde buldukları konumlara göre belirlenmektedir. Buna ek olarak çizelge içerisinde aynı gruptan birden fazla parçanın çizelgelenmesi durumunda, parçaların işlem süreleri çizelge içinde de revize edilebilmektedir.

Çalışmaya konu sistemin tüm özelliklerini barındıran çizelgeleme problemi için toplam parça tamamlanma süresinin en küçüklenmesinin amaçlandığı bir

matematiksel model önerilmiştir. Matematiksel model, akış tipi çizelgelemeye ek olarak problemin melezlik ve iş atlama özelliklerini de ele alabilmek üzere geliştirilmiştir. Bu alanda geçmişte gerçekleştirilen çalışmalarda melezlik ve iş atlama ayrı ayrı ele alınmış veya iş atlama, parçanın atlayacağı aşamadaki işlem süresinin sıfırlanması ile sağlanmıştır. Ele alınan problemin kesin çözümünün elde edilmesi için iş atlama ve melezliğin bir arada göz önüne alındığı bir matematiksel model geçmişte tanımlanmamıştır. Problemin NP-zor yapısı sebebiyle de öngörülebileceği üzere, geliştirilen iş atlamalı melez akış tipi çizelgeleme matematiksel modeli her boyuttaki veri kümesi için makul sürede çözüm üretememektedir.

Matematiksel modele ek olarak çözüm elde etme süresinin de önem taşıdığı durumlar için sezgisel çözüm yöntemleri incelenmiştir. Literatürde melez akış tipi çizelgeleme için farklı algoritmalar önerilmiştir ancak iş atlama özelliğinin probleme dahil edilmesi ve amaç fonksiyonu olarak parça tamamlanma sürelerinin toplamının benimsenmesi sebebiyle Genetik Boş Makine Zamanı Doldurma Algoritması geliştirilmiştir.

Geliştirilen Genetik Boş Makine Zamanı Doldurma meta sezgisel algoritması, çözüm adımlarında genetik algortmada kullanılan çaprazlama, seçim ve mutasyon özelliklerini kullanmaktadır. Algoritmanın değişkenlerini kodlama aşamasında kromozom, işlerin çizelgeleme sıralamasını belirleyen kısım ve işlerin makinelere atamasını belirleyen kısım olarak iki parça halinde ele alınmıştır. Kromozom ikili sayılar üzerine kurgulanmış ve bu ikili sayılar kendi içerisinde gruplanarak on tabanında probleme girdi sağlayan sayılara dönüştürülerek kullanılmıştır. Kromozomu oluşturan tüm genler ikili olup, çizelgelemede genler gruplandırılıp onluk tabana çevrildikten sonra elde edilen sayılar kullanılmaktadır. Meta sezgisel algoritma, kromozomun kısımlarından elde edilen iş makine atamaları ve iş çizelgeleme önceliklerine göre işleri çizelge üzerinde olabilecek en erken noktalara çizelgelemektedir. Problem yapısına göre her kromozom bir olurlu çizelgeye karşılık gelmektedir ve bireyin uygunluk değeri, bu çizelgenin amaç fonksiyonu değeri olarak belirlenmiştir.

Matematiksel model ve meta sezgisel algortmadan elde edilen sonuçlar farklı boyutlardaki problemler üzerinde karşılaştırılmıştır. Elde edilen amaç fonksiyonları ve bu değerleri elde etmek için ihtiyaç duyulan süreler incelenmiştir.

Matematiksel modelin belirli bir boyuttan küçük problemlerde kesin çözüm alınabilmesi ve büyük problemlerin çözümünde kullanılacak algoritmaların sonuçlarının etkinliğinin değerlendirilmesi için kullanılması hedeflenirken; meta sezgisel algoritma ile daha büyük boyutta problemlere kısa sürede iyi olurlu çözümler bulunması amaçlanmaktadır.



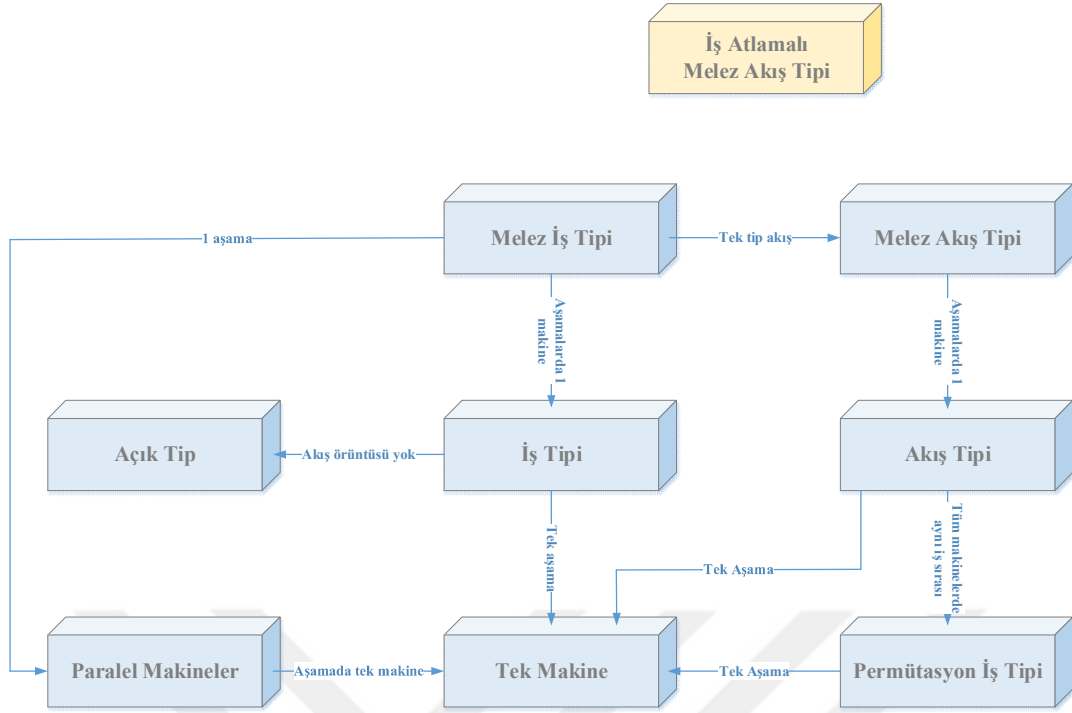


2. LİTERATÜR TARAMASI

Havacılık imalat sektörüne ait bir sistemin üretiminin çizelgeleneceği problemde, öncelikle sistemin sahip olduğu özelliklerden yola çıkarak problem tipinin belirlenmesi amaçlanmıştır. Belirlenen problem tipine ve amaç fonksiyonuna göre çözüm yöntemleri incelenecektir. Bu yöntemler; kesin çözüm yöntemleri, sezgisel algoritmalar ve simülasyon gibi alternatif yöntemlerden oluşmaktadır. Belirlenen yöntemin uygulamaya geçirilmesinden önce problemin girdilerinin tam olarak belirlenmesi gerekmektedir. Bir sonraki kısımda temel girdilerden parça işlem süresinin belirlenebileceği yöntemler araştırılacaktır. Literatür taramasının son kısmında ise öğrenme teorisi ve öğrenme eğrisinin probleme nasıl uyarlanabileceğine dair bir inceleme gerçekleştirilecektir.

2.1. Çizelgeleme Problemleri

Üretim çizelgeleme, sistemin kriterlerinin en iyi şekilde karşılanması için mevcut kaynakların atamalarının ve zaman aralıklarının belirlenmesi olarak tanımlanmaktadır (Graves, 1981). Bu atamalar, tamamlanması gereken işlerin makinelerde işleme sıra veya diziliminin zaman sınırları da değerlendirilerek belirlenmesi üzerinedir (Johnson & Montgomery, 1974). Üretim çizelgeleme problemlerinde işlerin teknolojik kısıtları belirtilmelidir. Teknolojik kısıtlar öncelikle işlerin makinelerdeki akış biçimine göre belirlenmektedir. Bu durum da çizelgeleme problemlerindeki ortamların tek makine, paralel makine, akış tipi, permütasyon akış tipi, iş tipi, melez akış tipi, melez iş tipi ve açık tip olarak farklı şekilde ele alınmasını gerektirmektedir (Maccarthy & Liu, 1993). Çizelgeleme problemlerinin üretim sistemine göre sınıflandırmaları ve bu sınıflar arasındaki temel farklılıklar Şekil 2.1’de ifade edilmiştir.



Şekil 2.1 : Çizelgeleme problem tipleri.

Üretim çizelgeleme problemlerinde bir veya birden çok eniyileme kriteri bulunmakta olup, French (1982), Bedworth ve Bailey (1987) ile Maccarthy ve Liu (1993)'ya göre belirlenmiş bu kriterler aşağıda verilmiştir.

- J : $j \in J$ işler kümesindeki bir J işini ifade etmektedir.
- C_j : Çizelgenin 0 zamanından J_j işinin tamamlanmasına kadar geçen süreyi ifade etmektedir.
- C_{max} : Tamamlanma zamanlarının (C_j) en büyüğüne eşittir ve yapılan çizelgelemenin toplam süresini ifade eder.
- F_j : İşin işlenmeye hazır olduğu zaman ile işlemlerinin bitişi arasındaki geçen süredir, işin atölyede geçirdiği süreye karşılık gelir.
- W_{kj} : J_j işinin k-1. sıradaki operasyonu tamamlandıktan sonra k. sıradaki operasyonu başlayana kadar geçen bekleme zamanıdır.
- L_j : İşin teslim zamanı ve tamamlanma zamanı arasındaki farktır. İşin tamamlanma zamanı teslim zamanından sonra ise iş pozitif geç kalmaya sahip

olurken tersi durumlarda iş negatif geç kalmaya veya erken tamamlanmaya (E_j) sahip olur.

- T_j : İşin tamamlanma zamanının teslim zamanına göre gecikme süresidir.

Bu amaçlar; kaynakların etkin kullanımı, talebin hızlı karşılanması ve teslim tarihlerine adapte olabilme konularında verilecek kararlarla ilişkilidir.

Firmaların üretim hattının zamanla taleplere göre farklılaşması sonucu, firma bünyesinde çeşitli işler için birden fazla makine bulundurması melez akış tipini oluşturur (Ruiz ve Vazquez-Rodriguez, 2010). Dios ve diğ., (2018)'ın her parçanın her makineye uğramama durumunu da ele alan atlanan işlemler barındıran melez akış tipi üretim tanımı da problem ile uyum sağlamaktadır. Ruiz ve diğ., 2008'deki sistem tanımları, çalışmada ele alınan sistem ile karşılaştırılmıştır. Sistemlerin gösterdiği benzerlikler göz önüne alındığında probleme konu sistem, çizelgeleme modelinin kurulması açısından iş atlamalı melez akış tipi üretim sistemi sınıfına dahildir. (Ruiz ve diğ., 2008)

Bu problem tipi için çoğunlukla kullanılan amaç fonksiyonları; tamamlanma zamanları, gecikme süreleri veya çok kriterli olabilmektedir. Bu problemin tek tip makineler bulunduran iki aşamalı ve aşamalardan sadece bir tanesinde birden çok makine olan bir sistemden daha büyük olmayan sistemler için NP-Zor olduğu ispatlanmıştır (Gupta, 1988).

Literatürdeki melez akış tipi çizelgeleme problemleri çoğunlukla 2 aşamalı ve tek tip makineli sistemler için ele alınmış olsa da, melez akış tipi çizelgelemenin çok makine için gerçekleştirildiği çalışmalar mevcuttur. Fakat öğrenme eğrisi ve iş süresi tahmini, tek makineli sistemler için ele alınmıştır. Öğrenme eğrisini barındıran çalışmalarda önerilen çözüm yöntemleri arasında kesin çözüm yöntemleri, sezgisel yöntemler, simülasyon ve yapay zeka ile çizelgeleme bulunmaktadır. (Priore ve diğ., 2006; Priore ve diğ., 2014, Azizoglu ve Kirca, 1998; Cho ve Wysk, 1993; Ouelhadj ve Petrovic, 2009)

Linn ve Zhang (1999), melez akış tipi çizelgeleme için belirtilen tarihe kadar çalışılmış problem tiplerini ve her problem tipi için uygulanmış çözüm yöntemlerini incelemiştir.

Problemin belirli koşullar altındaki NP-Zor yapısı ve buna göre çizelgeleme algoritmalarının etkinliği değerlendirilmiştir. Çalışmada değinilen sonuçlardan biri, melez akış tipi çizelgelemede teori ve uygulama arasındaki açıklığın çok geniş olduğudur ve araştırmacılar bu farkı kapatmaya yönelik çalışmalar yapılmasının büyük önem arz ettiği görüşündedir.

2.2. Çözüm Yöntemleri

Çalışmaya konu üretim sisteminde literatürde ele alınan problemlerin çoğunluğunun aksine bağımsız makinelerden oluşan 2’den fazla aşama bulunmaktadır. Değişken parça işlem sürelerine sahip veya öğrenme eğrisi etkili çizelgeleme problemleri literatürde ele alınmış olsa da bu çalışmalarda çok aşamalı çizelgelemenin gerçekleştirilmesinden çok veriye odaklanılmış ve veri üzerinde işlem sürelerinin elde edilmesi ve öğrenme eğrisinin hesaplanmasına dair çalışmalar gerçekleştirilmiştir. Bu çalışma kapsamında parçaların fiziksel ve kimyasal özelliklerine, makinenin durumuna ve içinde bulunan zamana göre farklılık gösteren rassal parça iş süreleri ve öğrenme eğrisi göz önünde bulundurularak toplam parça sürelerini en küçükleyen çok aşamalı iş atlamalı melez akış tipi çizelgeleme problemi ele alınacaktır.

Melez akış tipi problemler genellikle iki aşamalı, üç aşamalı ve m aşamalı olmak üzere 3 tip altında incelenmektedir. Gerçek üretim sistemlerine en benzer tip ise m aşamalıdır. Kesin çözüm algoritmaları bu problemin çözümü için kullanılan ilk metotlardandır; Lagrange, dal sınır algoritması (Portmann ve diğ., 1998, Chang ve Liao, 1994). Sonrasında sezgisel algoritmalar bu problemin çözümünde kullanılmaya başlanmıştır. Akış tipi çizelgeleme problemlerinin çözümü için kullanmış çizelgeleme sezgisel algoritmaları Çizelge 2.1’de yer almaktadır.

Kullanılan algoritmalar, oluşturdukları vektörler aracılığı ile daha iyi çözüme yönelmektedir. Bu durum da taranan alanın sürekli olmasını gerektirmektedir ve karma tamsayı parametrelere sahip bir problemin çözümünde sürekli değerlerin tamsayılara yuvarlanması ihtiyacı doğmaktadır. Ek olarak çizelge zamanının en küçüklenmesi amacına sahip problemlerde en iyi sonuca ulaşmak, parça tamamlanma sürelerinin toplamının en küçüklenmesi amacına sahip problemlere göre daha kolaydır.

Çizelge 2.1 : Akış tipi çizelgeleme problemlerinin çözümünde kullanılan algoritmalar.

Yöntem	Referans
Genetik Algoritma	Oğuz ve Ercan, 2005; Engin ve diğ., 2011
Yapay Arı Kolonisi	Li ve diğ., 2016
Tekrarlı Açgözlü Algoritma	Ying ve diğ., 2014
Guguk Kuşu Arama Algoritması	Marichelvam ve diğ., 2014
Dağılımın Tahmini Algoritması	Wang ve diğ., 2015
Yerel Arama Algoritması	Lei ve Guo, 2016
Sirkesineği Optimizasyon Algoritması	Li ve diğ., 2016

Enerji tüketiminin de ele alındığı başka bir melez akış tipi sistem için çizelge zamanının en küçüklenmesi probleminin çözümünde de genetik algorithmadan faydalanılmış ve en iyiye yakın sonuçlara ulaşılabilmiştir (Schulz, 2019).

