

**MONTAJ HATTINDA
MALZEME BESLEME SİSTEMİNİN
YAPAY SİNİR AĞI YÖNTEMİ İLE SEÇİMİ**

Müge Sinem ÇAĞLAYAN



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MONTAJ HATTINDA MALZEME BESLEME SİSTEMİNİN
YAPAY SİNİR AĞI YÖNTEMİ İLE SEÇİMİ**

Müge Sinem ÇAĞLAYAN
0000-0002-2544-5554

Doç. Dr. Aslı AKSOY
0000-0002-2971-2701
(Danışman)

YÜKSEK LİSANS
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2022
Her Hakkı Saklıdır

TEZ ONAYI

Müge Sinem Çağlayan tarafından hazırlanan “Montaj Hattında Malzeme Besleme Sisteminin Yapay Sinir Ağı Yöntemi ile Seçimi” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Doç. Dr. Aslı Aksoy

Başkan : Doç. Dr. Aslı AKSOY
0000-0002-2971-2701
Bursa Uludağ Üniversitesi,
Mühendislik Fakültesi,
Endüstri Mühendisliği Anabilim Dalı

İmza

Üye : Doç. Dr. İlker KÜÇÜKOĞLU
0000-0002-5075-0876
Uludağ Üniversitesi,
Mühendislik Fakültesi,
Endüstri Mühendisliği Anabilim Dalı

İmza

Üye : Dr. Öğr. Üyesi Hasan ŞAHİN
0000-0002-8915-000X
Bursa Teknik Üniversitesi,
Mühendislik ve Doğa Bilimleri Fakültesi,
Endüstri Mühendisliği Anabilim Dalı

İmza

Yukarıdaki sonucu onaylarım

Prof. Dr. Hüseyin Aksel EREN
Enstitü Müdürü

.././....

B.U.Ü. Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

18/02/2022

Müge Sinem ÇAĞLAYAN

**TEZ YAYINLANMA
FİKRİ MÜLKİYET HAKLARI BEYANI**

Enstitü tarafından onaylanan lisansüstü tezin/raporun tamamını veya herhangi bir kısmını, basılı (kâğıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma izni Bursa Uludağ Üniversitesi'ne aittir. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları ile tezin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları tarafımıza ait olacaktır. Tezde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alınarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederiz.

Yükseköğretim Kurulu tarafından yayınlanan “**Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge**” kapsamında, yönerge tarafından belirtilen kısıtlamalar olmadığı takdirde tezin YÖK Ulusal Tez Merkezi / B.U.Ü. Kütüphanesi Açık Erişim Sistemi ve üye olunan diğer veri tabanlarının (Proquest veri tabanı gibi) erişimine açılması uygundur.

Danışman Adı-Soyadı

Öğrencinin Adı-Soyadı

Tarih

Tarih

İmza

İmza

Bu bölüme kişinin kendi el yazısı ile okudum anladım

Bu bölüme kişinin kendi el yazısı ile okudum

yazmalı ve imzalanmalıdır.

anladım yazmalı ve imzalanmalıdır.

ÖZET

Yüksek Lisans Tezi

MONTAJ HATTINDA MALZEME BESLEME SİSTEMİNİN YAPAY SINIR AĞI YÖNTEMİ İLE SEÇİMİ

Müge Sinem ÇAĞLAYAN

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Aslı AKSOY

İşletmelerin gelişen ve değişen rekabet koşullarında tercih sebebi olmaları için kaliteyi arttırmaları, ayrıca maliyet ve teslimat süresini azaltarak verimliliklerini arttırmaları gerekmektedir. Parça besleme sistemleri verimliliği etkileyen önemli parametrelerden biridir. İşletmeler parça çeşitliliği, parça boyutu ve ağırlığı, ürün talep hacmi, işletme içerisindeki alan gereksinimi, iş gücü gibi parametreleri düşünerek en uygun parça besleme yöntemini seçmelidir.

Bu çalışmada hidrolik motor üreten bir firmada montaj hatlarına malzeme besleme yöntemi karar verme problemi ele alınmıştır. Çalışmanın amacı, fabrikada bulunan farklı değer akışlarındaki montaj hatları için mevcut malzemelerin en verimli şekilde besleme yönteminin seçilmesi ve yeni malzemelerin besleme yöntemine kolayca karar verilebilmesidir.

Çalışmada malzeme besleme yöntem seçim problemi çözümünde ileri beslemeli yapay sinir ağ yapısı kullanılmıştır. Literatür araştırması ve firmanın karar verme stratejileri doğrultusunda beş girdi ve dört çıktıya karar verilmiştir. Bu nedenle karmaşık olan problem için çok katmanlı yapay sinir ağı ve geri yayılım algoritması seçilmiştir. Firmanın mevcut durumda kullanmadığı kitleme yöntemi önerilmiştir.

Geliştirilen çözüm yaklaşımı ile firmaya yeni tanımlanacak ürünler ve yeni kurulacak montaj hatlarında kullanılacak malzemeler için en uygun ve kısa sürede malzeme besleme yöntemi seçilmesi sağlanmıştır. Ayrıca pilot hatta uygulanan yeni seçim ile personel verimliliği, kalite, ergonomik koşulların iyileşmesi gibi konularda artış; alan ihtiyacı, planlama ve karar verme zamanı gibi konularda azalış olduğu gözlenmiştir.

Anahtar Kelimeler: Montaj hattı besleme yöntemi, kitleme, yapay sinir ağı, geri yayılım algoritması

2022, vii + 56 sayfa.

ABSTRACT

MSc Thesis

SELECTING MATERIAL FEEDING SYSTEM OF THE ASSEMBLY LINE BY MEANS OF ARTIFICIAL NEURAL NETWORK METHOD

Müge Sinem ÇAĞLAYAN

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Industrial Engineering

Supervisor: Assoc. Prof. Dr. Aslı AKSOY

Manufacturing companies which aims to become preferred in competitive markets should decrease cost and lead time while increasing quality and efficiency. Material feeding system is one of the important parameter which effects the efficiency. Manufacturing companies should take into consideration of some criteria such as, great variety of materials, material volume, weights, product demands, area requirements in facility, labor force etc. to decide the most suitable material feeding method.

In this study, material feeding method decision making problem is discussed in a manufacturing company, produces hydraulic pump for material feeding to an assembly lines.

The aim of the study is to determine the most efficient material feeding method of existing materials for assembly lines in different value streams in the plant and to easily decide on the feeding method of new materials.

A feedforward neural network structure is used to solve material feeding method selection problem in this study.

Input and output criteria are determined according to literature research and strategic decisions of company. Multilayer artificial neural network topology and back propagation algorithm is applied for complex problem. Kitting method is proposed which is not currently applied.

The proposed approach provides an effective solution for decision making to choose the most suitable material feeding system and this method can easily be used for the new materials in new assembly lines. According to the implementation results of the proposed approach increase in labor productivity and quality, improvement of ergonomic conditions, decrease for empty space requirement, necessary time for planning and decision making was observed.

Key words: Assembly line feeding method, kitting, neural network, back propagation algorithm

2022, vii + 56 pages.

ÖNSÖZ ve TEŞEKKÜR

Bu çalışmanın amacı firmanın yalın üretim sistemini uygulayarak kalite ve personel verimliliği arttıran ergonomik, kişiden bağımsız bir sistemin malzeme besleme yöntemi seçimi için oluşmasını sağlamaktır. Montaj hattı besleme yöntemi olarak kitleme yöntemi ile firmayı tanıştırmak ve önemli getirilerini göstermektir.

Tez çalışmam boyunca desteğini esirgemeyen ve beni cesaretlendiren değerli hocam Doç. Dr. Aslı Aksoy' a teşekkürlerimi sunarım.

Bu uzun süreçte verdiği motivasyon ve sonsuz güven için eşim, Mehmed Cihad Çağlayan'a, uygulamada bilgisini paylaşan Abdullah Piroğlu'na, teşekkürlerimi sunarım. Ayrıca çalışmamda beni destekleyen ve bana olan güvenlerini hiç kaybetmeyen aileme teşekkür ederim.

Müge Sinem Çağlayan
30/12/2021.

İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	ii
ÖNSÖZ ve TEŞEKKÜR	iii
SİMGE ve KISALTMALAR DİZİNİ	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	vii
1. GİRİŞ	1
2. KURUMSAL TEMELLER ve KAYNAK ARAŞTIRMASI	4
2.1. Kanban	4
2.2. Hat Yanı Besleme	5
2.3. Kitleme (Kitting)	6
2.4. Malzeme Besleme Yöntemlerinin Karşılaştırması	9
3. MATERYAL ve YÖNTEM	15
3.1. Yapay Sinir Ağları	15
3.2. Yapay Sinir Ağ Yapısı	17
4. BULGULAR ve TARTIŞMA	26
4.1. Pilot Alanda Mevcut Durum Analizi	26
4.2. Yapay Sinir Ağı Yöntemi Kullanılarak Malzeme Besleme Yöntemi Seçimi	28
4.2.1. Yapay sinir ağının tasarımı	28
4.2.2. Yapay sinir ağının eğitimi	32
4.2.3. Yapay sinir ağının test edilmesi	33
4.2.4. Yapay sinir ağının performans değerlendirme kriteri	34
4.1. Uygulama	34
5. SONUÇ	44
KAYNAKLAR	47
EKLER	51
EK 1 Pilot montaj hattında kullanılan malzemeler için örnek eğitim verileri.....	52
EK 2 LM algoritması ile yapılan denemelerin bir kısmı	53
EK 3 LM algoritması ile yapılan tekrarlı denemelerin bir kısmı	54
EK 4 BR, SCG, GDM algoritmaları ile yapılan tekrarlı denemelerin bir kısmı	55
ÖZGEÇMİŞ	56