Qin ve diğerleri (2015) tarafından gerçekleştirilen iş sürelerinin belirsizliğinin ele alındığı bir çalışmada çözüm yöntemi olarak yeniden çizelgeleme üzerine bir karınca kolonisi algoritması önerilmiştir. Çalışma çizelgelenen sisteme eşzamanlı olarak sağlanan veri akışlarının da sistem üzerinde henüz işleme alınmamış parçaların işlem süresini etkilemesi durumunu ele almıştır. Çalışmada çizelge süresinin en küçüklenmesi amaçlanmıştır ve çalışmada ele alınan işlem süresi parametreleri belirli bir dağılıma göre türetilmiştir (Qin ve diğ., 2015).

Bir popülasyonda bulunan ve problem parametrelerine karşılık gelen kromozomlara sahip bireylerin (çözüm kümesi) kendi arasında çaprazlanması ile popülasyonun nesilden nesle ilerlemesini temel alıp nesiller ilerledikçe daha iyi amaç fonksiyon değerine sahip bireylerin elde edilmesini hedefleyen; kromozomların kodlanması ve uygunluk değerlerinin hesaplanması aşamalarında uygulanabilecek farklı yöntemler ile özelleştirilebilmesi mümkün olan ve pek çok farklı problem türü için kullanılabilen genetik algoritma, çalışmada ele alınan türde problemlerin çözümünde de tercih edilmiştir.

Genetik algoritmanın sözde kodu aşağıdaki gibidir:

Rastgele L uzunluğunda kromozomlar oluştur. $k \in K$

while sonlandırma koşulu = **yanlış**

forall k :

$$f_k^* = \max(f_k)$$

$$P_s = k.EbeveynSec()$$

$$P_c = Caprazlama(P_s)$$

$$k_{new} \leftarrow Elitizm(k)$$

$$k_{new} \leftarrow P_c$$

$$k \leftarrow k_{new}$$

next

- Ebeveyn seçimi, popülasyonu oluşturan bireylerin en iyi uygunluk değerine sahip ilk %50 arasından yapılır.
- Çaprazlama, bir bireyin oluşması için gereken kromozomlardan her birinin ebeveynlerin ilgili sıradaki kromozomundan birinin rastgele seçilmesi ile sağlanır, çaprazlamada mutasyon durumu ise belirli bir olasılığa göre yeni bireyin kromozomunun ebeveynlerden birinden gelmek yerine rastgele olarak belirlenmesini ifade eder. Mutasyon, çözümler arasındaki çeşitlendirmeyi yükselten bir faktördür.
- Elitizm, yeni jenerasyonu oluşturacak bireylerin çaprazlama ile belirlenmesine ek olarak ebeveyn popülasyonunun belirli bir oranının en iyi uygunluk değerine sahip olanların doğrudan bir sonraki jenerasyona taşınması ile sağlanır.
- Yeni jenerasyonların elitizm ve çaprazlama sürekli olarak daha iyi uygunluk değerlerine sahip bireylerden oluşması hedeflenirken, mutasyon faktörü ile çeşitlendirme de sağlanır.

Genetik algoritma, çözüm havuzunun sürekli iyileştirilmesi için genel bir yapı sunarken; farklı ebeveyn seçimi, çaprazlama, mutasyon ve elitizm tanımlamaları yapılarak farklı çözüm sistemleri kurulması mümkündür.

Yerel arama algoritması, rastgele bir noktadan (çözüm) başlayarak bir noktadan daha iyi çözüme sahip bir diğerine ilerlemek üzerine kuruludur. Komşu nokta arama fonksiyonu genetik algortmada olduğu gibi uygunluk fonksiyonu benzeri bir fonksiyona bağlıdır. Algoritmanın çözüm odaklılığı ve açgözlülük derecesi bu

fonksiyonun içerisinde amaç fonksiyonunun iyileştirilmesinin aldığı pay ile belirlenir. Bir noktadan diğerine geçiş sadece bir değişkenin farklılaşması ile sağlanır. Yerel arama algoritmasının temel halinde yerel en iyi sonuçta tıkanma ihtimali mevcuttur.

Rassal model oluşturma genetik algoritmaları olarak da adlandırılan Dağılımın tahmini algoritmaları, çözüm noktalarını içeren popülasyonu her adımda güncellenen olasılık dağılım fonksiyonlarına göre belirlenir.

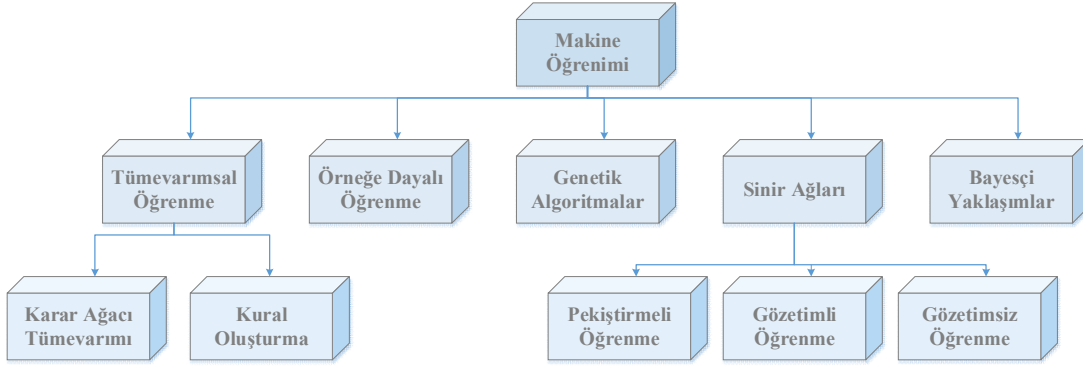
Günümüzde; doğada bulunan türlerin yaşamını idame ettirmesi ve nesillerinin devamını sağlamasından esinlenen pek çok algoritma, eniyileme problemlerinin sezgisel çözümünde kullanılmaktadır.

Doğadan esinlenen diferansiyel evrim algoritmalarının ortak özelliği, türlerin yaşam ortamı arayışında problemin çözüm uzayına karşılık gelen farklı bölgelere gitmesi ve iyi amaç fonksiyon değerlerine sahip çözümlere karşılık gelen iyi yaşam olanağı (besin, sığınma, eş) sunan bölgelere zamanla yönelim içerisinde olmasını ifade etmesidir. Bu yönelimler vektörler ile ifade edilir ve en iyi sonuca yakınsama bu vektörler ile sağlanır.

2.3. Veri Oluşturma - Makine Öğrenmesi Algoritmaları

Makine öğrenmesi algoritmalarının temel avantajı; öncesinde bilinmeyen, dolaylı, bilginin meydana çıkarılabilmesi ve veri kümelerindeki dolaylı ilişkilerin keşfedilebilmesidir. Eldeki veri miktarının fazlalığına duyulan ihtiyaç, algoritmanın niteliklerine göre değişim gösterebilmektedir fakat makine öğrenmesi algoritmalarının imalat sistemlerinde sonuç elde etmedeki etkinliği Alpaydın (2010), Filipic ve Junkar (2000), Guo ve diğ., (2008), Kim ve diğ., (2012), Nilsson (2005) gibi çalışmalar ile kanıtlanmıştır (Wuest ve diğ., 2016). Makine öğrenmesi algoritmalarının temel sınıflandırılması Şekil 2.2’de verilmiştir (Pham ve Afify, 2005).

Tümevarımsal öğrenmede makine, kendisine öğrenme kümesi olarak verilen veriyi kullanarak sonuçlar elde etmek için tüm veride kullanacağı kurallar oluşturur. Alt türlerden ilki olan karar ağacı tümevarımında karar ağacı, iç noktalar ve uç noktalardan oluşur.



Şekil 2.2 : Makine öğrenmesi problem tiplerinin sınıflandırılması.

Her nokta örnekler için bir ölçümü, bu noktalardan çıkan dallar da olası sonuçları temsil eder. Örneğin izlediği yol, hangi gruba dahil edileceğini belirler. Kural oluşturma ise karar ağacından farklı olarak doğrudan eğer-ise kuralları oluşturur. Kurallar bir sıraya tabi olmak zorunda değildir. Kurallar, örneğin öğrenme kümesindeki verilerle karşılaştırılmasında kullanılır ve örneğin hangi gruba dahil edileceğine karar verilir.

Örneğe dayalı öğrenmede tümevarımsal öğrenmeden farklı olarak sadece yeni bir örneğin sınıflandırılması gerektiğinde örneğin geçmiş veri ile ilişkisi incelenir. En yakın komşu, yerel ağırlıklandırılmış regresyon ve örnek tabanlı akıl yürütme algoritmaları örneğe dayalı öğrenme metodları arasındadır.

Sinir ağları; pekiştirmeli, gözetimli ve gözetimsiz öğrenme olarak sınıflandırılabilir. Gözetimli öğrenmede öğrenme kümesindeki her veri, makinenin kendiliğinden ulaşması gereken sonuçlara sahiptir. Yeni bir örnek sunulduğunda makine bu örneği öğrenme kümesi ile karşılaştırır. Sınıflandırma ve regresyon modelleri için etkin bir yöntemdir. Pekiştirmeli öğrenmede gözetimli öğrenmeye ek olarak doğru sonuca gidildikçe pozitif yönde, doğru sonuçtan uzaklaşıldıkça negatif yönde değerler alan ödül fonksiyonu bulunmaktadır. Bu ödül fonksiyonu ile makinenin sonuca ulaşırken doğru yönde gitmesi pekiştirilir. Gözetimsiz öğrenmede veri üzerinde herhangi bir işaretleme bulunmamaktadır ve girdinin hangi sınıfa ait olduğu bilinmemektedir. Gözetimsiz öğrenmede gözetimli öğrenmedeki gibi bir eğitim verisi bulunmamaktadır. Bu durumda algoritma verileri gruplandırmaya ve yeni örnekleri en uygun gruplara atamaya çalışır.

İmalat alanında makine öğrenmesi algoritmaları ile çözülecek problemlerde karşılaşılabilecek temel zorluklar,

- Farklı tip verilerin ele alınmasının gerekliliği,
- Verideki gürültü ve uç değerler,
- Gerçek zamanlı işleme,
- Çok sayıda veya çok boyutlu veri,
- Kolay anlaşılabilir sonuçlar üretme ve
- Uyarlanabilirliktir.


Probleme konu üretim sistemine ait parçaların iş sürelerinin tahmininde kullanılacak modelde bu zorluklardan en önemlileri verinin çok sayıda ve çok boyutlu olması, veri kümesinde uç değerler bulunabilmesi ve farklı tip verinin ele alınmasının gerekliliğidir. Ek olarak iş sürelerinin sürekli değerler oluşu ve parametrelere dair verinin çokluğu regresyon modellerinin tahminde kullanılmasını daha avantajlı kılmaktadır.

İş sürelerinin tahmin edilmesi üzerine çoklu doğrusal regresyon, destek vektör regresyon makinesi (Drucker ve diğ, 1997) ve karar ağacı regresyonu (Breimann ve diğ, 1984) metotları kullanılmış ve sonuçlar karşılaştırılmıştır.

Regresyon modelleri kurulmadan önce modelde kullanılacak verinin belirli varsayımları sağlaması beklenmektedir. Bu varsayımlar; verinin normalliği, eş varyanslılık, otokorelasyonun olmaması ve çoklu lineer regresyon için bağımsız değişkenler arasında çoklu doğrusal bağlantı olmaması ile gözlem sayısının parametre sayısına göre sahip olması gereken büyüklüktür.

Regresyon modellerine dahil edilecek parametrelerin aşamalı eleme kullanılarak seçilmesi hedeflenmiştir. Aşamalı eleme sırasında sisteme dahil edilen parametrelerin düzenlenmiş R-kare değerlerinden faydalanılarak modelin tahmin kabiliyetindeki en yüksek artışı sağlayacak parametrelerin seçiminin gerçekleştirilmesi hedeflenmiştir. İşlem süresi ve parça özellikleri kümesi üzerine kurulan regresyon modellerinin tutarlılıkları çapraz geçirme yöntemi kullanılarak yani modelin veri kümesinin farklı kısımlarını öğrenme kümesi olarak kullanarak sonuçların kümenin geri kalanı ile

karşılaştırılması ile incelenecektir. Modelin yetersiz uyum ve aşırı uyum durumları Şekil 2.3’de verilmiştir.



Şekil 2.3 : Regresyon modellerinde uyum durumları.

Çoklu doğrusal regresyon, bir bağımlı değişkenin bağımsız değişkenler ve bu değişkenlerin ağırlıklandırılması ile en yakın şekilde ifade edilmesi prensibine dayanır. Çoklu doğrusal regresyon denklemi aşağıda verilmiştir.


$$Y_i = b_0 + b_1 * X_{1i} + b_2 * X_{2i} + \dots + b_n * X_{ni} + \varepsilon_i \quad (2.1)$$

Y_i , bağımlı değişkeni; b_0 , sabit bir değeri, X_1 değerleri bağımsız değişkenleri ve b_n değerleri bu değişkenlerin kuvvetlerini ifade eder. ε_i değeri modelin hata payı yani artan değeridir.

Destek vektör regresyonu, sınıflandırma amaçlı kullanılan destek vektör makinesinin farklı bir türevidir. Destek vektör makinesinde veriyi sınıflara ayıran hiperdüzlemler destek vektör regresyonunda da kullanılmaktadır. Bu modelde hiperdüzlem, tahmin edilecek verilerin en fazla ε_i uzaklığında olan bir düzlemi ifade etmektedir. Normal regresyon modellerinde hatanın en küçüklenmesi hedeflenirken, destek vektör regresyonunda tüm hata değerlerinin belirli bir aralıkta kalması hedeflenir. Destek vektör regresyonuna ait denklem aşağıda verilmiştir.

$$F_2(x, \hat{w}) = \sum_{i=1}^N (\alpha_i^* - \alpha_i) * (v_i^t x + 1)^P + b \quad (2.2)$$

Destek vektör regresyonunun en uygun hiperdüzlemini ve destek vektörlerini ifade eden görsel Şekil 2.4’de verilmiştir.



Şekil 2.4 : Destek vektör regresyonunda en uygun hiperdüzlem ve destek vektörleri.

Karar ağacı regresyonu, sınıflandırma ve regresyon için kullanılabilen karar ağacı yapısına aittir. Benzer özellikteki verileri aynı sınıfta toplama amacıyla veri kümesinin dallandırılarak bölünmesi karar ağacının temel özelliğidir. Karar ağaçları farklı sınıflandırma derinliklerine sahip olabilirler. Arama derinleştikçe veri kümesi üzerinde daha hassas sınıflandırmalar gerçekleştirilebilir. Ancak derinliğin çok yüksek olması, verideki kirliliğe göre de gruplandırma ve tahmin yapılmasına sebep olabilir ve aşırı uyuma sebep verebilir. Tarama derinliğinin veriyi yeterli sayıda sınıfa ayırabilecek fakat verideki kirliliği de göz önüne almayacak bir sayı olarak belirlenmesi karar ağacı regresyonu için önem arz etmektedir.

2.4. Modelin Uyarlanması – Öğrenme Teorisi ve Eğrileri

Öğrenme eğrisi ilk olarak 1936 yılında Wright tarafından havacılık sanayiinde gerçekleştirilen bir çalışmada bir işin gerçekleştirilmesi için gereken süre ve işin tekrar sayısı arasındaki matematiksel bağlantının öne sürülmesi ile ortaya çıkan bir kavramdır (Wright, 1936).

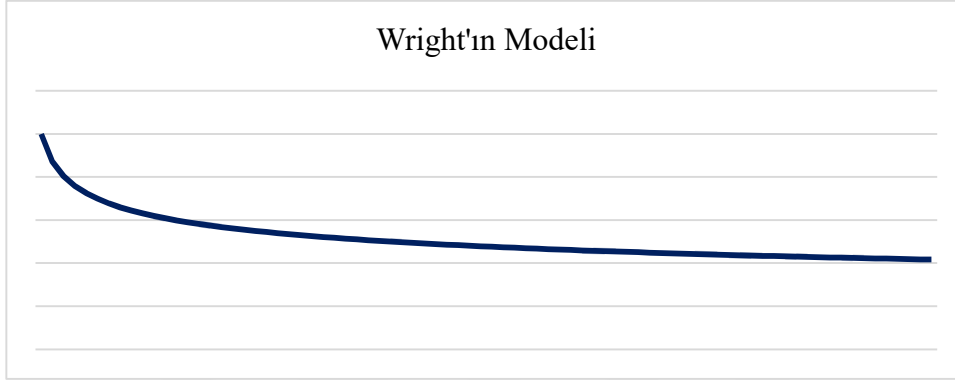
Tüm öğrenme eğrisi modelleri, sistemin veya insanın öğrenme hızını temsil eden öğrenme katsayısı (b) değerini kullanır. Öğrenme katsayısı 0 ile 1 arasında değerler alabilir. Öğrenme katsayısının yüksek değerlere sahip olması işin kolay öğrenilebilir olduğu anlamına gelmektedir. Kolay öğrenilebilen işlerde eğri eğimi daha yüksektir.

Öğrenme etkisinin en temel olarak işlendiği model Wright tarafından 1936'da önerilen bir modeldir. Wright'ın modeli aşağıda verilmiştir.

$$y_x = y_1 * x^{-b} \quad (2.1)$$

y_x , ve y_1 sırası ile x. ve 1. işlerin tamamlanması için gereken süreler, x tekrar sayısı ve b değeri de öğrenme eğrisinin eğimidir ($0 < b < 1$).

Wright'ın modeline ait işlem süresi azalış grafiği Şekil 2.5'de verilmiştir. ($b = 0,2$)




Şekil 2.5 : Wright'ın modeline göre parça iş süresi azalışı.

Başka bir model olan Plateau modelinde bir işin tamamlanması için gereken minimum süreyi ifade etmek için sabit C değeri modele eklenmiştir (Baloff, 1971). Plateau modeli:

$$y_x = C + y_1 * x^{-b} \quad (2.2)$$

Plateau modeline ait işlem süresi azalış grafiği Şekil 2.6'daki gibidir. ($b = 0,2$)

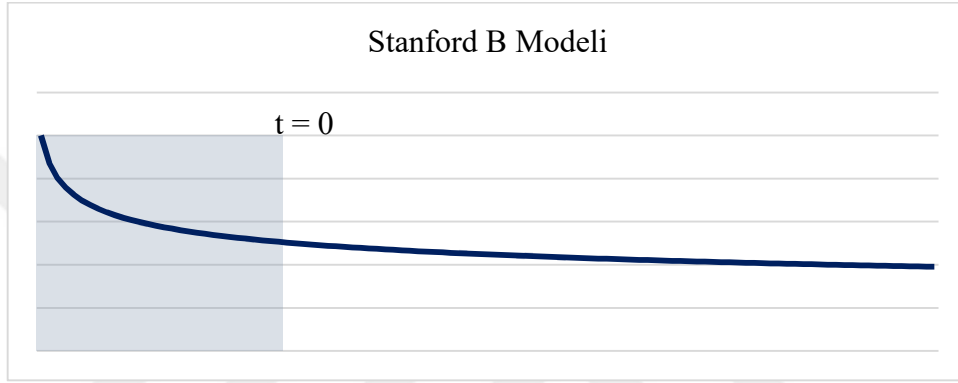


Şekil 2.6 : Plateau modeline göre parça iş süresi azalışı.

Stanford B modeli, Wright'ın modeline ek olarak geçmiş deneyimleri de probleme dahil eder. (Carlson, 1973). Modelde geçmişte B birim işlem tamamlandığı durumlar için hesaplama yapılır:

$$y_x = y_1 * (x + B)^{-b} \quad (2.3)$$

Stanford B modeline ait işlem süresi azalış grafiği Şekil 2.7'de verilmiştir. ($b = 0,2$) $t=0$ anında sistemde B adet işlem tamamlanmıştır.



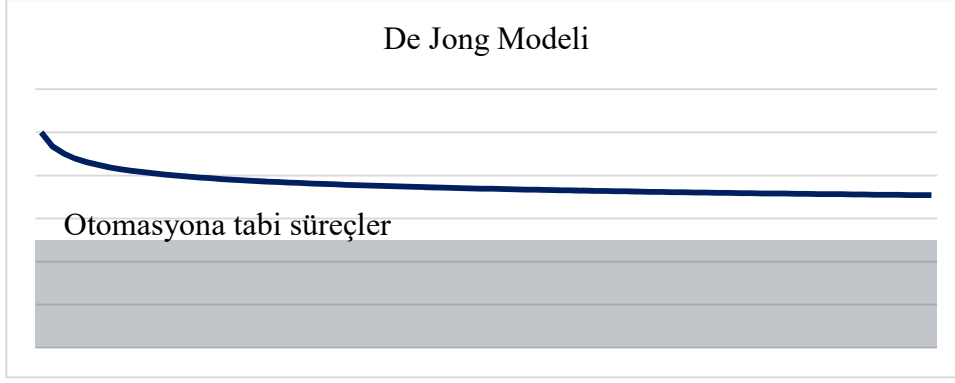
Şekil 2.7 : Stanford B modeline göre parça iş süresi azalışı.

De Jong'a göre her işte deneyim ve üretkenlik artsa da süresi kısaltılamayacak bileşenler bulunmaktadır (De Jong, 1957). Bu doğrultuda Wright'ın modeline kısaltılamazlık katsayısı ekleyerek modeli genişletmiştir:

$$y_x = y_1 * (M + (1 - M) * x^{-b}) \quad (2.4)$$

M katsayısı, sürecin otomasyon seviyesini temsil eder ($0 \leq M \leq 1$). Sürecin el ile tamamlanan bileşenleri azaldıkça erken öğrenme durağanlaşabilir. Otomasyon arttıkça M değeri yükselir.

Şekil 2.8'de De Jong modeline ait işlem süresi azalış grafiği mevcuttur. ($b = 0,2$) İşlemin tamamlanma süresinin yarısına karşılık gelen alt faaliyetler otomasyona tabidir.



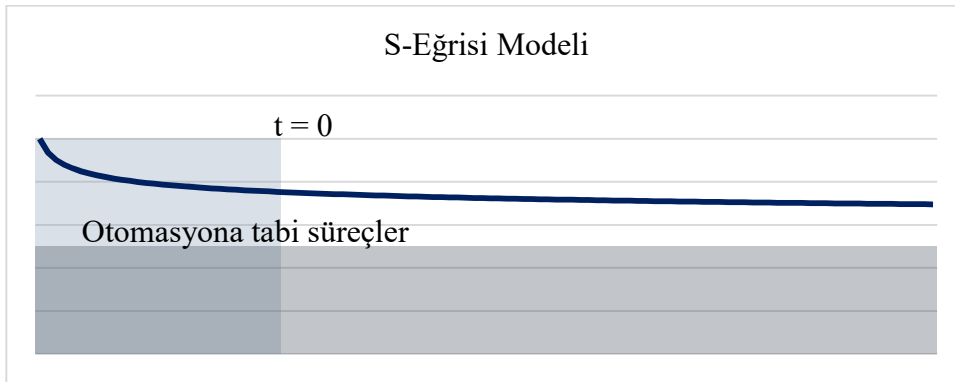
Şekil 2.8 : De Jong modeline göre parça iş süresi azalışı.

S - eğrisi modeli, Stanford B ve De Jong modellerinin birleşiminden oluşmuştur. Model, geçmişte yapılmış işlemleri ve işlerin üretkenliğinin artışından etkilenmeyen bileşenlerini ele alır (Nembhard ve Uzumeri, 2000):

$$y_x = y_1 * (M + (1 - M) * (x + B)^{-b}) \quad (2.5)$$

M katsayısı, sürecin otomasyon seviyesini temsil ederken ($0 \leq M \leq 1$), B değeri $t = 0$ anında sistemde tamamlanmış olan parça sayısına karşılık gelmektedir.

S - eğrisi modeline ait işlem süresi azalış grafiği Şekil 2.9'da yer almaktadır. ($b = 0,2$) $t = 0$ anında sistemde B adet işlem tamamlanmıştır ve işlemin tamamlanma süresinin yarısına karşılık gelen alt faaliyetler otomasyona tabidir.



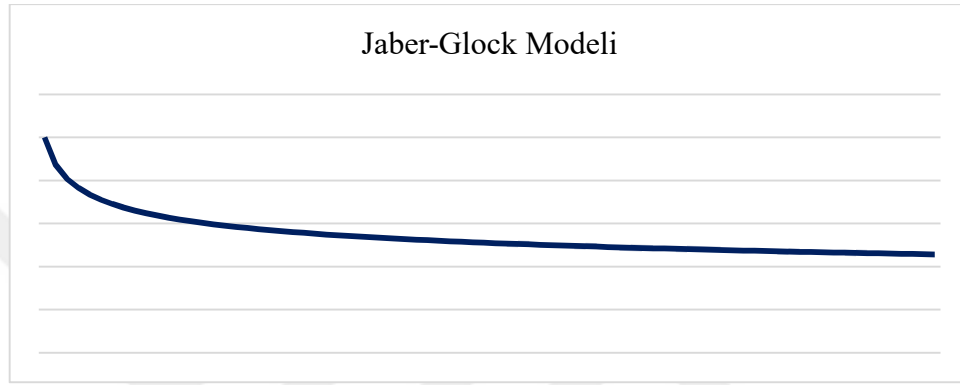
Şekil 2.9 : S-Eğrisi modeline göre parça iş süresi azalışı.

Jaber-Glock öğrenme eğrisi modeli, öğrenmenin pek çok sınai işte bilişsel ve motor öğrenme olarak ayrılabilmesini hesaba katar (Jaber ve Glock, 2013).

$$y_x = p * y_1 * x^{-b_c} + (1 - p) * y_1 * x^{-b_m} \quad (2.6)$$

Modelde b_c , bilişsel öğrenmeyi; b_m motor öğrenmeyi temsil eder. p , bilişsel ve motor öğrenmenin toplam içindeki oranlarını belirler ($0 \leq p \leq 1$).

Jaber-Glock modeline ait işlem süresi azalış grafiği Şekil 2.10'da verilmiştir. ($b_m = 0,1$, $b_c = 0,3$)



Şekil 2.10 : Jaber-Glock modeline göre parça iş süresi azalışı.

Literatürde logaritmik lineer fonksiyonlardan farklı olarak üstel öğrenme eğrisi modelleri ve hiperbolik öğrenme eğrisi modelleri mevcuttur. Üstel modeller, logaritmik lineer modellere göre birden çok parametreyi göz önüne alırlar. 2 parametrelili ve 3 parametrelili modellere ek olarak bir grubun öğrenme eğrisini elde etmek için grup öğrenme eğrisi modeli geliştirilmiştir (Glock ve Jaber, 2014). Üstel modeller aynı zamanda hiperbolik öğrenme eğrisi modeli olarak da gösterilebilir. 2 parametrelili ve 3 parametrelili hiperbolik öğrenme eğrileri literatürde mevcuttur (Mazur ve Hastie, 1978). Hiperbolik modeller artan üretkenliği gösterebildiği gibi azalan üretkenlik de hiperbolik modeller ile ifade edilebilir (Nembhard ve Uzumeri, 2000).

İmalat sektöründe öğrenme teorisi, bir işin direkt olarak gerçekleştirildikçe öğrenilmesi üzerinedir. Personel bir işi sıklıkla tekrarladıkça o işte daha yüksek verime ulaşır. Buna ek olarak öğrenme hızı, tahmini gerçekleştirilebilecek kadar düzenlidir (Hartley, 1965). Bir tipe ait üretilen hava aracı sayısı arttıkça birim başına düşen direkt işçiliğin azalışının ortaya çıkarıldığı havacılık sektörü, öğrenme teorisinin çıkış noktası gibi görünmektedir. İlk birimin üretilmesi 100 saat sürerken ikincinin 80 saat (ilk birimin %80'i) ve dördüncü birimin 64 (ilk birimin %64'i) saat sürmesi gibi bir

örnek ile öğrenme eğrisi özetlenebilir. Havacılık sanayiinde faaliyet gösteren firmalar, üretimin belirli alanlarında yaptıkları gözlemler ile elde ettikleri sonuca göre öğrenme eğrisi değerini genellikle %80 olarak ele almaktadır (Üretilen birim sayısı 2 katına çıktıkça birim işçilik sürelerinin %80 oranına düşmesi).



3. METODOLOJİ

Önerilen çözüm, ele alınan sistemin gereksinimlerine cevap verebilmekte olup birden çok çözüm aşamasına sahiptir. Bu kısımda problemin gereksinimleri detaylandırılmış ve bu doğrultuda geliştirilen çözüm yöntemi aşamalarına değinilmiştir.

3.1. Problem Tanımı

Çalışma kapsamında havacılık sektöründe imalat gerçekleştiren bir firmanın emek yoğun olarak nitelendirilen süreçlerinin bulunduğu bir sistemde işlem görmesi gereken parçalar için toplam işlem süresini en küçükleyen bir çizelge önerilmesi planlanmıştır.

Sistemdeki tüm süreçlere tabi olmayan parçalar ve zamanla değişen talepler doğrultusunda belirli aşamalardaki kaynakların artırılması ile değişime uğrayan üretim hattı göz önüne alınarak problem iş atlama melez akış tipi çizelgeleme olarak belirlenmiştir.

Çizelgeleme problemlerinin temel girdileri; sistemde bulunan $j \in J$ makineler, $i \in I$ aşamalar, işlem görmesi gereken $k \in K$ parçalar, parçaların işlem görmesi gereken makine veya aşamalar ve parçaların işlem süreleridir. Parçaların aşamalar arası taşınması göz ardı edilmiştir.

Parça çeşitliliğinin düşük ve üretim adetlerinin yüksek olduğu sistemlerde parçaların işlem süreleri ölçülebilir. Parçaların makine ile doğrusal olarak işlendiği sistemlerde ise işlem süresi yapılması planlanan işe göre kesin olarak hesaplanabilir. Fakat parça çeşitliliğinin yüksek olduğu, üretimde el işinin olduğu veya atölye yapısına sahip sistemlerde işlem sürelerinin belirli bir örneklemin işlem süresi ölçümü ile veya kesin doğrusal hesaplamalar ile belirlenmesi her zaman doğru sonuçlar doğurmayabilir. Bu sebeple problemde ele alınan sistemde geniş bir parça örnekleminin fiziksel ve kimyasal özelliklerinin ele alınmasına ek olarak aşağıdaki unsurlar da incelenmiştir:

- Kullanılan makinelerin yaşı ve sahip olduğu teknolojiler bakımından incelenerek elde edilen makine etkinlik katsayısı,
- Personelin içinde bulunulan vardiyaya göre değişim gösteren etkinliğini ele alabilmek adına üretimin gerçekleştiği vardiyaya göre etkinlik katsayısı.

Çizelgeye dahil edilecek tüm işler, yukarıdaki parametrelere sahiptir. İşlerin belirli bir oranının işlem süresi bilgileri doğrudan elde edilmiştir. Bu durumda veri, işlem süresi bilinenler ve bilinmeyenler olarak iki gruba ayrılabilir. İşlem süresi bilinen verilerin öğrenme kümesinde bulunduğu veri kümeleri için istatistiksel tahmin yöntemleri kullanılarak diğer parçaların işlem sürelerinin tahmin edilmesi planlanmıştır. Kıyaslanan farklı makine öğrenmesi algoritmaları arasından en iyi sonuç veren algoritmadan elde edilen sonuçlar çizelgeleme probleminde işlem süresi parametresi olarak kullanılmıştır.

Çizelgeleme probleminin çözümü için matematiksel model ve meta sezgisel algoritma önerilmiştir. Büyük problem boyutları için de iyi olurlu çözüm alınabilmesi geliştirilen meta sezgisel algoritma ile garanti altına alınmıştır.

Çözüm adımları:

1. Parça işlem sürelerinin elde edilmesi, sürelerin öğrenme eğrisi etkisinden arındırılması;
2. Tüm parçalar için işlem sürelerinin tahmin edilmesi, parçaların öğrenme eğrisi katsayılarına göre işlem sürelerinin hesaplanması;
3. Matematiksel model ile küçük boyutlu problemlerin çözümü;
4. Tahmin edilen parça işlem sürelerinin doğruluğunun küçük boyutlu problemler ile test edilmesi;
5. Geliştirilen meta sezgisel algoritma ile orta ve büyük boyutlu problemlerin çözümü;
6. Meta sezgisel algoritmanın çözüm doğruluğunun matematiksel modelin süre kısıtı ile çözülerek elde edilen sonuçların karşılaştırılıp test edilmesi

3.2. Uygulama Adımları

Bu aşamada, tanımlanan problemin çözümünde kullanılan adımlar yer almaktadır. İş süresi tahmini, iş sürelerine öğrenme eğrisi etkisinin yansıtılması, matematiksel model ile kesin çözüm adımları detaylandırılmış ve problemin çözümü için meta sezgisel algoritma geliştirilmesi gereksinimine değinilmiştir.