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
d	Adım büyüklüğü
e	Ağ hatalarının vektörü
E	Tüm hatalar
g	Eğim
H	Hessian matrisi
I	Birim matris
J	Jacobian matris
μ	Ayarlanabilir parametre
n	İterasyon sayısı
p	Adım yönü
t	Yanlılık (bias) değeri
W_j	Ağırlık
X_j	j . girdi
Y	Çıktı
y_i	Çıktı
\hat{y}_i	Hedef çıktı
λ	Marquardt parametresi

Kısaltmalar	Açıklama
BR	Bayes Düzenleme Algoritması (Bayesian Regularization Algorithm)
GDM	Momentumlu Eğim Azaltma Algoritması (Gradient Descent with Momentum Algorithm)
LM	Levenberg- Marquardt Algoritması (Levenberg- Marquardt Algorithm)
MSE	Ortalama Karesel Hata (Mean Squared Error)
SCG	Ölçeklenmiş Eşlenik Azaltma Algoritması (Scaled Conjugate Gradient Algorithm)
YSA	Yapay Sinir Ağı

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1. Yapay sinir ağı yapısı	18
Şekil 4.1. Malzeme besleme yöntemi seçim çalışması için oluşturulan YSA yapısı	31
Şekil 4.2. Malzeme besleme yöntemi seçimi için oluşturulan Matlab bildirimini	36
Şekil 4.3. Tekrarlı denemeler için oluşturulan Matlab bildirimini	37
Şekil 4.4. Malzeme besleme yöntemi seçimi için oluşturulan Matlab ağ yapısı	39
Şekil 4.5. Malzeme besleme yöntemi seçimi için oluşturulan ağ yapısı	39
Şekil 4.6. Seçilen ağ için eğitim, doğrulama, test ve tüm veriler için korelasyon katsayısı grafikleri	40
Şekil 4.7. Malzeme yöntemi seçim probleminde örnekler için elde edilen Matlab bildirimini	42

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 4.1. Malzeme besleme yöntemi için seçilen girdi parametrelerinin özellikleri	29
Çizelge 4.2. Malzeme besleme yöntemi için seçilen çıktı özellikleri	31
Çizelge 4.3. LM algoritması ile yapılan denemelerde elde edilen en iyi sonuçlar ...	35
Çizelge 4.4. LM algoritması ile yapılan tekrarlı denemelerde elde edilen en iyi sonuçlar	36
Çizelge 4.5. BR, SCG, GDM algoritmaları ile yapılan tekrarlı çalıştırmalarda elde edilen en iyi sonuçlar	38
Çizelge 4.7. 29 adet test verisinin gerçek çıktı değerleri ve ağın ürettiği çıktı değerleri	41

1. GİRİŞ

Günümüzde birçok işletme kalite, maliyet ve teslimat süresini azaltarak küresel pazardaki rekabet güçlerini arttırmak istemektedir. Parça besleme sistemleri verimliliği etkileyen önemli parametrelerden biridir. İşletmeler parça çeşitliliği, parça boyutu ve ağırlığı, ürün talep hacmi, işletme içerisindeki alan gereksinimi, iş gücü gibi parametreleri düşünerek en uygun parça besleme yöntemini seçmelidir.

Parça besleme sistemleri, parçaların stoklanması, parçaların taşınması ve parçaların besleme politikası olarak üçe ayrılmıştır. Literatürde parça besleme politikaları aşağıda belirtildiği şekilde dört farklı başlıkta incelenmiştir:

- Sürekli besleme (Hat yanı stoklama)
- Kanban ile malzeme besleme
- Kit ile besleme
- Melez yaklaşımlar

Ayrıca benzerliklere bağlı olarak, yığın (batch) tedarik gibi literatürde diğer politikalar hat yanı stoklama ve sıralı tedarik, kitleme besleme politikası kapsamında analiz edilmiştir (Kılıç ve Durmuşoğlu, 2014).

Hat yanı besleme politikasında malzemeler montaj hattı yanında ayrı bir kaptan veya rafta saklanır ve dağıtılır. Ürün çeşidine göre kap içerisindeki miktar değişmekle birlikte kap boşaldığında değiştirilir. Montaj operatörü veya malzeme hazırlama operatörü malzemeleri ihtiyaç durumunda raftan alarak hazırlar. Montaj hattında bir malzeme problemi olduğunda hattın yanında sürekli olarak malzeme bulunduğu için doğrudan kaptan yeni ürün alınarak üretime devam edilebilir. Ürün çeşitliliğinin fazla olduğu işletmelerde parça aramak için zaman ve montaj hattı yanındaki stok alanı ihtiyacı fazla olmaktadır (Çorakçı, 2008; Faccio, 2014).

Kanban, yalın üretim çekme prensibine dayalı, bilgi iletmek için kullanılan bir araçtır. Kanban son üretim biriminden ilk üretim birimine doğru bilgi akışı sağlayarak malzemelerin hareketine yardımcı olur. Ürün tanımlı alandan çekildikçe bir önceki sürece üret sinyali verilir.

Kanban, aşırı üretimin önüne geçmek, süreç içi stok adeti ve maliyetini azaltmak amacıyla kullanılan malzeme besleme yöntemidir. Bir sonraki süreç adımı bir önceki süreç adımına kanban kartı yardımı ile üret veya dur sinyali verir. Sadece bir sonraki süreçten ilgili malzeme tüketildiğinde üret sinyali gitmektedir. Bir sonraki süreçten gelen bilgiye istinaden üretim kararı verildiği için dışarıdan bir planlama gereksinimi duyulmaz, yönetilmesi kolaydır.

Kit, bir veya birden fazla montaj adımında kullanılan parçaların bir araya getirilmiş halini içeren kutuya verilen genel isimdir (Bozer ve McGinnis, 1992). Kit, bazı parçaların bir araya getirildiği özel toplamalardır (Brynzer ve Johansson, 1995). Kit, bir ürünü üretmek veya bir üretim adımını tamamlamak için gerekli malzemelerin bir araya getirilmesi olarak ifade edilebilir (Choobineh ve Mohebbi, 2004).

Kitleme ya da diğer adıyla kit ile malzeme beslemeyi önceden belirlenen miktardaki parçaları özel konteynerlere bir arada koyarak gerekli olan parçaları besleme aktivitesi olarak tanımlanmıştır (Çorakçı, 2008). Kit, sadece tanımlı parçaları, gerekli olacak bir zaman dilimi için elleçleyerek istasyonlara sevk etme işlemidir (Sali vd., 2015).

Kit, ürün çeşitliliğinin fazla ürün talep hacminin düşük, ortak bileşen sayısının az olduğu işletmelerde avantajlı bir malzeme besleme yöntemidir (Çevikcan vd., 2018).

Limere vd. (2012), kitlemenin avantajlarını aşağıdaki gibi sıralamıştır:

- Stok seviyesinin düşürülmesi,
- Operatörlerin parçaları bulup getirmek için harcadığı zamanın azaltılması,
- Parçanın aranması için gereken zamanın azaltılması,

- Ergonomik koşulların iyileşmesi, operatörlerin ergonomik tasarlanmış kitlelere daha rahat ulaşımının sağlanması.

Melez yaklaşımlar, malzeme besleme yöntemlerinin iki veya daha fazlasının birlikte kullanıldığı yöntemlerdir. Malzemelerin tanımlı bir kısmının hat yanında bulunurken veya kanban ile yönetilirken bir kısmının depodan beslenmesi veya kit ile beslenmesi yaklaşımı da olabilir.

Bu çalışmada hidrolik motor üreten bir firmada yaşanan problemlerden bazıları:

- Yüksek sipariş hacmi, düşük üretim kapasitesi,
- Montaj hatlarında uzun tip dönme süreleri,
- Montaj operatörünün katma değersiz işler yapması,
- Üretim kapasitesini artırmak amacıyla alınacak yeni makineler için alan ihtiyacı,
- Montaj hattında yanlış malzeme montajlanması nedeniyle müşteri şikayetleri,
- Yüksek tip çeşitliliği nedeniyle malzeme arama için harcanan zaman,
- Montaj hattı ve montaj operatörlerinin verimsiz çalışması,
- Hat yanında malzemeler için yeterli alanların bulunmaması,
- Her malzemenin müşteri talebinin birbirinden farklı olması.

Tüm bu problemler ele alındığında montaj hatları için standart ve sistematik bir malzeme besleme yöntemi seçilmesine karar verilmiştir. Çalışmanın amacı, fabrikada bulunan farklı değer akışlarındaki montaj hatları için mevcut malzemelerin en verimli şekilde besleme yönteminin seçilmesi ve yeni malzemelerin besleme yöntemine kolayca karar verilebilmesidir. Tezin ikinci bölümünde malzeme besleme yöntemleri ile ilgili olarak literatür incelenmiş, kanban, hat yanı besleme, kitleme yaklaşımları ve daha önceki çalışmalarda yapılan karşılaştırmalar ele alınmıştır. Tezin üçüncü bölümünde uygulama aşamasında kullanılmış olan yapay sinir ağı ile ilgili bilgiler verilmiştir. Dördüncü bölümünde fabrikada pilot alandaki mevcut malzeme besleme yöntemlerinden bahsedilerek çok katmanlı geri yayılım algoritması ile yapay sinir ağı kullanılarak fabrikada çalışılmak istenen pilot hat üzerinden uygulama anlatılmıştır. Tezin son bölümünde, uygulama ile elde edilen malzeme seçim sonuçları verilmiştir. Sonuçlar yorumlanarak gelecek çalışmalar için öneride bulunulmuştur.

2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

Bu çalışma kapsamında literatürde, montaj hattı besleme yöntemleri ve malzeme besleme yöntemi seçim problemleri araştırılmıştır. Literatürdeki birçok çalışmada malzeme besleme yöntemleri birbirleri ile kıyaslanarak malzeme seçim problemi için çeşitli yöntemler kullanılmıştır. Bu bölümde literatürde yer alan farklı malzeme besleme yöntemleri açıklanmıştır.

Literatürde tam zamanında üretim, hat yanı stoklama, kitleme, kanban, sıralama ve melez malzeme besleme yöntemlerinden bahsedilmektedir. Makalelerde en çok hat yanı stoklama, kitleme ve tam zamanında üretim malzeme besleme yöntemlerinden bahsedilmiştir (Kılıç ve Durmuşoğlu, 2015). Bahsedilen malzeme besleme yöntemlerinden firmadaki uygulama için en uygun olabilecek dört yöntem anlatılmıştır. Bunlar sırasıyla; kanban, hat yanı besleme, kit, ihtiyaca dayalı besleme yöntemi ve bir veya birden fazla besleme yönteminin bir araya geldiği melez malzeme besleme yöntemleridir.

2.1. Kanban

Kanbanla malzeme besleme sisteminde, her kutu ilgili ürün hakkında bilgiler içeren bir kart ile ilişkilendirilir. Kanban kartları her zaman ürünlerle birlikte süreçlerde ilerler. Kanban kartı ile istasyonlar tüketim bazlı yeniden ilgili parçalar ile doldurulur (Faccio vd., 2013; Kumar ve Pannerselvam, 2007).

Kanban, çekme prensibiyle montaj hattı malzemeleri tükettiğinde üretime veya tedarikçiye üret sinyali gönderen bir malzeme besleme yöntemidir (Uçan, 2014). Montaj veya üretimde bir aksaklık olduğunda önceki ve sonraki sürecin etkilenmesi en aza indirilir, kayıpların analizini kolaylaştırır (Koçan, 2014).

Kanbanla malzeme besleme, üretimde yaşanabilecek aksaklıklardan etkilenme düzeyini azaltmak amacıyla süpermarket yardımı ile minimum maksimum stoğu tanımlı, uyarı sınırları belirli bir üretim yönetimi sağlar (Koçan, 2014).

Kanbanla malzeme besleme yönteminin stok maliyetini azaltması, müşteri talebine yönelik bir üretim gerçekleştiği için esnekliği artırır, ek bir yönetim sistemi ihtiyacına gerek duymaz. Süpermarket ara stoğu tuttuğu için birbirinden farklı verimlilik düzeyine sahip iki proses arasındaki akışta problem olmadan yönetmeye yardımcı olur (Koçan, 2014; Uçan, 2014).

Çekme kanbanı, tedarikçi kanbanı ve üretim kanbanı olmak üzere üç farklı kanban tipi bulunmaktadır. Çekme kanbanı; bir sonraki istasyonun bir önceki istasyondan çekmek istediği malzemenin tip, miktar, yer gibi bilgilerin yer aldığı kartlardır. Tedarikçi kanbanı; tedarikçilere istenen malzemeyi, istenen adette, istenen zamanda, istenen yere verilmesini sağlayan bilgileri içeren kartlardır. Üretim kanbanı; bir önceki prosese bir sonraki proseste kullanılacak malzemenin tipi ve adetini söyleyerek süpermarketteki bir kutu malzemeyi tanımlar (Uçan, 2014).

2.2. Hat Yanı Besleme

Hat yanı besleme yöntemi parçaların merkezi bir depodan kullanılacağı noktaya yakın bir alana taşınması olarak düşünülmektedir. İlgili alanda parçalar stoklanır, montaj hattındaki operatör malzemeye ihtiyaç duyduğunda hat yanındaki stok alanlarından kullanır. Belirli bir parçaya artık ihtiyaç duyulmadığında veya ilgili parça kutusu boşaldığında tekrar merkezi depoya aktarılır ve hat yanındaki stok alanında yer açılması sağlanır (Zammori vd., 2015).

Bu yaklaşımda malzemeler devamlı olarak montaj hatı yanındaki stok alanında mevcuttur. Malzeme çeşitliliğinin çok olduğu işletmelerde hat yanı besleme politikası uygulandığında montaj hattı yanındaki stok alanları fazla olacaktır (Çorakçı, 2008). Malzeme çeşitliliği düşük, üretim hacminin yüksek olduğu işletmeler için avantajlı bir malzeme besleme yöntemidir (Koçan, 2014).

Malzeme çeşitliliği fazla olan hatlarda, hat yanında malzeme miktarı çok olduğunda montaj veya malzeme hazırlama operatörünün parça arama, bulma, seçme süresi fazla olacağından montaj verimliliğini düşüren bir malzeme besleme yöntemidir (Çevikcan vd., 2018).

2.3. Kitleme (Kitting)

Kitleme, belirli bir ürünün üretimi için gereken parçaların gereken adet kadar toplanarak montaj hattına belirlenen bir kutu içerisinde konularak getirilmesidir (Zammori vd., 2015).

Kitlemeye alt malzemeler dahil olabileceği gibi yarı monteli alt montaj parçaları da dahil olabilir (Ronen,1991, aktaran Koçan, 2014).

Kitlerin eksiksiz ve hatasız hazırlanması montaj hattı duruşunu engellemek ve hatalı parça montajı ile kalite problemlerine yol açmaması için önemlidir (Çevikcan, vd., 2018).

Kit hazırlığı, ilgili montaj hattının gereklilikleri dikkate alınarak yapılmalıdır. İstasyon bazlı besleme, giriş ve çıkış yönü belirlenerek besleme, hat yanında kit hazırlığı, stok alanında kit hazırlığı gibi karar verilmesi gereken kriterler bulunmaktadır (Çevikcan, vd., 2018).

Kitleme, hat kenarındaki stok miktarını azaltmak, kaliteyi artırmak, montaj hattında çalışan operatörleri verimliliğini artırarak çıktı sayısını artırmak amaçları ile çeşitli endüstrilerde tercih edilmiştir. Kit ile besleme yönteminin diğer bir avantajı olarak; parçaların montaj hattına hazır gelmesiyle, tip dönme sırasında hat kenarındaki stok alanına yürüme, parça arama, hatta yükleme sürelerini minimize ederek tip dönme süresini kısalttığı makalelerde değinilmiştir (Koçan, 2014).

Koçan (2014), kit ile tedarik sisteminde karar verilmesi gereken parametreleri aşağıdaki şekilde sıralamıştır:

- Kitlerin kim tarafından yapılacağı (fabrika içindeki işgücü kaynağı, tedarikçi, lojistik firması): Kitler fabrika içerisindeki çalışanlar tarafından yapılabileceği gibi tedarikçi firma ile anlaşarak kite uygun malzeme adeti göndermesi sağlanabilir veya üçüncü bir lojistik firması tarafından tedarikçilerden alınan malzemeler kit hazırlığı yapılarak doğrudan montaj hattına beslenebilir.
- Kitlerin nerede yapılacağı (fabrika içi, fabrika dışı, montaj hattına yakın sipariş toplama alanı, merkezi depo): Kitler fabrika içerisindeki bir merkezi depoda hazırlanabileceği gibi, hat yanında tanımlı bir alanda da hazırlanabilir, veya fabrika dışında üçüncü bir firmada hazırlanabilir.
- Hazırlanacak kit sayısı (tam zamanında/kit deposunda tutulacak adet kadar): Kitler montaj hattının tüketeceği adet kadar frekansiyel olarak hazırlanabilir, ya da kit deposunun kapasitesi kadar önden hazırlanarak montaj hattına besleme gerçekleştirilebilir.
- Kitlerin hareketli (her istasyona ayrı ayrı) veya sabit olması (istasyon yanındaki tanımlı kit alanı): Kitler montaj hattı tasarımına bağlı olarak; her istasyondaki tanımlı yere ayrı ayrı da beslenebilir, veya istasyon yanında kit için tanımlı alandan hatta beslenmesi sağlanabilir.
- Kit hazırlama yöntemi (manuel, robotik): Kitler montaj hattı operatörü, depo operatörü veya malzeme hazırlama operatörü tarafından hazırlanabileceği gibi otomasyona sahip robotlar tarafından da hazırlanabilir. İş gücü ve yatırım maliyeti dikkate alınarak kit ile malzeme besleme uygulanacak firma dinamiğine göre karar verilmelidir.
- İş gücü seçimi (montaj hattı operatörü, depo operatörü): Montaj hattı operatörünün doluluğuna bağlı olarak montaj hattına malzemeler montaj hattı operatörü tarafından beslenebileceği gibi depodaki operatörler tarafından tanımlı alanda kit hazırlığı yapılması sağlanabilir.
- Üretim siparişi toplama biçimi (tekil sipariş toplama, çoklu sipariş toplama, ışığa göre sipariş toplama vb.)