3.2.1. İş süresi tahmini modeli

İş atlamalı melez akış tipi çizelgeleme probleminin girdilerinden olacak ve tahmin edilmesi hedeflenen iş süreleri sürekli değerlerdir. Çalışmaya konu üretim sisteminde tahmin modelinin eğitilmesi için çok sayıda verinin bulunabilmektedir. Bu iki temel sebep göz önüne alındığında, iş süresi tahmin modelinde kullanılmak üzere regresyon modelleri incelenmiştir.

İş sürelerinin tahmininde kullanılacak makine öğrenmesi algoritmasından temel beklenti, sisteme tabi parçalar için yüksek doğrulukta sonuç elde edilmesidir. Algoritmaların sonuçlarının kıyaslanabilmesi için öncelikle parça işlem süreleri bilinen işler bölünüp halihazırdaki alıştırmaya kümesi içerisinde tekrardan yeni bir alıştırmaya kümesi ve test kümesi oluşturulmuştur.

Test kümesi regresyon modellerinin oluşturulmasında kullanılmadan önce verinin normalliği, eş varyanslılığı ve otokorelasyon durumu test edilmiştir. Verinin dağılımının normalliğinin testi için Kolmogorov – Smirnov testi uygulanmıştır. Eş varyanslılık, hataların varyansının modelin kullanılacağı tüm tahminler için benzer olması durumudur. Eş varyanslılığın zayıflığı, modelin tahmin doğruluğunu negatif yönde etkilemektedir. Otokorelasyon, bir testteki hataların bağımlı olması durumudur ve regresyon modellerinde hatalar arasında otokorelasyonun olmaması hedeflenir. Modelde otokorelasyonun testi için Durbin – Watson testi kullanılmıştır. Durbin – Watson testinin sonuçları 0 ile 4 arasında değerler alır ve otokorelasyon azaldıkça testten elde edilen değerler 2'ye yaklaşır.

Algoritmalarından elde edilen sonuçların kendi aralarında kıyaslanması bu kümelerin sonuçlarının doğruluklarının karşılaştırılması ile sağlanmaktadır. Algoritmanın kendi içinde tutarlı ve geçerli sonuçlar verip vermediği ise, modelin eğitilmesi aşamasında

çapraz geçirme ile veri kümesinin içerisinde farklı öğrenme kümeleri belirlenip geri kalan verinin tahmin edilerek elde edilen sonuçların karşılaştırılmasıyla kontrol edilmektedir. Böylelikle, modelin tahmin edilmesi hedeflenen verilerin farklılaşmasına olan toleransını incelemektedir. Modellerin farklı veri kümeleri üzerindeki tahmin performansları da incelenmiş ve modeller aşırı uyuma karşı test edilmiştir.

3.2.1.1. Çoklu doğrusal regresyon

Birden çok değişkenin doğrusal bağımlı olduğu bir değer tahmin edilmesi üzerine kurgulanmış olan çoklu doğrusal regresyon; bu değişkenlere olası en uygun katsayıları atayarak sonucu en etkin şekilde tahmin etmeyi amaçlar. Çoklu doğrusal regresyonda kullanılacak verinin bağımsız değişkenleri arasında çoklu doğrusal bağlantı olmaması ve gözlem sayısının parametre sayısına göre belirli bir büyüklüğe sahip olması gereklidir.

$$Y_i = b_0 + b_1 * X_{1i} + b_2 * X_{2i} + \dots + b_n * X_{ni} + \varepsilon_i \quad (3.1)$$

3.2.1.2. Destek vektör regresyonu

Destek vektör regresyonunda parametrelerle aynı boyuta sahip çok sayıda hiperdüzlem oluşturulur ve çözüm uzayındaki noktalar sınıflandırılır. Böldüğü sınıflar arasındaki uzaklıklardan en büyük olan hiperdüzlem göz önüne alınarak sonucun tahmini gerçekleştirilir.

$$F_2(x, \hat{w}) = \sum_{i=1}^N (\alpha_i^* - \alpha_i) * (v_i^t x + 1)^P + b \quad (3.2)$$

3.2.1.3. Karar ağacı regresyonu

Canlıların düşünme sistematığına benzetilen karar ağaçları bağımsız değişkenlerin belirli mantıksal sınıflara ayrılması ve bir aralığa karşılık gelecek bağımsız değişkenlere ait sonuçlara o aralık için belirlenmiş sonucun atanmasını temel alır. Bu sebeple kesikli yapıya sahip olan karar ağacı regresyonu, parametre sayısı arttıkça

sürekliliğe yaklaşır. Karar ağacının derinliği, modelin uyumu üzerinde kritik rol oynar. Derinliği yüksek bir karar ağacında model verideki kirliliklere ve uç değerlere de uyum sağlamaya başlar ve farklı veri kümeleri için ilk modelde elde edilene göre daha kötü sonuçlar sunarken, derinliği düşük bir karar ağacında model verileri yeterli sınıfa ayıramaz ve tahminden elde edilen sonuçlar veriyi yansıtamaz.

Örnek kümedeki işler bu bilgiler ışığında parça sürelerinin tahmini için öğrenme kümesi olarak kullanılmış ve farklı makine öğrenme algoritmaları yardımı ile işlerin bütünü için işlem süresi bilgileri elde edilmiştir.

İş süresine ek olarak parçaların işlem görmesi gereken aşamalar, aşamalarda bulunan makineler ve makinelerin özellikleri ve vardiya planına göre görev alacak personelin yetkinlik dereceleri problemin girdilerini oluşturmaktadır.

3.2.2. Öğrenme eğrisinin parça iş sürelerine etkisi

Sistemde üretilmesi planlanan parçalar, geçmişte üretilen parçalarla aynı veya farklı olabilir. Geçmişte üretilmemiş bir parça, halihazırda üretimi gerçekleştirilen parçalara üretim teknikleri bakımından büyük oranda benzerlik gösterebilmektedir. Bu sebeple şirketin ve personelin ilgili işin geçmişte tamamlanmasında kazanılan deneyimine ek olarak benzer işlerin tamamlanmasında kazanılan deneyimlerin etkisi de ele alınmıştır. Makinenin veya çalışma ortamının işleme hazır hale getirilmesi, işleme başlangıçta veya işlem bitişinde geçen süreler gibi unsurlar parçanın üretim süresine dahil edilmiştir. Ancak bu süreler şirketin veya personelin ilgili parçaların üretiminde edindiği tecrübeden bağımsız olarak değerlendirilmektedir ve öğrenme etkisi bu alt süreçlerin daha kısa zamanda gerçekleştirilmesinde belirleyici bir unsur değildir.

Bu sebeple ve sistemde ele alınacak parçaların veya benzerlerinin ilk kez üretilmiyor olma durumunun da olması ile problemdeki parça işlem sürelerinin hesaplanma aşamasında aşağıdaki S eğrisi öğrenme eğrisi modeli benimsenmiştir.

$$y_x = y_1 * (M + (1 - M) * (x + B)^{-b}) \quad (3.3)$$

y_x ve y_1 değerleri, sırasıyla x . ve 1. işlerin işlem sürelerini ifade etmektedir. Öğrenme katsayısı olarak adlandırılan b değeri ve öğrenme hızını ifade etmektedir.

M katsayısı, sürecin otomasyon seviyesini temsil ederken ($0 \leq M \leq 1$), B değeri $t = 0$ anında sistemde tamamlanmış olan parça sayısına karşılık gelmektedir.

Öğrenme etkisinin incelenmesinde kullanılan geçmiş parça işlem sürelerindeki azalışı yansıtan öğrenme katsayılarına göre ortalama öğrenme katsayısı değeri $b = 0,8$ olarak belirlenmiştir. Parça işlem süreleri öğrenme eğrisi etkisinden arındırılarak gelecek parçalar için işlem süresi tahminleri gerçekleştirilmiş ve sistemde ele alınan işlerin geçmiş gerçekleşme sayısına göre öğrenme eğrisi etkisi tekrar dahil edilmiştir.

Sistemde işlenmesi planlanan parçaların birbirleri ile gösterdikleri benzerliklerden dolayı üretim yöntemleri de benzerlik gösterebilmektedir. Yüksek oranda benzerlik gösteren parçalar gruplanmış ve bir gruptaki parçalar öğrenme etkisi hesaplanırken aynı parça olarak ele alınmıştır. Parçaların çizelgenin başlangıç zamanından önce işlenen benzerleri, problemde kullanılan S – eğrisi öğrenme modelinin B değerini oluşturmaktadır. Çizelgeleme sırasında aynı gruptan parçalar tamamlandıkça B değeri tamamlanan parça sayısınca güncellenmektedir.

3.2.3. İş atlamalı melez akış tipi çizelgeleme matematiksel modeli

Bu aşamada, çalışmada ele alınan iş atlamalı melez akış tipi üretim sistemi için tam sayılı doğrusal programlama modeli geliştirilmiştir. Sistem, her aşamasında en az bir tane özdeş makine bulunduran birden çok üretim aşamasından oluşmaktadır ve aşamalar arası stok alanları kısıtlanmamıştır (sonsuz olduğu varsayılmıştır). Bir aşamada faaliyet gösteren herhangi bir makinede tamamlanan iş, doğrudan rotasındaki bir sonraki aşamaya ilerleyip ilgili aşamadaki makinelerin doluluğuna göre işleme veya kuyruğa girmektedir. İhtiyaç duyduğu tüm aşamaları tamamlayan parçalar, sistemden çıkış yapmaktadır. Matematiksel model ile oluşturulacak çizelge ile toplam iş tamamlanma süresinin en küçüklenmesi amaçlanmıştır.

Matematiksel modelin karmaşıklığının çözüm süresine negatif etkisi de göz önünde bulundurularak çizelge içi öğrenme etkisi modele dahil edilmemiştir. Aynı gruptaki parçaların bir çizelgede işlenmesi durumunda, parçaların öğrenme eğrisi üzerinde bulunduğu nokta sabit tutulmuştur.

Modelin girdileri:

- İşlerin her aşamadaki ham işlem süresi
- Makinelerin etkinlik katsayıları
- Hangi makinenin hangi aşamada bulunduğu
- İşlerin hangi aşamalara uğrayıp uğramayacağı
- İşlerin uğrayacağı aşamaların sıra numaraları

Model ile hesaplanması amaçlanan değerler:

- Toplam çizelge uzunluğu
- İşlerin uğradığı makineler
- Parçaların işlem süreleri ve kuyrukta bekleme süreleri
- Makinelerdeki iş sıraları

Problemde işlenmesi hedeflenen parçaların bulunduğu işler kümesi, bu işlemlerin gerçekleştirildiği makineler kümesi ve bir veya birden fazla makineyi barındırabilen aşamalar kümesi mevcuttur. Matematiksel modelde ele alınan veri kümeleri aşağıda verilmiştir.

Kümeler

I: Aşamalar kümesi

K: İşler kümesi

J: Makineler Kümesi

Problemde ele alınan tüm parametreler ve karar değişkenleri indislerinde yukarıda tanımlanan kümelerde tanımlı birimleri kullanmaktadır.

Modelin girdileri; iş – aşama atamaları, işlerin aşamalardaki işlem süreleri, makine – aşama atamaları, makinelerin aşama içi etkinlik katsayıları ve işlerin aşamalara uğrama sıralarıdır. Matematiksel modelin ikili kısıtlarında kullanılmak üzere büyük bir sayı olan M değeri de parametreler içerisinde tanımlanmıştır. Matematiksel modele girdi sağlayan parametreler aşağıda verilmiştir.

Parametreler

R_{ki} :	$\begin{cases} 1, k \text{ işinin } i \text{ aşamasında işlem görmesi} \\ \text{gerekliyse} \\ 0, \text{Diğer durumlar} \end{cases}$	$\forall k \in K, i \in I$
P_{ki} :	$k \text{ işinin } i \text{ aşamasındaki işlem süresi}$	$\forall k \in K, i \in I$
G_{ij} :	$\begin{cases} 1, j \text{ makinesi } i \text{ aşamasında ise} \\ 0, \text{Diğer durumlar} \end{cases}$	$\forall i \in I, j \in J$
E_j :	$j \text{ makinesinin etkinlik katsayısı}$	$\forall j \in J$
S_{ki} :	$k \text{ işinin aşamaları arasında } i \text{ aşamasının} \\ \text{sırası}$	$\forall k \in K, i \in I.$
M :	Büyük bir sayı	

Problemde karar verilmesi gereken değerler; işlerin aşamalardan ve makinelerden çıkış zamanları, işlerin aşamalar ve makineler önünde bekleme süreleri, iş – makine atamaları, işlerin makinelerde işlem görme sıraları ve ardışıklıklarıdır. İşlerin aşamaları tamamlama zamanları ve aşamaların sıraları kullanılarak ise işlerin tüm aşamaları tamamlama süreleri hesaplanmaktadır. Bu doğrultuda matematiksel modele dahil edilen karar değişkenleri aşağıda verilmiştir.

Karar Değişkenleri

c_{ki} :	$k \text{ işinin } i \text{ aşamasından çıkış zamanı}$	$\forall k \in K, i \in I$
cm_{kj} :	$k \text{ işinin } j \text{ makinesinden çıkış zamanı}$	$\forall k \in K, i \in I$
t_{ki} :	$k \text{ işinin } i \text{ aşamasına girmeden kuyrukta} \\ \text{bekleme süresi}$	$\forall k \in K, j \in J$
tm_{kj} :	$k \text{ işinin } j \text{ makinesine girmeden kuyrukta} \\ \text{bekleme süresi}$	$\forall k \in K, j \in J$
x_{kj} :	$\begin{cases} 1, k \text{ işi } j \text{ makinesinde işlem gördüyse} \\ 0, \text{Diğer durumlar} \end{cases}$	$\forall k \in K, j \in J$
y_{kl}^j :	$\begin{cases} 1, j \text{ makinesinde } k \text{ işi } l \text{ parçasından önceyse} \\ 0, \text{Diğer durumlar} \end{cases}$	$\forall k, l \in K, j \in J$
cp_k :	$k \text{ işinin tamamlanma zamanı}$	$\forall k \in K$

Matematiksel modelin amaç fonksiyonu, parça tamamlanma sürelerinin toplamının en küçüklenmesidir. Amaç fonksiyonu ve kısıtlar aşağıda verilmiştir.