- Kit hazırlama alanı ile hat arasındaki bilgi akışı (kanban, görselleştirme, malzeme toplama listesi, RFID sistemleri): Kitlerin hazır olup olmadığı, hangi malzemeleri üretecekleri bilgisi gibi bilgilerin kit hazırlama alanı ile montaj hattı arasında sağlanması gereklidir. RFID gibi otomatik sistemler, kanban kartları, görselleştirme veya listeler aracılığı ile bilgi alışverişi sağlanabilmektedir.
- Kit kaplarının seçimi: Montaj hattına beslenecek parça boyut, hacim, ağırlık bilgilerine göre kit kaplarının seçimi yapılmalıdır.
- Kitlerin hatta sevkiyat şekli (kit arabası, robotik sistem, konveyör): Montaj hattı tasarımı ve kit hazırlama yerine göre sevkiyat şekli; kit arabası, robotik sistemler ve konveyörler gibi karar verilmesi gereken bir konudur.
- Kit içerisinde yer alacak ürünlerin özellikleri (çok küçük, çok büyük, pahalı, kalitesel elleçlemeye uygun olmayan parçaların durumu: Montaj hattına beslenecek malzemelerin boyutu, fiyatı ve herhangi bir kalite problemine yol açma riski değerlendirilerek kite konulup konulmayacağına karar verilmelidir.

Kit ile besleme yapıldığında hat yanındaki ve istasyonlar arasındaki stok miktarı azaldığı için yalın ve standart bir üretim alanının oluşmasını sağlar. Üretimin esnekliğini artırır, ilgili üretim siparişine ait parçalar kittede hazır halde olduğu için parça arama, karar verme, hat yanından montaj hattına taşıma süreleri azalır yok olduğu için tip dönme süresini kısaltır, malzemelerin istasyona veya istasyonlara kolayca ikmalini sağlar. Kittede yalnızca ilgili üretim siparişinin parçaları bulunduğu için hatalı parçanın takılma ihtimalini azaltır. Hatalı parça takılması nedeniyle demontaj ve tekrar montaj yapılmaz verimliliği ve kaliteyi artırır. Olası mühendislik değişikliklerine cevap verme hızı, ilgili malzemenin hattan alınması ile artar (Koçan, 2014).

Kit ile beslemenin bazı dezavantajları aşağıda belirtilmiştir:

- Kit hazırlamak için gereken zaman katma değer yaratmayan zamandır, kit hazırlamak için ek bir alan ihtiyacı vardır, ihtiyaç olacak malzemelerin listesi önceden kit hazırlayacak operatörlerle paylaşılmalıdır, ek planlama gerektirir. Elleçleme fazla olduğundan kalite zararı görebilecek veya çalınabilir parçalar için

risklidir. Çok büyük ve ağır veya çok küçük parçaları kite koymak zor olabilir (Bozer ve McGinnis, 1992).

- Kit hazırlama alanında, kit içerisinde bulunacak malzemelerin gerekli zamanda ve miktarda bulunması gerekir. Tedarikçi firmaların veya üretim hatlarındaki temin sürelerindeki farklılıkların azaltılması gereklidir. Kit tüm tedarik zincirini etkileyen bir süreçtir. Kit şeklinde teslimat, tedarikçilerin olgunluk seviyesini artırmakla birlikte müşteriye cevap verme süresini de düşürecektir (Koçan,2014)
- Eksik malzemesi olan kitin montaj hattına teslim edilmesi, hat duruşuna neden olabileceği gibi eksik malzeme için gereken ek bir taşıma maliyetine de sebep olur. Eksik malzemeli kit yerine plandaki diğer tipin üretimi için tip dönme süresini artırır (Koçan, 2014)
- Kit hazırlamak için işgücüne ihtiyaç vardır, bu iş gücü depodaki personel sayısı artırılarak karşılanabileceği gibi montaj hattı malzeme besleme operatorlerinin sayısı artırılarak hat yanında kit hazırlanması olarak karşılanabilir. Yeterli olgunluk seviyesinde olmayan tedarikçiler ile çalışıldığında kit hazırlama zamanında kite girecek tüm alt parça ve/veya yarı montajı parça tedariki istenen zamanda sağlanamayabilir (Koçan, 2014).

2.4. Malzeme Besleme Yöntemlerinin Karşılaştırması

Yapılan literatür araştırmasında hat yanı besleme yöntemi ile kit ile besleme yöntemi ara stok miktarı, temin süresi, malzeme hazırlayan operatör sayısı, kit hazırlamak için gereken zaman, montaj hattı üretim adeti parametreleri ile bir karşılaştırma yapılmıştır, Malzeme besleme yöntemi seçimi için uygulanan çözüm yaklaşımlarının çoğu maliyet fonksiyonu ve lineer programlama yöntemleridir.

Bozer ve McGinnes (1992), hat yanı besleme ve kitleme arasındaki farkları incelemiş, en iyi montaj hattı besleme tipi için bir karar verme modeli geliştirmiştir. Geliştirilen model bir tam sayılı doğrusal programlama modelidir. İki besleme sistemini için süreçler arasındaki stok miktarı, merkezi bir depo ve hat yanındaki kullanılacak alan ihtiyacı, malzemeleri taşıma ölçütü ile kıyaslama yapılmıştır. Kit ile besleme yönteminin alan gereksinimini azaltıp süreç içerisindeki stok miktarını azaltarak avantajlı olduğu

düşünülr iken hazırlama sürecinin iş gücü açısından değerlendirilmesinde hat yanı besleme yönteminin daha avantajlı olduđu yorumlanmıştır.

Caputo ve Pelagagge (2008), kitleme ve hat yanı stoklamayı iş gücü, alan ihtiyacı, süreç içindeki stok miktarı parametreleri ile maliyeti en küçüklemeyi amaçlayan bir optimizasyon modeli ile değerlendirmiştir. Bilgisayar simülasyonu tabanlı bir parametrik analiz yapmıştır. Kitlemenin süreç içi stođu minimize ettiđini, hat yanı stoklamanın sipariş toplama süreci için işçilik gerektirdiđini fakat üretim alanında daha fazla stok alanına ihtiyaç olacađını yorumlamıştır.

Wänström ve Medbo (2008), hat yanı besleme ile sıralı tedarik sistemlerini iş gücü, üretim esnekliđi, malzeme planlama parametreleri ile montaj süreci performansını nasıl etkilediđini inceleyerek bir kıyaslama yapmıştır. İki farklı İsveç otomotiv fabrikasında vaka incelenmiştir, ayrıca 20'den fazla Japonya'daki firmaya ziyaret gerçekleştirilmiştir. Malzemelerin bulunduđu rafların tasarımının ve paketleme tiplerinin seçiminin montaj performansına etkisi olduđu belirlenmiştir. Ayrıca, iş gücü, üretim esnekliđi, malzeme planlama, verimlilik gibi incelenen parametrelere göre hat yanı stoklama yönteminin daha iyi bir seçim olacađı yorumlanmıştır.

Battini vd. (2009), parça besleme yöntemlerinden iş istasyonuna palet, iş istasyonuna araba ve kitleme için bir çalışma yaparak montaj hattı tasarımına etki eden en önemli faktörleri montaj hattı ve ambar arasındaki mesafe, her bir bitmiş ürünün bileşenlerinin ortalama sayısı, ortalama montaj lot büyüklüđu ve montaj hattındaki istasyon sayısı olarak değerlendirmektedir.

Hua ve Johnson (2010), hat besleme yöntemini doğru seçmek için faktörleri şöyle açıklamıştır; ürün ve bileşenlerin üretim hacmine etkisi, çeşitliliğin ve boyutun etkisi, bileşenlerin stoklanmasını ve malzeme elleçlemesinin etkisi, üretimin kontrolünün etkisi, sistem seçiminin operasyonel performans üzerindeki etkisinin incelenmesi gerektiđini belirtmiştir.

Caputo ve Pelagagge (2011), kit, tam zamanında kanban tabanlı sürekli besleme ve hat yanı besleme yöntemleri için karar vermeye yardımcı bir modeli vaka çalışması ile göstermişlerdir. Önerilen seçim yöntemi, İtalya'da otomat üreticisinde uygulanmıştır. Bozer ve McGinnes'in 1992 yılında oluşturduğu maliyet fonksiyonlu model geliştirilerek iş gücü gerekliliği, ekipman maliyeti ve süreç içi stokların maliyeti eklenmiştir. Tüm malzemeleri içeren tek bir besleme yöntemi yerine, melez besleme yöntemlerinin tercih edilebilir olduğunu yorumlamışlardır.

Hanson vd. (2012), kitleme ve hat yanı stoklamadaki malzemelerin montaj hattına getirilmesindeki harcanan süreyi karşılaştırmayı otomobil endüstrisinde gerçekleştirmiştir. Yüksek çeşitlilikte kittede avantajlı olduğu yorumlanarak kitlemenin malzeme toplama ve sayma işlemlerini artırdığı, hat yanı stoklamasının süreç içi malzeme stoğunu artırarak elde tutma maliyetini artırdığı aynı bileşen farklı montaj istasyonlarında kullanılacaksa hat içerisinde çoklu alan ihtiyacı gerektireceğinden bahsetmiştir.

Limere vd. (2012), kit ve hat yanı stoklama yöntemlerini seçmek amacıyla işçilik temelli matematiksel maliyet yöntemi geliştirmişlerdir.

Hanson ve Brolin (2013), hat yanı ve kitlemeyi ürünün kalitesi, montaj desteği, esnekliği, bitmiş ürün envanter düzeyi ve gerekli stok alanı açısından tanımlamışlardır.

Caputo vd. (2015), toplam maliyeti minimize edecek montaj hattına beslenen parçalar için en uygun malzeme besleme yöntemini seçmeyi amaçlayarak matematiksel model geliştirmiştir. Parametre olarak işçilik maliyeti, yatırım maliyeti, süreç içi stok elde tutma maliyeti, fabrikada kaplanan yer maliyeti değerlendirilmiştir. Otomotiv endüstrisinden alınan büyük boyutlu bir problem için vaka çalışması yapılmıştır. Duyarlılık analizi ile desteklenmiştir. Çalışma Matlab programındaki optimizasyon araçları ile gerçekleştirilmiştir.