$$\min z = \sum_{k \in K} cp_k \quad (3.4)$$

Öyle ki;

$$\sum_{j \in J} x_{kj} * G_{ij} = R_{ki}, \quad \forall i \in I, k \in K \quad (3.5)$$

$$c_{ki} \geq cm_{kj} * G_{ij}, \quad \forall i \in I, k \in K, j \in J \quad (3.6)$$

$$t_{ki} \geq tm_{kj} * G_{ij}, \quad \forall i \in I, k \in K, j \in J \quad (3.7)$$

$$c_{ki} = c_{ki'} + t_{ki} + \sum_{j \in J: G_{ij}=1} x_{kj} * P_{ki} * E_j, \quad (3.8)$$

$$\forall i, i' \in I, k \in K: i > 1, R_{ki} = 1, S_{ki} = S_{ki'} + 1$$

$$c_{ki} = t_{ki} + \sum_{j \in J: G_{ij}=1} x_{kj} * P_{ki} * E_j, \quad \forall i \in I, k \in K: i = 1, R_{ki} = 1 \quad (3.9)$$

$$cm_{kj} + M * y_{kl}^j \geq cm_{lj} + tm_{lj} + \sum_{i \in I: G_{ij}=1} x_{kj} * P_{ki} * E_j, \quad (3.10)$$

$$\forall j \in J, k, l \in K: k < l$$

$$cm_{lj} + M * (1 - y_{kl}^j) \geq cm_{kj} + tm_{kj} + \sum_{j \in J: G_{ij}=1} x_{lj} * P_{li} * E_j, \quad (3.11)$$

$$\forall i \in I, k, l \in K: k < l$$

$$x_{kj} * M \geq cm_{kj}, \quad \forall i \in I, j \in J, k \in K: G_{ij} = 1, R_{ki} = 1 \quad (3.12)$$

$$cm_{kj} \geq x_{kj} * P_{ki} * E_j, \quad \forall i \in I, j \in J: i = 1, G_{ij} = 1 \quad (3.13)$$

$$\sum_{j \in J: G_{ij}=1} cm_{kj} \geq \sum_{j \in J: G_{ij}=1} x_{kj} * P_{ki} * E_j + c_{k(i-1)}, \quad (3.14)$$

$$\forall i \in I, k \in K: i > 1, R_{ki} = 1$$

$$c_{ki} \leq cp_k, \quad \forall i \in I, k \in K \quad (3.15)$$

$$y_{kl}^j = 0, \quad \forall j \in J, k, l \in K: k \geq l \quad (3.16)$$

$$c_{ki} \geq 0, \quad \forall i \in I, k \in K \quad (3.17)$$

$$t_{ki} \geq 0, \quad \forall i \in I, k \in K \quad (3.18)$$

$$cm_{kj} \geq 0, \quad \forall j \in J, k \in K \quad (3.19)$$

$$tm_{kj} \geq 0, \quad \forall j \in J, k \in K \quad (3.20)$$

$$cp_k \geq 0, \quad \forall k \in K \quad (3.21)$$

$$x_{kj} \in \{0,1\}, \quad \forall j \in J, k \in K \quad (3.22)$$

$$y_{kl}^j \in \{0,1\}, \quad \forall j \in J, k, l \in K \quad (3.23)$$

- Amaç fonksiyonunu ifade eden eşitlik (3.4) ile toplam çizelge zamanının en küçüklenmesi hedeflenmiştir.
- Eşitlik 3.5 işlerin hangi aşamalara uğrayacağını işlem gereklilikleri matrisine göre belirlemektedir.
- Eşitlikler 3.6 ve (3.7), işlerin makinede tamamlanma süreleri ve aşamada tamamlanma süreleri arasındaki bağlantıyı kurar.
- Eşitlik (3.8), işin uğraması gereken ardışık iki aşama arasındaki tamamlanma süresi farkının işin ilgili aşamaya girmeden önceki bekleme süresi ve işlem süresi olmasını sağlar.
- Eşitlik (3.9), işin ilk aşamadaki bitiş süresinin işin bekleme süresi ve işlem süresi toplamına eşit olmasını sağlar.
- Eşitlikler (3.10) ve (3.11), makinelerdeki işlerin kesişmesini önler.

- İşin tamamlanma süresine yansımaları eşitlik (3.12) ile garanti altına alınır.
- Eşitlikler (3.13) ve (3.14) ise işin makinelerdeki tamamlanma sürelerinin önceki aşamanın tamamlanma süresine göre hesaplanmasını sağlar. Eşitlik (3.13) ilk aşamada, eşitlik (3.14) ise diğer tüm aşamalarda kullanılır.
- İşlerin tamamlanma süreleri eşitlik (3.15) ile belirlenir.
- Eşitlik (3.16), değeri önceden belli olan karar değişkenlerine değer atayarak çözüm uzayını küçültür.
- (3.17) – (3.23) eşitlikleri, karar değişkenlerinin etkinlik alanını belirler.

Geliştirilen matematiksel model, amaç fonksiyonunun düzenlenmesi ve parça tamamlanma sürelerinin en büyüğünün amaç fonksiyonu değerine atanması ile toplam çizelge uzunluğunun en küçüklenmesi problemine dönüştürülebilir. Toplam çizelge uzunluğunun en küçüklenmesi problemlerinde en iyi sonuca aynı boyuttaki parça tamamlanma sürelerinin toplamının en küçüklenmesi problemlerine göre çok daha hızlı ulaşılabilmektedir. Toplam çizelge uzunluğunun en küçüklendiği problemde alternatif en iyi sonuç sayısı çok daha fazladır.

Matematiksel modelin çözümü ile amaçlanan, sisteme ait farklı boyutlarda veri kümeleri için en iyi çizelgenin ortaya çıkarılabilmesidir. Fakat problemde bulunan ikili 3 boyutlu değişkenlerin de negatif etkisi ile her boyuttaki küme için en iyi çözüme ulaşılması mümkün olmamaktadır. Matematiksel modelin çözüm sürelerinin yüksekliği ve iyi sonuca ulaşamama sebepleri ile daha kısa sürede ve daha iyi olurlu çözümler elde edilebilmenin amaçlandığı meta sezgisel çözüm yaklaşımları üzerinde çalışılmıştır.



4. SEZGİSEL YAKLAŞIM


Veri kümesinin büyüklüğü, kesin çözüm elde edilmekte kullanılan matematiksel modelden makul sürede sonuç alınmasını negatif olarak etkilemektedir. Bu sebeple problemin çözümü için problemin gereklilikleri doğrultusunda özelleştirilmiş bir genetik algoritma geliştirilmiştir. Geliştirilen algoritma, Genetik Boş Makine Zamanı Doldurma Algoritması olarak adlandırılmıştır. Genetik Boş Makine Zamanı Doldurma Algoritmasında; genetik algoritmanın tipik çaprazlama ve mutasyon özelliklerinin üzerine parametrelerin oluşturulması, genlerin tanımlanması ve uygunluk hesaplaması alanlarında değişiklikler yapılmıştır.

Matematiksel modelde problem karmaşıklığı nedeniyle dahil edilmeyen çizelge içi öğrenme etkisi, algoritmaya dahil edilmiştir. Bir parçanın çizelgelendiği anda o çizelgede aynı tip parçaların işlemi tamamlanmışsa, parçanın tabi olduğu öğrenme eğrisinde bir adım ilerlenir ve parçanın işlem süresi bu öğrenme etkisine göre belirlenir.

4.1. Değişkenlerin Kodlanması

Genler 0 - 1 değerlerini alan ikili değişkenler olarak belirlenmişlerdir. 0 ve 1'den yüksek değerlere ulaşılacak istendiğinde ise kromozomun üzerindeki ardışık değişkenler ikili tabana çevrilmiş çok haneli sayılar gibi ele alınarak istenilen sayıya ulaşılabilir.

Genetik algoritmanın temel noktası olan kromozom; iki aşamalı olarak ele alınmıştır. Problemden bir aşamada birden çok makinenin bulunduğu iş - aşama eşleşmelerinin tümünde parçanın aşamada bulunan hangi makinede işlem görmesi gerektiğine karar verilmesi gerekmektedir. Kromozomun ilk parçası, bu aşamalarda makine seçimine karşılık gelmektedir. Şekil 4.1, geliştirilen meta sezgisel algoritmanın kromozom yapısını ifade etmektedir.



Şekil 4.1 : Genetik boş makine zamanı doldurma algoritmasının kromozom yapısı.

Tüm iş - makine atamaları bu yolla belirlendikten sonra işlerin makine üzerinde çizelgelenmesinde kromozomun ikinci parçasından yararlanılır. Kromozomun ikinci parçası işlerin çizelge üzerine hangi sıra ile yerleştirileceğini belirler. İlk yerleştirilen iş, diğer işlerden etkilenmeksizin mümkün oldukça en başa çizelgelenirken; sonraki işler kendinden önceki işlerden kalan alanlara çizelgelenebilmektedir.

Algoritmanın uygunluk fonksiyonu hesaplama adımları aşağıdaki gibidir:

1. Kromozomu iki parçaya ayır,
2. Kromozomdaki iki tabanındaki sayıları 10'luk tabana çevir,
3. Kromozomun ikinci parçasına göre birden çok makineye sahip aşamalarda iş – makine atamaları yap,
4. Kromozomun ilk parçasına göre işleri değerlerine göre artan olarak sırala,
5. Bu sıraya göre işleri çizelgeye dahil et,
6. Tüm işler çizelgeye dahil edildikten sonra çizelgelenen parçaların tamamlanma sürelerinin toplamını hesapla,
7. Çizelgelenen parçaların tamamlanma sürelerinin toplamını uygunluk değeri olarak ata.

4.2. Çizelge Oluşturma

Genetik Boş Makine Zamanı Doldurma Algoritması'nın sözde kodu aşağıda verilmiştir.

Veri: Parça – aşama iş süreleri matrisi, P_{ki}

Parça – aşama eşleşme matrisi, R_{ki}

Parçaların bulunduğu grup numaraları matrisi, N_k

Parçaların öğrenme eğrisi üzerinde bulunduğu noktayı gösteren matris, L_k

Aşama – makine eşleşme matrisi, G_{ij}

Makine etkinlik katsayısı matrisi, E_j

1’den iş sayısına kadar olan sayıları içeren bir dizi, $joblist$

Parçaların N_k ve L_k değerlerine göre öğrenme katsayılarını hesaplayan fonksiyon, $LC(N_k, L_k)$

Sonuç: $\sum_{k \in K} cp_k$ değerini en küçükleyen c_{ki} , x_{kj} , y_{kl}^j değerlerinin hesaplanması

forall i :

while $\sum_{j \in J} G_{ij} > 1$:

forall f in 1 to $\sum_{j \in J} G_{ij}$

$A_{ft} \leftarrow f$. en küçük j değeri

$B_t \leftarrow i$

$t \leftarrow t + 1$

$t \leftarrow 0$

forall f :

$C_f \leftarrow (\sum_{t \in T} A_{ft})_2$

forall i :

$O_i \leftarrow rand(joblist)$

$joblist \leftarrow joblist - \{O_i\}$

$O_i \leftarrow (O_i)_2$

$L \leftarrow \sum_{i \in I} O_i + \sum_{f \in F} C_f$

next

Genetik Algoritma:

Rastgele L uzunluğunda kromozomlar oluştur. $g \in G$

while sonlandırma koşulu = **yanlış**

forall g :

$r \leftarrow 1$

forall k :

$k^* \leftarrow rank_k$ değeri r 'ye eşit olan $k \in K$ işi

$r \leftarrow r + 1$

$s \leftarrow 1$

forall i :

$t \leftarrow 0$

$i^* \leftarrow SPM_{k^*i}$ değeri s 'ye eşit olan $i \in I$ aşaması

$i' \leftarrow SPM_{k^*i'}$ değeri $s - 1$ 'e eşit olan $i \in I$ aşaması

$j^* \leftarrow k \in K$ işinin $i \in I$ aşamasında gireceği makine ($j^* \in J$)

$t \leftarrow k^* \in K$ işinin $i' \in I$ aşamasından çıkış zamanı

L_k değerleri $k^* \in K$ işinin potansiyel başlangıç anları için geçmişte tamamlanmış aynı N_k değerine sahip parçaların tamamlanmalarına göre güncellenir.

$t^* \leftarrow j^* \in J$ makinesinde t zamanından sonra $P_{k^*i^*} * LC(N_k, L_k)$ boyutunda ardışık boşluğa sahip ilk an, $k^* \in K$ işi $j^* \in J$ makinesinde t^* anına çizelgelenir.

next

next

$$f_g = \sum_{j \in J} C_j$$

$$f_g^* = \max(f_g)$$

$$P_s = g.EbeveynSec()$$

$$P_c = Caprazlama(P_s)$$


$$k_{new} \leftarrow Elitizm(g)$$

$$k_{new} \leftarrow P_c$$

$$k \leftarrow k_{new}$$

next

Ebeveyn seçimi, çaprazlama ve elitizm fonksiyonları ilgili fazın anlatımı aşamasında detaylandırılmıştır. Şekil 4.2, bir bireyin kromozomlarından nasıl bir çizelge oluşturulduğunun mantıksal akışını ifade etmektedir.



Şekil 4.2 : Genetik boş makine zamanı doldurma algoritması çizelgeleme süreci.

4.3. Seçilim, Çaprazlama ve Mutasyon Fazları

Geliştirilen algoritmada genetik algoritma prensiplerine uygun olarak bir jenerasyondaki uygunluk değeri hesaplamaları tamamlandıktan sonra bireyler bu değerlere göre sıralanır. Bireylerin en iyi uygunluk değerine göre sıralandıktan sonra eski jenerasyonun ilk %10'unu oluşturan kısım, seçilim ile doğrudan bir sonraki jenerasyona taşınır. Eski jenerasyonun en iyi %50'sini oluşturan bireylerin arasında rastgele çaprazlama gerçekleştirilir ve çaprazlama sonucu oluşan bireyler bir sonraki popülasyonun geri kalanını (%90) oluşturur. Çaprazlama sırasında yeni bireyin bir kromozomu %45 ihtimal ile 1. ebeveynden, %45 ihtimal ile de 2. ebeveynden gelebilirken %10 mutasyon ihtimali bulunmaktadır. Mutasyon durumunda ilgili kromozom rastgele bir değer almaktadır. Yeni bireyin her kromozomu birbirinden bağımsız olarak belirlenir.

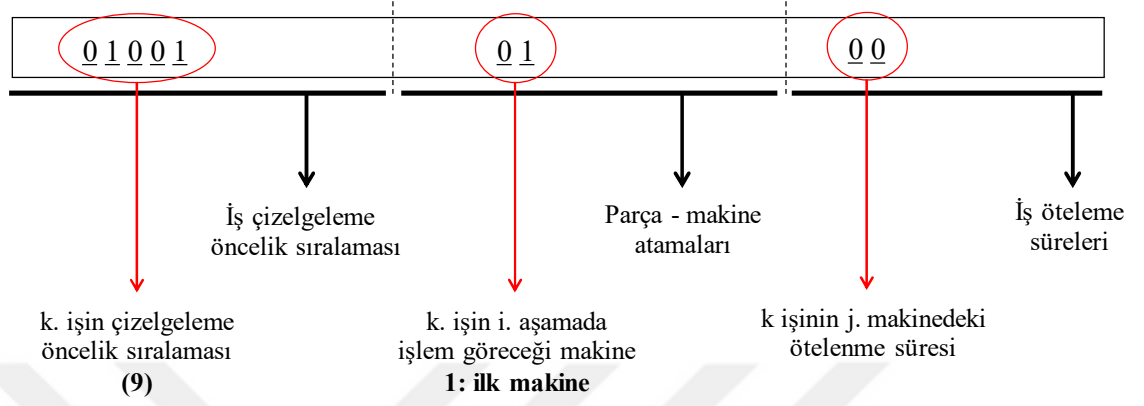
4.4. Alternatif Çizelge Oluşturma Yöntemleri

Genetik Boş Makine Zamanı Doldurma Algoritmasında işlerin atandığı makinelerde kısıtları sağlayan en erken zamana çizelgelenmesi, parçaların birbirinin arasına çizelgelenerek daha yüksek bir doluluk oranına sahip çizelge oluşturulmasına engel olabilmektedir.

Bu durumun önüne geçilmesi için işlerin çizelgelenmesi aşamasında incelenen kendinden önceki aşamalarının tamamlandığı zaman ve işin çizelgeleneyeceği makinenin doluluk durumuna ek olarak rassal ileri kaydırma işlemi yapılmaktadır. Bu işlem bir işin kendinden önce çizelgelenen iş ile arasına farklı işlerin çizelgelenmesine olanak tanımak için belirli bir orana göre çizelgede koşulları sağlayan ilk noktadan daha ileri çizelgelenmesini kapsamaktadır.