Limere vd. (2015), hat yanı besleme ve kitleme yöntemi arasında seçim yapmak amacıyla lojistik maliyetlerini en küçükleyecek bir optimizasyon modeli geliştirmişlerdir. Geliştirilen model bir karışık tam sayılı programlama modelidir. Amaç fonksiyonunda

yer alan en küçüklenmek istenen maliyet kalemleri şunlardır: montaj hattı yanındaki malzemeleri toplamak için işçilik maliyetler,iç taşıma için gereken maliyetler, süpermarketin dolumu için gereken maliyetlerdir. Karar değişkenleri şunlardır: ilgili malzemenin istasyona toplu mu verileceği, kit ile mi besleneceği, toplu bir malzeme alımı için operatörün iş istasyonundaki ortalama yürüme mesafesi, bir bitmiş ürünü montajlamak için gereken kit sayısı, stoklama yapılacak kutu sayısı. Model CPLEX çözücü ile dört farklı kısıt seçimi ile çözdürülmüştür: alan kısıtlı, alan kısıtı olmadan, bir hattaki tüm parçaları kite koyarak, bir hattaki tüm parçaları toplu besleyerek. Model sonucunda kit ile besleme yönteminin az hacimli parçalar için yürüme mesafesini azaltarak tercih sebebi olabileceği yorumlanmıştır.

Sali vd. (2015), kit, hat yanı ve sıralama yöntemlerini, montaj öncesi malzeme hazırlama, malzeme toplama, merkezi depodan montaj hattına taşıma, stoklama maliyetlerini değerlendirecek bir toplam maliyet formülasyonu ile incelemişlerdir.

Kılıç ve Durmuşoğlu (2015), malzeme besleme sistemlerini, parça taşıma, parça besleme politikaları ve parça stoklama olarak üçe ayırarak detaylı literatür araştırması sunmuşlardır. Hat yanı, kit ve kanban tabanlı yanı sıra melez yaklaşımlara da makalelerinde yer vermişlerdir. Literatür araştırmaları sonucunda çoğu makalenin hat yanı stok ve kit ile besleme hakkında olduğunu söylemişlerdir. Çoğunda maliyet minimizasyonunu amaçlarken parameter olarak montaj için gerekli toplam alan, malzeme toplama verimliliği, doğru parça besleme, malzeme taşıma süresi, parça arama süresi. Vaka analizi çalışmalarında genellikle simülasyon modelleri kullanılmıştır. Ayrıca malzeme besleme seçim problemi için optimizasyon modelleri ve sezgisel yaklaşımlar tercih edilmiştir. İncelenen tüm makaleler sonucunda çıkarımda bulunulmuştur. Müşterilerin ürün esnekliğine yönelik artan talebine bağlı olarak melez besleme yöntemi seçimleri gereklidir. Hat yanından parça besleme, kısıtlı alan ve arama, bulma seçme gibi hazırlık maliyetler açısından zordur, sadece kitleme ile besleme yöntemini seçmek büyük ve pahalı parçaların üretim alanında tanımlı olacak kit alanında bırakılması problem olabilir.

Caputo vd. (2018), kit, hat yanı stoklama ve tam zamanında üretim yöntemlerine göre malzemelerin montaj hatlarına tedarikindeki maliyetin parça özelliklerine bağlı olan bir maliyet modeli geliştirerek her malzeme için en iyi yöntemi karar veren duyarlılık ve parametrik analiz yapmışlardır.

Baller vd. (2020), dokuz farklı hat besleme yönteminin malzeme ailesi başına farklı hat besleme yöntemlerini modelleyerek montaj hattının yanı sıra süpermarkette de değişken yürüme mesafelerini göz önünde bulundurarak literatürdeki karma tamsayı programlama formülasyonlarını esnek hat kenarı aralığına izin vererek genişletmişlerdir. Ayrıca geliştirilen model ile bir vaka çalışmasında uygulanarak önerilen modelin manuel planlamaya kıyasla toplam maliyetleri %3,36 oranında azalttığı sonucuna ulaşmışlardır. Esnek hat kenarı aralığına izin verildiğinde bu oran % 7,54 'e çıkmaktadır.

Zennora vd. (2020), büyük boyutlu sabit montajı olan malzemeler için montaj operatörlerinin verimliliğini düşüren malzeme besleme faaliyetleri ile montaj faaliyetlerinin aynı anda yapılabilmesi için malzeme besleme maliyetini azalmayı amaçlayan bir matematiksel model geliştirmişlerdir. Değişkenlerin ve parametrelerin geliştirilen model üzerindeki etkilerini inceleyebilmek amacıyla bir duyarlılık analizi yapmışlardır.

İncelenen literatür araştırmasında montaj hattı besleme yöntemini seçmek için aşağıda belirtilen parametrelerin kullanıldığı belirlenmiştir:

- Alan gereksinimi
- Süreç içi stok miktarı
- İş gücü maliyeti (malzeme arama, hazırlama, toplama, taşıma, stoklama işlemleri için)
- Üretim esnekliği
- Malzeme planlama
- Ortak bileşen sayısı, montaj ortalama lot büyüklüğü, montaj istasyon sayısı
- Üretim hacmi
- Ürün çeşitliliği
- Ürün elleçleme

- Kalite
- Verimlilik
- Zaman
- Stok elde tutma maliyeti
- Yatırım maliyeti
- Yer
- Lojistik maliyeti

Literatür arařtırmasında incelenen parametreler ile uygulama yapılan firmanın istekleri ve yapısı dođrultusunda uygun montaj hattı besleme yöntemini seçmek amacıyla beř farklı parametre seçilmiştir. Bunlar; parça boyutu, üretim hacmi, referans sayısı, montaj istasyon sayısı ve ürün üretim yeri ile ilgilidir.

Çalışmalarda malzeme besleme yöntemi seçim problemleri için; maliyet fonksiyonları, liner programlama ve genetik algoritmalar kullanılmıştır.

Yapay sinir ađları yöntemleri ile çözüm yaklaşımının literatürdeki açık kalan kısım olduđu fark edilmiştir. Çözümü istenen problem karmaşık, doğrusal olmayan veri yapısına mevcuttur. Yapay sinir ađları karmaşık ve doğrusal olmayan yapılarda, eksik ve/veya hatalı verilerde tahminleme yapabilme özelliđine sahip kısa sürede çözüm bulabilen yaklaşımlardır. Bu çalışmada yapay sinir ađı (YSA) ile çözüm yöntemi tercih edilmiştir.

3. MATERYAL ve YÖNTEM

Montaj hattı besleme yöntemi seçimi için literatür incelenmiş, ilgili firmada uygulanabilecek yöntemler detaylı araştırılmıştır. Literatür araştırması sonucunda, mevcut çalışmalarda çok sık rastlanmayan yapay sinir ağları ile çözüm yaklaşımı, problemin çözümü için uygun görülerek yöntem ile ilgili literatür araştırmasına devam edilmiştir. Yapay sinir ağları, seçim problemlerinde tercih edildiği için malzeme besleme yöntemi seçim probleminde düşünülmüştür. Bu bölümde yapay sinir ağları çözüm yaklaşımı hakkında genel bilgiler verilmiştir.

3.1. Yapay Sinir Ağları

Bilgisayarların öğrenmesine yönelik çalışmaları kapsayan yapay sinir ağları, yapay zeka biliminin alt dalı olarak ilgi gören araştırma alanı olmaktadır. Günümüzde sürekli olarak gelişen yapay zeka ile birlikte tüketiciler için yeni ürünler ortaya çıkmakta ve bu kendisini günlük yaşamda daha yoğun olarak hissettirmektedir.

YSA insan beyninin sinir yapısını taklit ederek sinirsel algılayıcılar yardımı ile önceden öğrenilmiş ya da sınıflandırılmış bilgileri kullanarak yeni bilgiler türetebilen ve oluşturabilen, karar verebilen bilgisayar programlarıdır. Örüntü tanıma, sistem tanıma, robotik, sinyal işleme, doğrusal olmayan denetim alanları gibi birçok uygulama alanında YSA yaygın olarak kullanılmaktadır (Efe vd., 1999).

YSA'nın tarihsel gelişimine bakıldığında 1970 yılına kadar pek ilerleme kaydedilememiştir. 1970 yılına gelindiğinde ise XOR probleminin çok katmanlı ağ ile çözülmesiyle YSA'na ilgi artmıştır (Öztemel, 2012).

YSA'nın tercih edilmesini sağlayan özellikler aşağıdaki şekilde özetlenebilir;

- YSA hızlı bilgi işleme yeteneğine sahiptir ve bu özelliğe sahip olmasını sağlayan şey paralel yapıya sahip olmasıdır (Bayır, 2006).

- YSA'nın paralel sistemler mantığında çalışması, sistemin toplam işlevinin yapısal olarak dağıtılmış olmasıdır. Diğer bir deyişle birçok nöron eş zamanlı olarak çalışır ve karmaşık bir işlev çok sayıda küçük nöron aktivitesinin bir araya gelmesiyle oluşur. Bu da zaman içerisinde herhangi bir nöronun işlev dışı kalması durumunda ağ performansının önemli ölçüde etkilenmeyeceği anlamına gelmektedir (Bayır, 2006).
- YSA genelleme yapabilme yeteneğine sahiptir. Ağın eğitimi esnasında ağa bazı bilgiler verilir. Ağın eğitimi tamamlandıktan sonra, yapay sinir ağı daha önce görmediği veriler için de çözüm üretebilir (Aksoy, 2005).
- YSA'nın ağ fonksiyonları doğrusal değildir. Temelde nöronların doğrusal olmayan yapıya sahip olması, nöron bağlantılarından meydana gelen YSA'nın doğrusal olmayan özellik göstermesini sağlar ve karmaşık problemi çözümünde kolaylık sağlar (Ergezer vd., 2003).
- Sayısal ortamda tasarlanan YSA yaklaşımlarının tüm devre gerçekleştirilebilirlikleri mevcuttur (Bayır, 2006).
- YSA'nın istenilen doğruluk düzeyinde veriler elde edebilmesi için ağırlıkların doğru bir şekilde belirlenmesi gerekmektedir. Ağırlıklar istenilen sonuçları verene kadar değiştirilir ve ilgili problemde almış olduğu örnekleri değerlendirerek öğrenme özelliğini kazanır (Bayır, 2006).
- YSA, problemde aldığı verilerle kendi denklemlerini oluşturabilme yeteneğine sahiptir (Ergezer vd., 2003).
- YSA, arzu edilen sayıda değişken ve parametreyle çalışabilmektedir. Bu özelliği sayesinde tahmin ve çözümleri çok başarılı düzeyde olmaktadır (Bayır, 2006).

YSA'nın belirtilen dezavantajları aşağıdaki şekilde özetlenebilir (Çörekçioğlu vd., 2021):

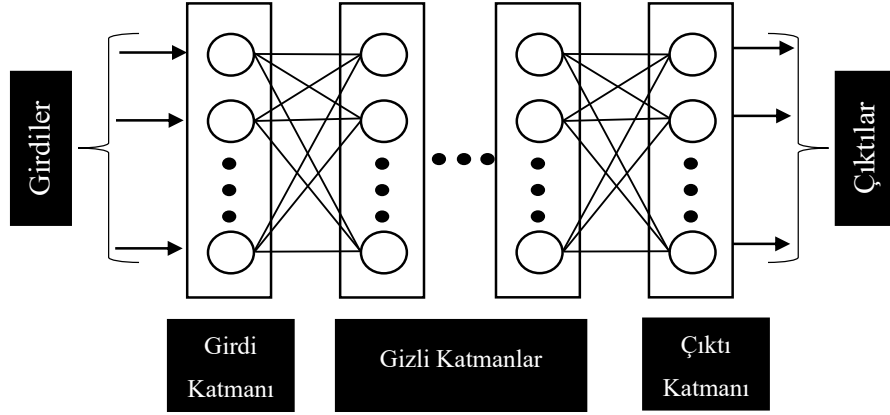
- Çözülmesi beklenen probleme uygun bir ağ yapısı kurulması gerekmektedir, iterasyonlar yardımı ile uygun ağ yapısının bulunması zaman alabilir.

- Ağın eğitimde problem tüm farklı yönleriyle verilmezse ağ hata değeri büyük sonuçlar verebilir.
- Her problem için farklı parametreler ile ağ yapısı kurulmalıdır, parametrelerin seçimi için kural tanımlanmamıştır. Öğrenme katsayısı, gizli katman sayısı, düğüm sayısı gibi parametreler deneme-yanılma yöntemi ile bulunması gereklidir.
- Veriler, ağa eğitim amacıyla verilmeden önce sayısallaştırılmalıdır. Sayısallaştırma işlemi ağ performansını etkilemektedir, en uygun sayısallaştırma yapılmazsa ağ performansı düşük olabilir.
- Eğitimin sonlandırma zamanına dair bir standart yoktur, belirlenen hata seviyesinin altına indiğinde eğitim tamamlanmış olarak kabul edilir. Eğitimin tamamlanmasının en uygun zamanının ne olduğu ile ilgili bir kabul yoktur.

3.2. Yapay Sinir Ağ Yapısı

İnsanın biyolojik sinir yapısından ilham alınarak oluşturulan yapay sinir ağları üç farklı katman çeşidinden meydana gelmektedir. Girdi katmanı, sadece dışardan gelen bilgilerin ağa iletiildiği ve bilginin işlenmediği katmandır. Gizli katman, girdi katmanından gelen bilgilerin işlendiği ve çıktı katmanına gönderildiği yerdir. Bir ağda birden fazla gizli katman bulunabilir. Çıktı katmanında ise, gizli katmanlardan gelen bilgilerin işlenerek bilginin dış dünyaya gönderildiği katmandır (Can ve Şahin, 2021).

Örnek bir yapay sinir ağı yapısı Şekil 3.1’de verilmiştir.



Şekil 3.1. Yapay sinir ağı yapısı

YSA, girdi değişkeninden yola çıkarak çıktı değişkenini tahmin eden bir sezgisel yapay zeka yöntemidir. Her bir girdinin bir ağırlığı vardır, aktivasyon fonksiyonları kullanılarak çıktı değeri hesaplanır (Bayır, 2006).

$$Y = f(w_1 * x_1 + w_2 * x_2 + \dots + w_n * x_n - t) \quad (3.1)$$

Eşitlik 3.1’ de girdiler; ağırlıkları ile gizli katmanına yanlı(bias) terim eklenerek veya çıkartılarak iletilir. Gizli katmanındaki değerler ağırlık ile çarpılarak yanlı terim eklenerek çıktı katmanına iletilir. En az hataya sahip ağı belirlemek için iterasyonlar yapılır (Bayır, 2006).

En çok tercih edilen aktivasyon fonksiyonları, lineer fonksiyon, sigmoid fonksiyon ve tanjant fonksiyonudur.

Ele alınan bir problemin YSA yaklaşımı ile çözümünde tasarımcının önüne çeşitli seçenekler çıkar. İlk seçenek öğrenme mekanizması üzerinedir. Choy vd. (2003), iki tip öğrenme stratejisinden bahsetmektedir. Bunlar öğreticili öğrenme ve öğreticisiz öğrenme olarak isimlendirilmektedir.

Öztemel (2012), aşağıda belirtilen üç farklı öğrenme stratejisini açıklamıştır:

1. Danışmanlı Öğrenme (Supervised Learning): Danışmanlı ya da denetimli öğrenme adı verilen bu sistemde; girdi ve çıktı örnekleri ağa sağlanarak ağ girdiyi süreçten geçirir ve kendi çıktısını üretmiş olur sonrasında gerçek çıktı ile karşılaştırma yapar. Bu öğrenmenin sonucunda, ortaya çıkan hatayı minimize etmek için bağlantılardaki ağırlıkların yeniden düzenlenmesi gerekir. Ağırlıkların düzenlenmesi işlemi hata seviyesinin istenen noktaya gelinceye kadar devam eder (Dongare vd., 2012).
2. Danışmansız Öğrenme (Unsupervised Learning): Eğitici-siz öğrenme olan bu yöntemde eğitim seti kullanılmamaktadır. Girdiler arasında grup oluşturma ve ayırım oluşturma YSA'na bırakılır. Eğitici-siz öğrenme algoritmaları sistemin karşılaştığı veri kümesinin içerdiği istatistiksel bilgilerin elde edilmesini amaçlar ve girdi bilgilerinin hangi kümeye ait olduğunu gösterir. Danışmansız öğrenmenin temeli dış müdahale olmaksızın, girdilerin ağ tarafından analiz edilmesi ve bu analiz sonucunda bağlantıların oluşturulmasıdır. Danışmansız öğrenme stratejisini kullanan ağ yapılarına Hopfield Ağı, Boltzman Makinesi, Hamming Ağı, Rekabetçi Öğrenme Ağları ve ART (Adaptif Rezonans Teorisi) ağları örnek gösterilebilir (Sevinçtekin, 2014).
3. Takviyeli Öğrenme: Bu yönetim eğitici öğrenme yönetimine benzerlik gösterse de danışmanlı öğrenme yönetimine göre takviyeli öğrenme yönteminde sisteme çok fazla detay verilmemektedir. Sisteme girilen bilgilerin çıktısına bakılarak, ağ yapısının sonuçları ne ölçüde doğru ya da yanlış olduğunu derece olarak bildirmektedir. Takviyeli öğrenmede verilen bu bilgilerin ağına tekrar kullanıp öğrenmesi amaçlanmaktadır (Sevinçtekin, 2014).

Bağlantı biçimlerine göre YSA iki farklı kategoride incelenmektedir:

1. İleri beslemeli yapay sinir ağları: İleri beslemeli modelde bilgiler girdiden çıktıya doğru ve geri dönüş olmadan bir sonraki katmanın girdisi olacak biçimde aktarılmaktadır. Bu tek yönlü akışta sırasıyla, girdilerin ağa tanıtıldığı giriş katmanından ara katmanlar ve çıktıların alındığı çıkış katmanına doğru bağlantılar

gerçekleşir. Tek yönlü akış gerçekleştiğinden dolayı bir döngü oluşmamaktadır (Çörekçioğlu vd., 2021).

2. Geri beslemeli yapay sinir ağları: Geri beslemeli modelde bilgiler ileri yönlü hareket ederken aynı zamanda geri yönlü akışında gerçekleştiği ağlardır. Bu modelde, sinir hücre çıktısı kendisine, kendinden önce gelen katmana veya kendi katmanında yer alan hücreye girdi olarak verilir bu da doğrusal olmayan ve ileri besleme modeline göre daha yavaş çalışan ağ yapısı anlamına gelmektedir. Geri beslemeli YSA'na örnek olarak; Eman, Hopfield ve Jordan ağları verilebilir (Çörekçioğlu vd., 2021).

Ayrıca, YSA katman sayısına göre tek ve çok katmanlı olarak ikiye ayrılmaktadırlar.