Algoritmanın iş öteleme yetisi, kromozoma ilave edilen 3. bir kısım ile sağlanmaktadır. Bu kısım, işlerin makinelerde çizelgelenirken olabilecek en erken noktadan kaç birim öteleneceğini belirtir ve ikili sayılardan oluşmaktadır. Bu durum, algoritmanın çalışma hızı üzerinde negatif etkiye sebep olmaktadır ve algoritmanın genel olarak iyi çözümlere ulaşması daha çok zaman almaktadır; fakat Genetik Boş Makine Zamanı Doldurma algoritmasının iş öteleme göz önüne alınmaksızın yerel en

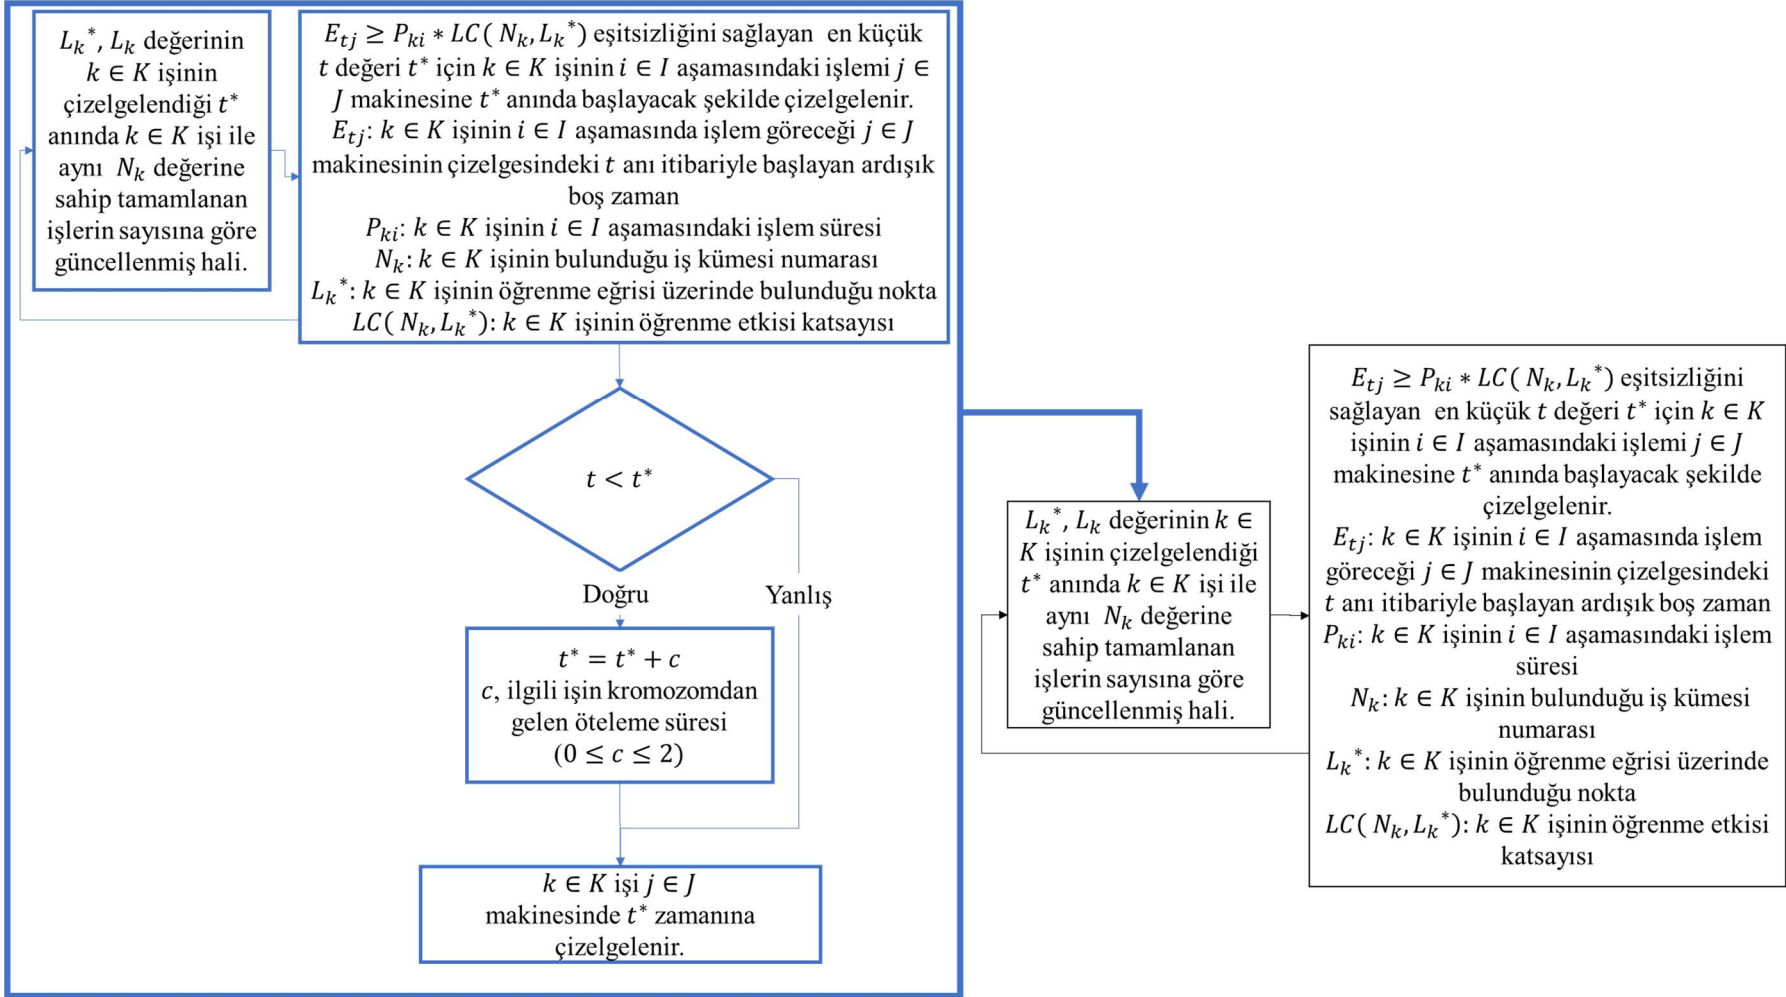
iyi sonuçta tıkanmasından bağımsız olarak elde edebileceğinden daha iyi sonuçlar elde edebilme kabiliyeti bulunmaktadır. Şekil 4.3, iş öteleme özelliği bulunan algoritmanın kromozom yapısını ifade etmektedir.



Şekil 4.3 : İş ötelemeli genetik boş makine zamanı doldurma algoritması kromozom yapısı.

Çözüm yöntemi olarak ele alınan problemin boyutu göz önüne alınarak matematiksel model veya meta sezgisel algoritma kullanımı konusunda; çözüm için gerek duyulan süre ve elde edilmesi planlanan çizelgenin ne denli verimli olması arasındaki denge göz önüne alınarak da geliştirilen iki meta sezgisel algoritma arasında seçim yapılabilir.

Geliştirilen genetik boş makine zamanı doldurma algoritmalarının çizelgeleme sırasında uyguladığı mantıksal akış diyagramı şekilde verilmiştir. Mavi ile ifade edilen kısımlar iş öteleme fonksiyonuna dair adımlardır.



Şekil 4.4 : İş öteleme süreci.

5. UYGULAMA

İş atlamalı melez akış tipi çizelgeleme probleminin çözümü için metodoloji bölümünde tanımlanan adımların sırası ile uygulanması planlanmıştır. İşlem süresi tahmininin gerçekleştirilmesinin ardından probleme girdi sağlaması planlanan veri kümelerinin tanımlanması hedeflenmiştir.

Sistemde probleme konu olan alanda bulunan makineler, bu makinelerin özellikleri ve makinelerden geçen parçalar hakkında bilgi toplanmıştır. Problemin çözümünde kullanılması hedeflenen matematiksel model ve meta sezgisel algoritmanın sonuçlarının incelenmesi ve karşılaştırılmasında kullanılmak üzere parçaların akışları incelenerek farklı boyutlarda veri kümeleri oluşturulmuştur.

Veri Kümesi 1:

- 3 Aşama
- 5 Makine
- 12 İş

Veri Kümesi 2:

- 5 Aşama
- 8 Makine
- 15 İş

Veri Kümesi 3:

- 7 Aşama
- 11 Makine
- 40 İş

5.1. İşlem Süresi Verisi Oluşturma

Diğer tüm girdiler sistemden doğrudan sağlanabilirken parça iş sürelerinin makine öğrenmesi algoritmaları yardımı ile tahmin edilmesi amaçlanmıştır. Tahmin için kurulan alternatif regresyon modelleri, iş süresi tahmin verisi öğrenme ve test kümelerine bölünmüştür. Modelin aşırı uyum gösterip göstermediğinin testi için çapraz geçişleme dahilinde tahmin verisinin içinden farklı öğrenme kümeleri oluşturulmuş ve bu kümeler ile eğitilen farklı modeller kullanılarak verinin tümü için işlem süresi tahmini gerçekleştirilmiştir. Elde edilen iş sürelerinin doğruluğu ise tahmin edilen iş sürelerinin gerçek iş süresi değerleri ile mutlak sapma ve R^2 değerleri üzerinden karşılaştırılması ile test edilmiştir. Test kümesi üzerindeki en iyi sonuç değerlerine sahip modelden elde edilen iş süreleri ve gerçek iş sürelerinin bir karşılaştırması da tahmin edilen ve gerçek verinin iş süresi parametresi olarak tanımlandığı problem ikililerinin matematiksel model ile kesin olarak çözülüp, elde edilen çizelgelerin karşılaştırılması ile gerçekleştirilmiştir. Bu karşılaştırma ile tahmin verisinin gerçek sisteme uyarlanmasında çizelgeler üzerinde ne boyutta farklılıklar oluşabileceği incelenmiştir.

Regresyon modelleri, bağımsız değişkenler üzerinden bağımlı değişkenin değerini tahmin etmeye dayanır. Çizelge 5.1’de regresyon modelleri kurulurken modele dahil edilen bağımsız ve bağımlı değişkenler ve bu değişkenlerin kategorik veya sayısal değişken tiplerinden hangisine dahil olduğu verilmiştir.

Çizelge 5.1 : Regresyon modellerinde kullanılan bağımlı ve bağımsız değişkenler.

Değişken	Durum	Tip
Malzeme Tipi	Bağımsız	Kategorik
Alt Malzeme Tipi	Bağımsız	Kategorik
Gerçekleştirilen İşlem Tipi	Bağımsız	Kategorik
Kullanılan Makine	Bağımsız	Kategorik
Parça Eni	Bağımsız	Sayısal
Parça Boyu	Bağımsız	Sayısal
Parça Yüksekliği	Bağımsız	Sayısal
Parça İşlem Süresi	Bağımlı	Sayısal

Regresyon modellerinde kullanılacak verinin normalliği test edilmiştir. Başvurulan Kolmogorov – Smirnov testine göre elde edilen sonuçlar Çizelge 5.2’de verilmiştir. Sonuçlar incelendiğinde veri Kolmogorov – Smirnov testine göre normal dağılıma sahiptir.

Çizelge 5.2 : Kolmogorov – Smirnov testi veri ve sonuçları.

Ortalama	20,7
Standart Sapma	4,5
D	0,38
D_{tablo}	0,65

Verinin eş varyanslılığının testi için çoklu doğrusal regresyon modeli ve elde edilen sonuçlar kullanılmıştır. Veri eş varyanslılık varsayımına uyum sağlamaktadır. Otokorelasyon için ise Durbin – Watson testine başvurulmuştur. Testten elde edilen sonuçlar Çizelge 5.3’de verilmiştir. Testten 2 değerine yakın sonuçlar elde edilmesi veride düşük otokorelasyon olduğu anlamına gelmektedir. Otokorelasyon hipotezinin sonucu ise testten elde edilen değerler d_U ve d_L sınırlarının içerisinde kalması ile belirlenmektedir. Sonuçlar incelendiğinde Durbin – Watson testine göre veride otokorelasyon bulunmamaktadır.

Çizelge 5.3 : Durbin – Watson testi veri ve sonuçları.

d	1,61
Örneklem Boyutu	60
d_U	1,48
d_L	1,69

Parçaların öğrenme eğrisi etkisi arındırılmış işlem sürelerinin tahmini için kullanılan algoritmalar ve test örneğinde bu algoritmaların kullanımı ile elde edilen iş süreleri arasındaki mutlak yüzde sapma değerleri Çizelge 5.4’de verilmiştir.

Sonuçlar incelendiğinde örnek kümedeki verilerin tahmin doğruluğu en yüksek olan algoritma %6,8 mutlak iş süresi sapması ile karar ağacı regresyonu olmuştur.

Çizelge 5.4 : Kurulan regresyon modellerinin tahmin sapmaları.

Algoritma	İş Süresi Mutlak Yüzde Sapma
Çoklu Doğrusal Regresyon	%13,7
Destek Vektör Regresyonu	%23,6
Rastgele Değişken Regresyonu	%9,5
Karar Ağacı Regresyonu	%6,8

Belirleme katsayısı olarak kullanılan R^2 değeri, modelin tahmin verisinde ortaya koyduğu sapmanın verideki sapma ile kıyasını sağlamakta ve 0 ile 1 aralığında değerler almaktadır. R^2 değerinin 1'e yakınlığı tahminin yüksek doğruluğa sahip olduğunu ifade etmektedir. Test edilen regresyon modellerinin R^2 değerleri Çizelge 5.5'de verilmiştir.

Çizelge 5.5 : Kurulan regresyon modellerinin sonuçlarının R^2 değerleri.

Algoritma	R^2
Çoklu Doğrusal Regresyon	0,92
Destek Vektör Regresyonu	0,90
Rastgele Değişken Regresyonu	0,93
Karar Ağacı Regresyonu	0,96

R^2 değerleri incelendiğinde en yüksek değere sahip model Karar Ağacı Regresyonu modeli olmuştur. Çizelgeleme problemine girdi sağlayacak parça işlem sürelerinin oluşturulmasında Karar Ağacı Regresyonu modelinin kullanılması kararlaştırılmıştır.

Parça işlem sürelerinin öğrenme kümesindeki verilerin işlem süreleri öğrenme eğrisi etkisinden arındırılmış ve bu şekilde diğer parçalar için regresyon modeli ile elde edilen işlem süreleri zaman bağımsız olarak tahmin edilmiştir. Öğrenme eğrisinden etkilenmeyen bu parça işlem süreleri, sonradan probleme konu verinin üretim tarihi göz önünde bulundurularak düzenlenmiştir.

Matematiksel modelin belirli bir boyut üzerindeki veri kümeleri için hızlı sonuç veremediği bilinmektedir. Bu sebeple matematiksel model ve algoritmanın çıktılarının karşılaştırmasının yapılabilmesi adına matematiksel modelin de çözüm verebileceği boyutta bir problem olan 1. ve 2. veri kümeleri kullanılmıştır.

5.2. Tahmin Edilen İşlem Sürelerinin Doğruluğu

Tahmin edilen işlem süreleri kullanılarak ortaya çıkarılan çizelgelerin gerçek dünyaya adaptasyonu sırasında tutarlılığının kontrol edilebilmesi için 1. veri kümesi boyutunda gerçek işlem süreleri ve tahmin edilen işlem sürelerinin kullanıldığı veri kümesi ikilileri oluşturulmuş ve bu veri kümeleri kendi arasında karşılaştırılmıştır. İşlem süresi tahminlerinden oluşan problemin çizelgelenmesinden elde edilen sonuçların gerçek işlem sürelerinin bulunduğu problemde elde edilen sonuçlara yakınlığı

- İş - makine atamaları,
- Makine doluluk oranları ve
- Amaç fonksiyonu değerleri ile kıyaslanmıştır.

Kıyaslamalar yapılırken iş – makine atamalarında makinelerin eşit olarak değerlendirilmesi için makine etkinlik katsayıları devreden çıkartılmıştır; yani bir aşamadaki makinelerin hepsi özdeş kabul edilmiştir. 14 karşılaştırma hazırlanmış ve bu karşılaştırmalardaki toplam 28 problemin çözümünü için gereken ortalama işlemci süresinin 3988 saniye olduğu gözlenmiştir. Kıyaslamalar tutarlılık yüzdesi olarak ifade edilmiştir ve yüksek değerler yüksek benzerliğe karşılık gelmektedir. 15 farklı veri kümesi ikilisine ait sonuçlar Çizelge 5.6’da verilmiştir:

Çizelge 5.6 : Tahmin edilen iş sürelerinin tutarlılık karşılaştırmaları.