1. Tek katmanlı YSA: Girdi ve çıktı katmanı bulunup gizli katman bulunmayan ağ yapısına tek katmanlı yapay sinir ağları denilmektedir. Girdi ve çıktı katmanlarının birden fazla düğüm sayısı bulunabilir. Çıktı fonksiyonu, tek katmanlı YSA' da doğrusal olmaktadır (Arı ve Berberler, 2017). Yöntemin başarılı olması için verilerin doğrusal olması gereklidir (Taşoğlu, 2020). Girdiler aktivasyon fonksiyonu ile çıktı katmanına bağlanır, çıktı sayısı nöron sayısına eşittir. Tahmin değeri delta kuralına göre hesaplanarak iterasyonlar ağırlıkların tekrar düzenlenmesi ile devam eder (Taşoğlu, 2020).
2. Çok katmanlı YSA: Girdi ve çıktı katmanından farklı olarak gizli katmanların bulunduğu ağ yapılarıdır. Ağ yapısına eğitim işlemi uygulanır. Girdi ve çıktı değişkenleri verilerek ağın çıktı değerini öğrenip belirli hata düzeyinde katmanlara ağırlıklar verilerek tahmin etmesi beklenir. Öğrenme işlemi ileri veya geri beslemeli ağ yapısı ile yapılır (Çörekçioğlu vd., 2021). Çok katmanlı ve geri yayılım ağı, ağa verilen eğitim verisindeki çıktılar ile ağın tahmini arasındaki farka hata denilmektedir. Geri yayılım algoritmasında; ağdaki toplam hata düzeyini minimize etme amacıyla ağdaki tüm katmanlar arası ağırlıklara hata fonksiyonunun etkisini yayar. Çıkış yönündeki hatalara göre katmanlardaki ağırlıklar tekrar hesaplandığı için geri yayılım öğrenme kuralı denilmiştir. Bu ağ, genellikle Genelleştirilmiş Delta Kuralı ile eğitimini gerçekleştirmektedir (Bayır, 2006). Doğrusal olmayan problemlerde kullanımı

yaygındır. İleri beslemeli ve bir veya daha fazla gizli katmana sahiptir. Aynı katmandaki işlemciler arasında bağlantı yoktur fakat bir katmandaki işlemci bir sonraki katmandaki tüm işlemcilerle arasında bağ vardır (Çörekçioğlu vd., 2021).

Literatürde kullanımı tercih sebebi olan öğrenme kuralları aşağıda belirtilmiştir.

1. Hebb kuralı: Hebbian kuralı olarakta anılan, YSA'nın eğitiminde kullanılan öğrenme kuralı biyolojik sistemlere dayanmaktadır. Kuramın temel dayanağı, “eğer sinyal alan ile gönderen nöronlar arasındaki sinaptik ağırlıkların ikisi de matematiksel olarak aynı işarete sahip ise, bu iki nöron arasındaki bağ kuvvetlendirilmelidir, aksi halde bağın kuvveti azaltılmalıdır” ilkesine dayanmaktadır (Çelik, 2008).
2. Hopfield kuralı: Diğer YSA modellerine göre kıyaslandığında daha basit bir yapısı olan Hopfield ağ yapısı, denetimsiz bir öğrenme modeli olup John Hopfield tarafından geliştirilmiştir. Hebb kuramına benzeyen Hopfield kuramında, birbirine bağlı nöronlardan oluşan tek katmanlı ağ yapısına sahiptir ve önemli olan nokta bağ kuvvetlerindeki değişimlerin ne kadar olacağını modelde belirtmektir. Bu kurala göre; bağ kuvveti öğrenme hızı kadar artırılır ya da azaltılır. Bu öğrenme hızı pozitif ya da negatif bir sayısal değerdir. Uygulamada öğrenme hızı 0 ile 1 arasında seçilmektedir (Ballı, 2014).
3. Kohonen kuralı: 1980'lerde T. Kohonen tarafından geliştirilen öğrenme kuralı, biyolojik sistemdeki öğrenmeyi esas alarak geliştirilmiştir. Kohonen kuralı tek katmanlı ağ olup giriş ve çıkış nöronlarından oluşmaktadır. Giriş nöronlarının sayısını veri setindeki değişken sayısı belirler. Çıkış nöronlarının her biri bir kümeyi temsil eder. Diğer YSA'dan farklı olarak, çıkış katmanındaki nöronların dizilimi çok önemlidir. Bu dizilim doğrusal, dikdörtgensel, altıgen veya küp şeklinde olabilir (Gürbüz, 2020). Sisteme çıktı değerleri tanıtılmadığından dolayı denetimsiz öğrenme olarak ifade edilmektedir. Bu kuralın temel mantığında; kazanan hepsini alır anlayışı yatmaktadır. Girdi verilerine en yakın çıktıyı üreten nöron galip gelen olarak belirlenir ve buna göre nöron ağırlık değerlerini günceller. Galip gelen nöron, diğer nöronlardan daha güçlü konuma geçer ve diğer nöronlarda bu durumuna göre ağırlık değerlerini günceller. Güncellenen ağırlık

değerleri ile en iyi sonuca ulaşma olasılığı yakalanabilir ve bundan dolayı da kazanan nörona yakın olan diğer nöronların en iyi sonucu verme olasılığı artmış olur (Sevinçtekin, 2014).

4. Delta Kuralı: Son zamanlarda yaygın olarak kullanılan Widrow ve Hoff tarafından geliştirilen Delta kuralı, Windrow-Hoff Öğrenme ve En Küçük Kareler Ortalaması (Least Mean Square) kuralı olarak da bilinir. YSA' da kullanılan ve sistemin hata oranlarının belirlenmesinde Hebb kuralı ile birlikte en çok telaffuz edilen kuraldır. Delta kuralı, Hebb kuralının daha gelişmiş bir halidir ve Hebb kuralının üzerine kurulmuştur. Delta Kuralı' na göre bağların kuvvetleri, ağ çıktısı ile hedeflenen çıktı arasındaki fark (Delta) minimum olana kadar sürekli olarak değiştirilir. Buradaki hedef ağın hata karelerinin toplamının en aza indirilmesidir (Çelik, 2008).

Öğrenme Algoritması: YSA' da veriler ağ yapısındaki katmanların bağlantılarının ağırlıklarında tutulmaktadır, veriler düğümlerin yanı sıra tüm ağ yapısına saklanmaktadır. Düğümlerin ağırlık değerlerine ek olarak tüm ağdaki ağırlıkların uygun değerde olması gerekmektedir. Uygun ağırlık değerlerine ulaştırmak için ağı eğitmek gereklidir. Ağın öğrenmesi için ağırlık değerlerinin belirlenmiş bir kural ile değiştirilebilir olması gereklidir. İterasyonlar ile en küçük hata değeri bulunması amaçlanarak adım büyüklüğü ve adım yönü belirlenmektedir. Öğrenme algoritmalarının ortak özelliği adım büyüklüğünü bulma yöntemidir. Algoritmalar arası farklılık adım yönünün bulunmasıdır. İterasyonlarda önce adım yönü belirlenir sonrasında adım büyüklüğü belirlenir (Amasyalı, 2015).

Literatürde kullanılan öğrenme algoritmalarından birkaçı aşağıda belirtilmiştir:

- Levenberg- Marquardt Algoritması (Levenberg- Marquardt Algorithm): İleri beslemeli geri yayımlı, tekrarlamalı bir algoritmadır. Doğrusal olmayan fonksiyonların karelerinin toplamı olarak minimumu bulma yaklaşımını benimseyen bir algoritmadır (Yaqub vd., 2016). Eğim düşmesi (steepest descent) ve Newton algoritmalarından geliştirilmiştir (Mamizadeh ve Aslan, 2019). Bu algoritma, yakınsamanın kısa sürede olması yönünden avantajlıyken algoritma

çalışmasında yüksek bellek kullanılması yönünden dezavantajlıdır. Hataların karesinin toplamı amaç fonksiyonu olarak kullanılacağından Hessian matrisi kullanılmaktadır. Hessian matrisi tahmini için eşitlik 3.2 kullanılabilir.

$$H = J^T J \quad (3.2)$$

Eğim için eşitlik 3.3. kullanılmaktadır.

$$g = J^T e \quad (3.3)$$

Eşitlik 3.3.' deki J , ağırlık ve yanlılık değerleri ile ilk türevi alınan ağı Jacobian matrisi, e ağ hatalarının vektörüdür. Levenberg- Marquardt algoritması, hataların kareleri toplamı en uygun çözümü için eşitlik 3.4 ile hesaplanmaktadır.

$$X_{n+1} = X_n - [J^T J + \lambda I]^{-1} J^T e \quad (3.4)$$

n , iterasyon sayısı, I birim matrisi, λ Marquardt parametresi' dir. λ , sıfır değerini aldığıında Eşitlik 3.4 Hessian matris yaklaşımı Newton'un metodudur.

λ , için başlangıç değeri belirlenmektedir, sonraki iterasyonlarda Marquardt parametresi değişmektedir. Hataların kareleri toplamı değeri iterasyonlarda azaldığında, λ değeri belirli bir oran ile çarpılmaktadır. Hataların kareleri toplamı değeri iterasyonlarda arttığı durumda, λ değeri belirli bir orana bölünmektedir. Ağ performansını en iyilemek amaçlanır (Okkan vd., 2018).