	1	2	3	4	5	6	7
İş – Makine atamaları	%73	%73	%77	%82	%86	%41	%73
Makine dolulukları	%83	%90	%90	%99	%91	%89	%96
Amaç fonksiyonları	%91	%95	%99	%99	%99	%96	%98
Toplam	%82	%86	%89	%94	%92	%75	%89

	8	9	10	11	12	13	14
İş – Makine atamaları	%64	%45	%59	%36	%55	%27	%59
Makine dolulukları	%93	%84	%93	%87	%85	%94	%91
Amaç fonksiyonları	%97	%97	%98	%98	%96	%99	%99
Toplam	%85	%75	%83	%74	%79	%74	%83

Kıyaslamalar incelendiğinde ortalama değer 83% olarak hesaplanmaktadır. İş – makine atamaları özelinde bir inceleme yapıldığında kimi ikililerde düşük benzerlik oranıyla karşılaşılsa da makine dolulukları benzerlik göstermektedir. Buradan tahmin verileriyle yapılan çizelge ile gerçek işlem süresi verileriyle yapılan çizelgede işler farklı makinelere atanabiliyor olsa da örneklem arası bir makineden ikinci makineye kayan bir iş karşılık ikilinin diğer çizelgesinde ikinci makineden ilk makineye geçen bir iş olduğu sonucuna varılabilmektedir. Bu sebeple makine dolulukları benzer olmakta ve toplam parça işlem süresindeki benzerliğin de yardımı ile ikililerin amaç fonksiyonu değerleri birbiri ile yüksek benzerlik göstermektedir.

Aynı örneklem için makine etkinlik katsayılarının devreye alınarak çözülmesi durumunda elde edilen sonuçlara ait karşılaştırmalar Çizelge 5.7’de verilmiştir:

Çizelge 5.7 : Makine verimi dahil edildiğinde tahmin edilen iş sürelerinin tutarlılık karşılaştırmaları.

	1	2	8	9	10	13
İş – Makine atamaları	%82	%73	%77	%65	%77	%96
Makine dolulukları	%78	%94	%96	%87	%93	%99
Amaç fonksiyonları	%90	%95	%98	%98	%98	%99
Toplam	%83	%87	%90	%83	%89	%98

Tablodaki toplam tutarlılık yüzdeleri ve iş - makine atama tutarlılık yüzdeleri incelendiğinde probleme makine etkinlik katsayısının eklenmesinin ikililer arasındaki tutarlılığın artmasını sağlamıştır. Sonuçların benzerliğindeki artışa sebep olarak çözüm aşamasında makine seçimlerinin yüksek verimliliğe sahip makine lehine yapıldığı gözlenmiştir.

Yüksek tutarlılık değerine sahip veri kümesi ikililerinin bir diğer ortak özelliği de toplam işlem sürelerinin birbirine yakınlığıdır. Makine etkinlik katsayısının dahil edildiği problemin etkinlik katsayısı bulunmayan problemde daha az alternatif en iyi sonuca sahip olduğu da bulgular arasındadır.

5.3. Matematiksel Modelin Çözüm Kabiliyetleri

Matematiksel model ile her veri kümesine ait koşturumlar gerçekleştirilmiştir. Bu koşturumlarda IBM CPLEX Studio üzerinden Intel Core i7® 4700MQ işlemci ve 8 GB RAM'e sahip bir sistem kullanılmıştır.

1. veri kümesi, tahmin edilen işlem sürelerinin doğruluğunun analiz edilmesi aşamasında 14 farklı ikili için toplam 28 koşturuma tabi olmuştur. 1. veri kümesinde bulunan problemlerin koşturum işlemci süreleri Çizelge 5.8'de ifade edilmiştir.

Çizelge 5.8 : Koşturumların işlemci süre istatistikleri.

	Süre (sn)
En kısa çözüm	1.128
En uzun çözüm	11.625
Ortalama çözüm	3.988

2. veri kümesine ait bir problemin matematiksel model ile çözümü için 5 saat ve 30 saat işlemci süresi zaman kısıtlı koşturumlar gerçekleştirilmiştir.

5 saatlik koşturumun sonrası elde edilen bilgiler aşağıdaki gibidir:

- En iyi değer ile olan açıklık: %30,3
- Amaç fonksiyonu değeri: 340

Makine doluluklarının uç ve ortalama değerleri aşağıdaki gibidir.

- En yüksek: %100
- En düşük: %47
- Ortalama: %74

İlgili çizelgede tamamlanması planlanan işlerin toplam tamamlanma süresi 340 dakikadır.

30 saatlik koşturumun sonrası elde edilen bilgiler aşağıdaki gibidir:

- En iyi deęer ile olan açıklık: %13,6
- Amaç fonksiyonu deęeri: 314

Makine doluluklarının uç ve ortalama deęerleri ařaęıdaki gibidir.

- En yüksek: %100
- En düşük: %46
- Ortalama: %78

İlgili çizelgede tamamlanması planlanan işlerin toplam süresi 314 dakikadır.

İki zaman kısıtlı kořturum örneęi de incelendięinde, ilgili sistemin gerçek zamanlı çizelgelenebilmesi için bir benzer doęruluęa sahip kısa süreli çözüm üretme aracının kullanılmasının gerektięi anlaşılabilmektedir.

5.4. Sezgisel Yaklařımın Sonularının İncelenmesi

Orta ve büyük boyuttaki problemlere kısa sürede iyi olurlu sonuçlar elde edilmesi için önerilmiş olan Genetik Boř Makine Zamanı Doldurma Algoritması ile elde edilen sonuçların en iyiye yakınlıęı ve kısa süreli kořturumlarda matematiksel modelin ortaya koyduęu performansın incelenmesi için 2. veri kümesi boyutunda problemler ele alınmıřtır.

Meta sezgisel algoritma, iterasyon tamamlanma sürelerini hesaplayarak tanımlanan süre limitine göre belirli bir iterasyonda durmak üzere kurgulanmıřtır. Bu şekilde matematiksel modelde olduęu gibi iki çözüm yöntemi de belirli bir süre içerisinde elde edilen çizelgelerin sonuçları üzerinden deęerlendirilmiřtir.

Geliřtirilen genetik boş makine zamanı doldurma algoritması, kromozom yapısı ve tanımını gereęi gen havuzunda sadece olurlu çözümler üretebilmektedir. Her ne kadar genetik algoritma yapısı dâhilinde mutasyon ve meta sezgisel algoritmanın çizelgeleme ařamasında rassal iş öteleme ile çözüm havuzunda çeřitlilik saęlansa da algoritma olurlu bölge içerisinde en iyi sonuca ulařmadan önce yerel en iyi noktada tıkanabilmektedir.

Şekil 5.1’de 2. Veri kümesine ait 2 problem örneğinin matematiksel model kullanılarak çözümleri sonrası elde edilen çizelgeler, amaç fonksiyonu değeri, karar değişkenlerinin değerleri ve çözüm süreleri verilmiştir.

Matematiksel modelin işlemci süresine göre 1800 saniyeye ulaşmasının ardından elde ettiği amaç fonksiyonu değeri 345’dir.

Aynı problemin çözümü için İş Ötelemeli Genetik Boş Makine Zamanı Algoritması kullanıldığında ise 1000 saniyelik süre limitinin ardından elde edilen çizelgenin amaç fonksiyonu değeri 335’dir.



İki çözüm yöntemi 3. veri kümesine ait problemler için de kıyaslanmıştır. Matematiksel model, 1800 saniyelik işlem süresinin sonunda 1947 toplam tamamlanma zamanına sahip bir çizelge ortaya koyabilmiştir. Genetik Boş Makine Zamanı Doldurma Algoritması 1000 saniyelik süre limitinin ardından 1885 amaç fonksiyonu değerine sahip bir çizelge oluşturmuştur.

Çizelge 5.9’da 2. veri kümesine ait örneklem için matematiksel model ve meta sezgisel algoritmadan elde edilen sonuçlar karşılaştırılmış, yüzde fark değerleri verilmiştir.

Çizelge 5.9 : Matematiksel model ve meta sezgisel algoritmadan elde edilen sonuçların 2. tip veriler için karşılaştırması.

	Veri 2.1		Veri 2.2		Veri 2.3	
	Süre	Değer	Süre	Değer	Süre	Değer
	Açıklık		Açıklık		Açıklık	
Matematiksel Model	1800	345	1800	369	1800	351
	%33		%21		%41	
Algoritma	1000	335	1800	368	1000	351
Fark	+%80	+%3	0	+%0,3	+%80	0

Matematiksel modelin zaman kısıtı 30 dakika olarak belirlendiği 2. veri kümesine ait örneklemde; meta sezgisel algoritma, matematiksel modelin ulaştığı sonuca matematiksel modelden ortalama %50 daha hızlı ulaşabilmektedir.



Şekil 5.1 : Matematiksel model ve meta sezgisel algoritma ile elde edilen çizelgelerin karşılaştırılması.

Çizelge 5.10'da 3. Veri kümesine ait örneklem için matematiksel model ve meta sezgisel algoritmadan elde edilen sonuçlar karşılaştırılmış ve yüzde fark değerleri verilmiştir.

Çizelge 5.10 : Matematiksel model ve meta sezgisel algoritmadan elde edilen sonuçların 3. tip veriler için karşılaştırması.

	Veri 3.1		Veri 3.2		Veri 3.3		Veri 3.4	
	Süre	Değer	Süre	Değer	Süre	Değer	Süre	Değer
	Açıklık		Açıklık		Açıklık		Açıklık	
Matematiksel	1800	1202	3600	2123	1800	1947	1800	2262
Model	%70		%68		%74		%72	
Algoritma	1000	1161	1200	1887	1200	1875	1200	1901
Fark	+%80	+%4	+%200	+%13	+%50	+%4	+%50	+%19

Matematiksel modelin zaman kısıtı 3 örneklem için 30 dakika olarak belirlenirken, 1 örnekleme zaman kısıtı 1 saat olarak belirlenmiştir. Matematiksel model ile elde edilen çözümler, ortalama %95 daha uzun süre sonucunda elde edilmiş olsa da genetik boş makine zamanı doldurma algoritmasından elde edilen amaç fonksiyonu değerlerinin matematiksel modelden elde edilen sonuçlara göre ortalama %10 daha iyi olduğu tespit edilmiştir.



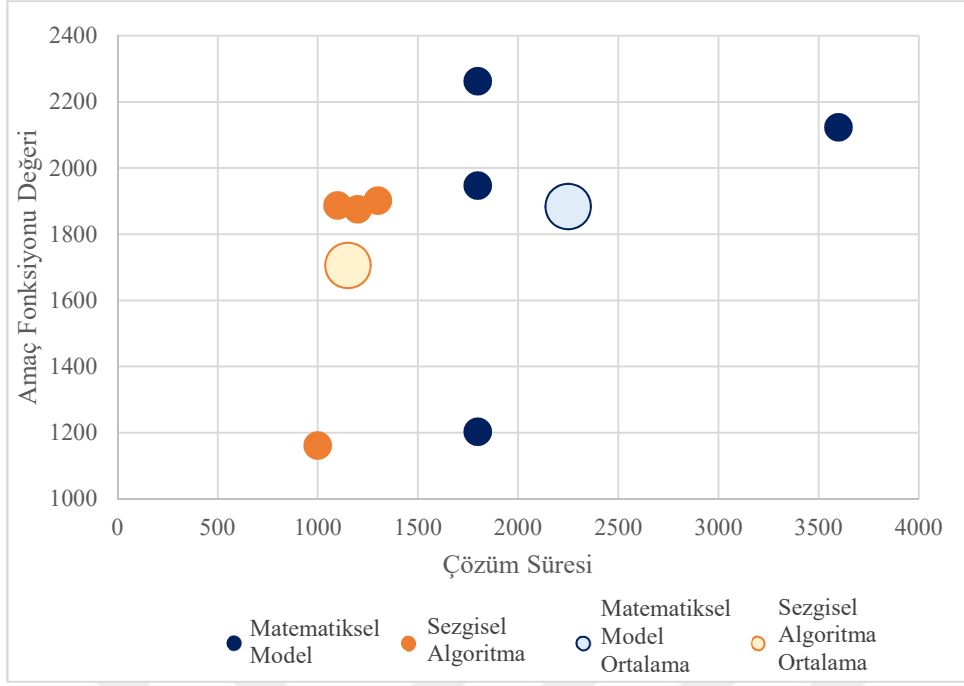
6. SONUÇ VE ÖNERİLER

Çalışma, Türkiye'nin havacılık imalat sektöründe önde gelen bir firmasını yansıtacak şekilde kurgulanmış ve problemde kullanılan veriler bu doğrultuda seçilmiştir. Problemin çözümünde çizelgelemenin gerçekleştirilmesi öncesinde parametrelerin oluşturulması ihtiyacı olduğundan geliştirilen yöntemin uygulaması parça iş süreleri tahmini ve çizelgeleme olarak 2 aşamalı olarak gerçekleştirilmiştir ve bu aşamalar farklı modüller olarak kullanılabilir.

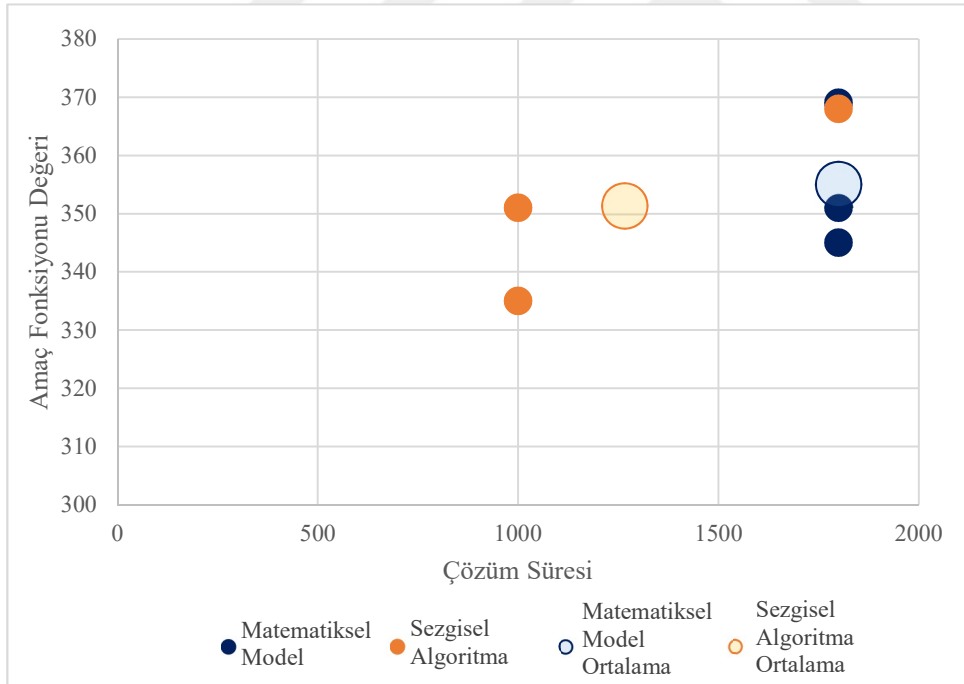
Parça iş süresi tahmin modülü; firmada personel, makine ve projelerin iş yükü hesaplamalarında aktif olarak kullanılmaktadır. Sisteme girişi yapılan fakat kesinliği olmayan işlem sürelerinin doğruluğunun test edilmesinde kullanılan tahmin modülü, bu şekilde personelin gerçekleştirdiği çalışmaların sisteme girişini kontrol edebilmektedir.

İş atlamalı melez akış tipi çizelgeleme probleminin toplam iş tamamlanma süresinin en küçüklenmesi amaçlı çözümü için ise iki farklı yöntem önerilmiştir. Önerilen yöntemlerden ilki olan matematiksel model ile kesin çözüm elde edilebilmektedir. Matematiksel model, küçük boyutlu problemler için kabul edilebilir zamanda en iyi sonuç verebilmektedir. Daha büyük veri kümesine sahip problemlerin çözümü için Genetik Boş Makine Zamanı Doldurma Algoritması önerilmiştir. Önerilen meta sezgisel algoritma ile bu problemlere matematiksel modelden kısa sürede ve matematiksel modelden elde edilen sonuçlarla kıyaslanabilir sonuçlar elde edilebilmektedir.

Matematiksel model ve meta sezgisel algoritmadan elde edilen 2. ve 3. veri kümesine ait sonuçların grafiksel karşılaştırması sırası ile Şekil 6.1 ve Şekil 6.2'de verilmiştir.



Şekil 6.1 : 2. veri kümesine ait sonuçların karşılaştırması.




Şekil 6.2 : 3. veri kümesine ait sonuçların karşılaştırması.

Toplam çizelge süresinin en küçüklenmesinin amaçlandığı bu problemde düşük amaç fonksiyonu değerine sahip çözümler daha tercih edilebilirdir. Ek olarak benzer sonucun daha kısa sürede elde edilebilmesi de çizelgeleme faaliyetlerini hızlandıracak ve görece yavaş çözüm yöntemlerine göre daha yüksek fayda sağlayacaktır. Turuncu

ile ifade edilen ve meta sezgisel algoritma ile elde edilen sonuçlara karşılık gelen noktalar, matematiksel modelin sonuçlarına karşılık gelen mavi noktalar her iki ekseninde de daha iyi konumdadır.

Genetik Boş Makine Zamanı Doldurma Algoritmasına ilave olarak işlerin çizelgeleneceği noktayı ileri öteleme alternatifi sunan İş Ötelemeli Genetik Boş Makine Zamanı Doldurma Algoritması önerilmiştir. İş öteleme fonksiyonunun, algoritmanın iyi çözümlere ulaşma hızına negatif etki ettiği gözlemlenmiştir. Fakat iş öteleme fonksiyonu olmaksızın algoritmanın yerel en iyi sonuçta takılma ihtimalinin daha yüksek olduğu da gözlemlenen sonuçlar arasındadır. Şekil 6.3’de geliştirilen meta sezgisel algoritmanın iki türevinin de aynı problemin çözümünde kullanılması sonucu amaç fonksiyonu değerinin algoritma adımlarına göre değişimi sunulmuştur. Koyu renk ile ifade edilen çizgi, iş öteleme fonksiyonu bulunmayan algoritmanın adımları süresince elde edilen amaç fonksiyonu değerlerini ifade ederken; açık renk ile gösterilen çizgi iş öteleme fonksiyonunun dahil edildiği algoritma için elde edilen sonuçları göstermektedir.



Şekil 6.3 : Meta sezgisel algoritmada iş atlama işlevinin sonuçlara etkisi.

Şekil 6.3’de gözlenebildiği gibi iş öteleme fonksiyonuna sahip algoritmanın iş öteleme dahil edilmeyen algoritmanın elde ettiği sonuçlara ulaşması için daha çok iterasyon gerekmiştir fakat sonuç olarak iş öteleme fonksiyonunun algoritmaya kattığı çeşitliliğin de etkisiyle daha iyi sonuçlara ulaşabilmiştir.

Küçük boyutlu problemlerin çözümü için matematiksel modelin kullanımı ile kesin çözümün elde edilmesi en etkili yöntem olarak ortaya çıkmaktadır. Orta boyutta problemlerde ise sonuçlar veriye göre farklılık göstermektedir. Orta boyutta birden çok problem çözüm yöntemlerinin kıyaslamasında kullanıldığında ise geliştirilen meta sezgisel algoritmanın matematiksel model ile benzer sonuçlar üretmede matematiksel modelden daha hızlı olduğu gözlenmiştir. Genetik Boş Makine Zamanı Doldurma Algoritması'nın çözüme ayrılan süre arttıkça matematiksel model karşısında avantajını kaybettiği de gözlenen sonuçlar arasındadır. Bu vaka, çözüme ayrılan sürenin çizelgelenen işlerin sahip olduğu çevrenden daha büyük olduğu durumlarda gerçekleşmektedir. Problem boyutunun daha da büyümesi, meta sezgisel algoritmanın hem çözüm süresi hem de elde edilen sonucun en iyiye yakınlığı konusunda daha avantajlı konuma gelmesine sebebiyet vermektedir.

Geliştirilen meta sezgisel algoritma ve matematiksel modelin sadece iş atlamalı melez akış tipi çizelgeleme problemlerinin çözümü için değil; bu problemin daha genel formları olan iş atlamalı akış tipi çizelgeleme problemleri, melez akış tipi çizelgeleme problemleri, akış tipi çizelgeleme problemleri ve iş tipi çizelgeleme problemlerinin çözümleri için kullanılabilmesi mümkündür.

Tekrarlanan faaliyetlerin zaman içerisinde daha etkin şekilde tamamlanmasını ifade eden öğrenme teorisi, üretim sistemlerindeki akışların ifade edilmesinde önemli bir yer tutmaktadır. Bu sebeple ve işlem sürelerinin en doğru şekilde sisteme yansıtılmasını sağlamak amacıyla sistemde geçmişte tamamlanmış faaliyetleri ve bu faaliyetlerin zamanla iyileştirilmesi mümkün olmayan süreçleri olabildiğini göz önüne alan S – eğrisi öğrenme modeli kullanılmıştır. Parça iş sürelerinin tahmini öncesinde eğitim kümesindeki işlerin işlem süreleri için öğrenme eğrisi ters yönde kullanılarak süreler öğrenme etkisinden arındırılmış ve tahmin buna göre gerçekleştirilmiştir. İşlem sürelerinin girdi sağladığı çizelgeleme aşamasında ise parçaların geçmiş faaliyetler de göz önüne alınarak öğrenme eğrisi üzerinde hangi noktada olduğu belirlenerek tekrardan bir öğrenme eğrisi fonksiyonu oluşturulmuştur. Bir çizelgede benzer parçaların işlenmesinin işlem süreleri üzerindeki etkisi de probleme dahil edilmiştir.

Çalışma kapsamında bir havacılık imalat tesisinin emek yoğun olarak nitelendirilen bir pilot bölgesi için iş sürelerinin belirsiz olduğu durumlar için üretim çizelgesi oluşturulması amacıyla çözüm yöntemleri geliştirilmiştir.

İş sürelerinin geçmiş veri ışığında tahmin edilerek süredeki belirsizliğin üstesinden gelmek için iş süresi tahmin modeli geliştirilmiştir. Çizelgeleme probleminin çözümü için ise küçük ölçekte problemler için bir kesin çözüm yöntemi, orta ve büyük ölçekte problemler için ise genetik algoritmanın iterasyon prensiplerine sahip bir meta sezgisel algoritma geliştirilmiştir. Sonrasında geliştirilen meta sezgisel algoritma türevlendirilmiş ve algoritmanın türevleri kendi arasında karşılaştırılmıştır.





KAYNAKLAR

- Alpaydin, E.** (2010). Introduction to machine learning (2nd ed.). *Cambridge, MA: MIT Press.*
- Azizoglu, M., & Kirca, O.** (1998). Tardiness minimization on parallel machines. *International Journal of Production Economics, 55(2)*, 163–168.
- Baloff, N.,** (1971). Extensions of the learning curve - some empirical results. *Journal of the Operational Research Society, 22(4)*, 329–340.
- Bedworth, D. D. & Bailey, J. E.** (1987). Integrated Production Control Systems: *management, analysis, design. 2 edition. New York: John Wiley & Sons, Inc.*
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J.** (1984). Classification and regression trees. Chapman and Hall/CRC.
- Carlson, J.G.,** (1973). Cubic learning curve: precision tool for labor estimating. *Manufacturing Engineering & Management, 71(5)*, 22–25.
- Chang, S. C., & Liao, D. Y.** (1994). Scheduling flexible flow shops with no setup effects. *IEEE Transactions on Automation Science and Engineering, 10(2)*, 112-122.
- Cho, H., & Wysk, R. A.** (1993). A robust adaptive scheduler for an intelligent Workstation controller. *International Journal of Production Research, 31*, 771–789.
- Davis, J., Edgar, T., Graybill, R., Korambath, P., Schott, B., Swink, D., & Wetzel, J.** (2015). Smart manufacturing. *Annual Review of Chemical and Biomolecular Engineering, 6*, 141–160.
- De Jong, J.R.,** (1957). The effects of increasing skill on cycle time and its consequences for time standards. *Ergonomics 1 (1)*, 51–60.
- Dios, M., Fernandez-Viagas, V., & Framinan, J.** (2018). Efficient heuristics for the hybrid flow shop scheduling problem with missing operations. *Computers and Industrial Engineering, 115*, 88–99.
- Drucker H., Burges C.J.C., Kaufman L., Smola A., & Vapnik V.** (1997). Support vector regression machines. *Advances in Neural Information Processing Systems 9*, 155–161
- Engin, O., Ceran, G., & Yilmaz, M.K.** (2011). An efficient genetic algorithm for hybrid flow shop scheduling with multiprocessor task problems. *Applied Soft Computing, 11 (3)*, 3056-3065.
- Filipic, B., & Junkar, M.** (2000). Using inductive machine learning to support decision making in machining processes. *Computers in Industry, 43*, 31–41.

- French, S.** (1982). Sequencing and scheduling: an introduction to the mathematics of the job shop. *New York: Wiley.*
- Glock, C.H., & Jaber, M.Y.,** (2014). A group learning curve model with and without worker turnover. *Journal of Modelling in Management, 9(2), 179–199.*
- Graves, S.C.,** (1981). A Review of Production Scheduling. *Operations Research, 29:4, 646-675*
- Guo, X., Sun, L., Li, G., & Wang, S.** (2008). A hybrid wavelet analysis and support vector machines in forecasting development of manufacturing. *Expert Systems with Applications, 35, 415–422.*
- Gupta, J. N.D.** (1988). Two-stage, hybrid flowshop scheduling problem. *Journal of the Operational Research Society, 39(4), 359–364.*
- Hartley, K.** (1965). The Learning Curve and Its Application to the Aircraft Industry. *The Journal of Industrial Economics, 13(2), 122-128.*
- Jaber, M.Y., & Glock, C.H.,** (2013). A learning curve for tasks with cognitive and motor elements. *Computers and Industrial Engineering, 64(3), 866–871.*
- Johnson S. M. & Montgomery D. C.** (1974). Operations Research in Production, Planning, Scheduling and Inventory Control. New York: Wiley.
- Kim, D., Kang, P., Cho, S., Lee, H., & Doh, S.** (2012). Machine learning-based novelty detection for faulty wafer detection in semiconductor manufacturing. *Expert Systems with Applications, 39, 4075–4083.*
- Lee, J., Lapira, E., Bagheri, B., & Kao, H.** (2013). Recent advances and trends in predictive manufacturing systems in big data environment. *Manufacturing Letters, 1, 38–41.*
- Lei, D., & Guo, X.,** (2016). Hybrid flow shop scheduling with not-all-machines options via local search with controlled deterioration. *Computers Operations Research, 65, 76-82.*
- Li, J.Q., Sang, H.Y., Han, Y.Y., Wang, C.G., & Gao, K.Z.** (2018). Efficient multi-objective optimization algorithm for hybrid flow shop scheduling problems with setup energy consumptions. *Journal of Cleaner Production, 181, 584–598.*
- Li, J., Pan, Q., & Duan, P.,** (2016). An improved artificial bee colony algorithm for solving hybrid flexible flowshop with dynamic operation skipping. *IEEE Transactions on Cybernetics, 46 (6), 1311-1324.*
- Li, J.Q., Pan, Q.K., & Mao, K.A.,** (2016-2). Hybrid fruit fly optimization algorithm for the realistic hybrid flowshop rescheduling problem in steelmaking systems. *IEEE Transactions on Automation Science and Engineering, 13 (2), 932-949.*
- Linn, R., Zhang W.,** (1999). Hybrid flow shop scheduling: a survey. *Computers and Industrial Engineering, 37 (1–2), 57–61.*
- Maccarthy, B.L. & Liu, J.Y.** (1993). Addressing the gap in scheduling research: a review of optimization and heuristic methods in production scheduling. *International Journal of Production Research, 31, 1, 59-79.*

- Marichelvam, M.K., Prabakaran, T., & Yang, X.S.,** (2014). Improved cuckoo search algorithm for hybrid flow shop scheduling problems to minimize makespan. *Applied Soft Computing*, 19, 93-101.
- Mazur, J.E., Hastie, R.,** (1978). Learning as accumulation: a reexamination of the learning curve. *Psychological Bulletin*, 85 (6), 1256–1274.
- Nembhard, D.A., Uzumeri, M.V.,** (2000). An individual-based description of learning within an organization. *IEEE Transactions on Engineering Management*, 47(3), 370–378.
- Nilsson, N. J.** (2005). Introduction to machine learning. Stanford, CA.
- Oğuz, C., Ercan, M.F.** (2005). A genetic algorithm for hybrid flow-shop scheduling with multiprocessor tasks. *Journal of Scheduling*, 8 (4), 323-351.
- Ouelhadj, D., Petrovic, S.** (2009). A survey of dynamic scheduling in manufacturing systems. *Journal of Scheduling*, 12, 417–431.
- Pham, D. T., Afify, A. A.** (2005). Machine-learning techniques and their applications in manufacturing. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 219(5), 395–412.
- Portmann, M.C., Vignier, A., Dardilhac, D., Dezalay, D.,** (1998). Branch and bound crossed with GA to solve hybrid flowshops. *European Journal of Operational Research*, 107 (2), 389-400.
- Priore, P., Gomez, A., Pino, R., Rosillo, R.** (2014). Dynamic scheduling of manufacturing systems using machine learning: An updated review. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, 28. 83-97.
- Priore, P., Fuente, D., Puente, J., Parreño, J.** (2006). A comparison of machine-learning algorithms for dynamic scheduling of flexible manufacturing systems. *Engineering Applications of Artificial Intelligence*, 19. 247-255.
- Qin, W., Zhang, J. & Song, D.** (2018). *Journal of Intelligent Manufacturing*, 29: 891.
- Ruiz, R., Serifoglu, F., & Urlings, T.** (2008). Modeling realistic hybrid flexible flowshop scheduling problems. *Computers and Operations Research*, 35(4), 1151–1175.
- Ruiz, R., & Vazquez-Rodriguez, J. A.** (2010). The hybrid flow shop scheduling problem. *European Journal of Operational Research*, 205(1), 1–18.
- Schulz S.** (2019). A Genetic Algorithm to Solve the Hybrid Flow Shop Scheduling Problem with Subcontracting Options and Energy Cost Consideration. *Information Systems Architecture and Technology: Proceedings of 39th International Conference on Information Systems Architecture and Technology – ISAT 2018. ISAT 2018. Advances in Intelligent Systems and Computing*, vol 854.

- Wang, S.Y., Wang, L., Liu, M., & Xu, Y.,** (2015). An order-based estimation of distribution algorithm for stochastic hybrid flow-shop scheduling problem. *International Journal Computer Integrated Manufacturing*, 28 (3), 307-320.
- Wright, T.P.** (1936). Factors affecting the cost of airplanes. *Journal of Aeronautical Science* 3(4), 122–128.
- Wuest, T., Weimer, D., Irgens, C., Thoben, K.D.** (2016). Machine learning in manufacturing: advantages, challenges, and applications. *Production & Manufacturing Research*, 4:1, 23-45.
- Ying, K.C., Lin, S.W., & Wan, S.Y.,** (2014). Bi-objective reentrant hybrid flowshop scheduling: an iterated Pareto greedy algorithm. *International Journal of Production Research* 52 (19), 5735-5747.



ÖZGEÇMİŞ

Ad-Soyad : Fatih AYDIN
Uyruğu : T.C.
Doğum Tarihi ve Yeri : 26.08.1995 - Osmangazi
E-posta : fatih.aydin.123@hotmail.com

ÖĞRENİM DURUMU:

- **Lisans** :2017, TOBB Ekonomi ve Teknoloji Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği
- **Yüksek Lisans** :2019, TOBB Ekonomi ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

Yıl	Yer	Görev
2017-2018	TOBB Ekonomi ve Teknoloji Üniversitesi	Tam Burslu Yüksek Lisans Öğrencisi
2018 - ...	TUSAŞ Türk Havacılık ve Uzay Sanayii A.Ş.	Kurumsal Kaynak Yönetimi Mühendisi

YABANCI DİL: İngilizce, Almanca

TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Aydın, F., Derinkuyu, K., (2019).** Hybrid Flow Shop Scheduling with Learning Effect under Uncertain Process Times, International Conference on Natural and Engineering Sciences, August 27-30, İstanbul, Turkey.