- Bayes Düzenleme Algoritması (Bayesian Regularization Algorithm): Levenberg-Marquardt algoritmasına göre katmanların ağırlıklarını ve yanlılık terimini güncelleyerek ağı eğitilmesini sağlar. Büyük ağırlıklar çıktının aşırı değişikliğine neden olabilir bu nedenle algoritmada düzenleme yapılır, büyük ağırlıkların negatif etkileriyle başa çıkmada kullanılan geleneksel bir yöntemdir (Yaşub vd., 2016). En küçük kareler hata fonksiyonunun toplamı ve ağırlıkların bileşimini küçükleterek genelleme yapma yeteneği yüksek olan bir ağ düzenler (Taşoğlu, 2020). Geri yayılım için Levenberg-Marquardt yöntemine göre her değer Eşitlik 3.5, 3.6 ve 3.7' de verildiği gibi güncellenir.

$$JJ = Jt * Jt \quad (3.5)$$

$$Je = Jt * E \quad (3.6)$$

$$dt = -(JJ + I * mu) / Je \quad (3.7)$$

E , tüm hatalar, I , birim matris, J , Jacobian matris, t , yanlılık değeri, mu , ayarlanabilir parametredir.

- Ölçeklenmiş Eşlenik Azaltma Algoritması (Scaled Conjugate Gradient Algorithm): Conjugate Gradient Algoritmasının bir gelişmiş yöntemi olan, katman ağırlıkları ve ağ giriş değerleri mevcut olan türevi alınabilen transfer fonksiyonları olan YSA'nın eğitiminde kullanılan bir algoritmadır (Yağub vd., 2016). Kısa sürede öğrenme işlemi gerçekleştirilir (Taşoğlu, 2020). Eşlenik azaltma algoritması Eşitlik 3.8, 3.9, 3.10 ve 3.11' de verilmiştir.

$$p(0) = f'(w(0)) \quad (3.8)$$

$$w(n + 1) = w(n) + p(n) * d \quad (3.9)$$

$$b(n) = (f'(w(n)))^T * f'(w(n)) / (f'(w(n - 1)))^T * f'(w(n - 1)) \quad (3.10)$$

n iterasyon sayısı, d adım büyüklüğü ve p adım yönü'dür. Ölçeklenmiş eşlenik azaltma algoritması, eşlenik azaltma algoritmasından farklı olarak ikinci dereceden türev alınarak bir hesaplama gerçekleştirir (Amasyalı, 2015).

- Momentumlu Eğim Azaltma Algoritması (Gradient Descent with Momentum Algorithm): Eğim azaltma Algoritması (Gradient Descent Algorithm) lokal minimumu yakalamak için negatif eğimi izleyen bir optimizasyon algoritmasıdır (Yağub vd., 2016). Momentumlu eğim azaltma algoritması, eğim azaltma algoritmasından farklı olarak sadece lokal minimumu değil aynı zamanda hata yüzeyindeki son trendlere göre de ağı eğitir. Hata yüzeyindeki küçük sapmalara izin verir. Lokal minimumda, ağ en uygun hata değerini birkaç minimum değeri bulduğunda yakaladığını sanır, fakat daha küçük bir hata değeri yakalama potansiyeline sahiptir. Momentumlu eğim azaltma algoritması öğrenme oranı ve momentum sabiti olmak üzere iki farklı öğrenme parametresine sahiptir. Momentum sabiti sıfır değerini aldığı anda momentumun olmadığı anlamına

gelirken, bir deęerini aldıęında yksek momentumlu olduęu ve lokal minimuma duyarsız bir aę eęitimi gerekleřtięi anlamına gelir, aę eęitim performansı ktdr (Hagan vd., 1996).

Aktivasyon Fonksiyonu: Girdi katmanı ile ıktı katmanı arasındaki iliřkiyi oluřturmaktadır. Bir dęmn birden fazla girdisi olabilirken tek bir ıktısı olabilir. Bir girdinin aktivasyon sonrası deęeri ya direkt olarak ıktı dęmne iletilir ya da bařka bir dęme iletilir. Eęitimin hızının artması iin trevi alınabilir bir aktivasyon seilmesi nemlidir. Genellikle doęrusal olmayan aktivasyon fonksiyonları kullanılmaktadır. Aę tasarımı sırasında yapılan denemeler ile aktivasyon fonksiyonuna karar verilir (Tařoęlu, 2020).

Transfer fonksiyonu: Girdi katmanında bulunan dęmler bir aęırlık ile arpılarak transfer fonksiyonuna iletilir. Transfer fonksiyonundan gelen deęer ve yanlılık deęeri toplanarak eřik deęeri ile kıyaslanır. Aktivasyon fonksiyonunun trne gre bir ıktı retilir (Tařpoęlu, 2020). Yapay sinir aęlarında genellikle kullanılan transfer fonksiyonları, doęrusal olan ve doęrusal olmayan olarak ikiye ayrılmaktadır Radial tabanlı, logaritmik sigmoid, tanjant sigmoid gibi transfer fonksiyonları doęrusal deęildir (Koyuncu ve Tuna, 2016).

4. BULGULAR ve TARTIŞMA

Tez çalışması kapsamında uygulama yapılan firmada hidrolik motor ve pompa üretilmektedir. Fabrikada hücresel üretim yapılmaktadır. Fabrikada bulunan farklı değer akışlarından A10 motor/pompa değer akışındaki bir montaj hattı pilot hat olarak seçilmiştir. İlgili montaj hattında tip dönme süresi oldukça uzun, tip sayısı fazla ve verimsizliği yüksek olduğu için tercih sebebi olmuştur.

Bu bölümde pilot alanda mevcut durum analizi yapılarak seçilen çözüm yaklaşımının uygulama adımları anlatılmıştır.

4.1. Pilot Alanda Mevcut Durum Analizi

Fabrikada ürün gruplarına göre A2, A4, A6, A10 ve MC gibi farklı değer akışları bulunmaktadır. A10 değer akışında üç farklı montaj hattı bulunmaktadır. Üç montaj hattında kullanılan bazı alt bileşenlerin ön montaj olması gerekmektedir. İki farklı ön montaj adımı bulunmaktadır.

Üç montaj hattından bir tanesi tip dönme süresinin en uzun olduğu manuel montaj hattıdır. Pilot montaj hat olarak bu hat seçilmiştir.

Pilot hat, A10 değer akışındaki ve fabrikadaki diğer değer akışlarındaki montaj hatları ile bazı malzemeleri ortak kullanmaktadır. Bu hatta bileşenlerin tamamı verilmeden önce bileşenlerin bir kısmı iki farklı ön montaj hattında ara mamule dönüşmektedir. Bu da malzeme besleme yöntemi seçiminde farklı seçeneklerin bulunabileceği hat olmasını gerektirmektedir. Bu nedenle pilot alan olarak seçilmiştir.

Pilot hatta 2221 adet farklı tipte malzeme montajlanmaktadır. Bu malzemelerin 1150 adeti fabrika içerisinde üretilirken 1071 adeti tedarikçi firmalardan satın alınmaktadır. 103 farklı tip malzeme iki kutu sistemi ile kanban prensibinde yönetilirken 1047 farklı tip malzeme hat yanında stoklanmaktadır, ayrıca 1071 farklı tip malzeme montaj hattında ilgili malzemeye ihtiyaç duyulduğunda çağrı ile merkezi depodan tedarik edilmektedir.

Farklı tiplerdeki malzemeler farklı boyut ve ağırlığa sahiptir. Parçaların talepleri birbirinden farklı olmakla birlikte, talep zaman periyoduna göre değişiklik göstermektedir. Parçaların elleçlenmesi kalite problemine neden olmamaktadır.

Mevcut durumda montaja gerekli malzemeleri montaj operatörü, lojistik biriminden gelen üretim planına göre hazırlamaktadır. Lojistik birimi ön montaja ve diğer montaj hatlarına üretim planını paylaşmaktadır.

Montaj hattı yanındaki benzer tiplerin sayısı fazla olduğu için malzeme arama için geçen süre fazladır. Bu da tip dönme süresini uzatmaktadır. Plana göre montaj operatörü ambardan tedarik edilecek malzemeler için en az dört saat önce ambara bilgi vermelidir. Ambardan gelen malzemeler ihtiyaç adeti kadar kullanılarak hat yanında yeterli alan bulunmadığı için ambara tekrar teslim edilmesi için bilgi verilmektedir.

Malzeme besleme yöntemine ilgili montaj hattından sorumlu takım liderleri tecrübeleriyle karar vermektedir. Montaj operatörlerinin katma değersiz işler yapması, yeni gelecek makine ve montaj hatları için fabrikada yeterli alanın bulunmaması, montaj hattı çıktı sayısının arttırılmak istenmesi, montaj hattında malzeme karışması nedeniyle müşterilerden gelen şikayetler gibi sebepler ile malzeme besleme yöntemleri tekrar düzenlenmek istenmektedir. Tüm fabrikadaki malzemeler için karar verme işlemi, takım liderlerinin oldukça zamanını alacağı için fabrikadaki tüm değer akışlarına uygulanabilecek bir yöntem geliştirilmesi kararlaştırılmıştır.

Mevcut durumda hat besleme yöntemi olarak kullanılmayan kitleme, fabrikanın tip çeşitliliği fazla ürün talep hacmi az olduğu için önerilerek hat yanındaki alan ihtiyacına hizmet edecek, montaj operatörünün iş yükünü azaltarak montaj hattındaki çıktıyı arttıracak, eksik/yanlış montaj riskini azaltarak kaliteyi arttıracak bir yöntem olduğu düşünülmüştür. Mevcut hat besleme yöntemlerine ek olarak hat besleme yöntemlerinden biri olarak değerlendirilmiştir.

4.2. Yapay Sinir Ağı Yöntemi Kullanılarak Malzeme Besleme Yöntemi Seçimi

Malzeme besleme yöntemi seçimi için YSA yöntemi kullanılmış olup aşağıdaki adımlar izlenmiştir.

1. Sinirsel ağın tasarımı
2. Sinirsel ağın eğitilmesi
3. Sinirsel ağın test edilmesi

4.2.1. Yapay sinir ağının tasarımı

Ağ tasarımında aşağıdaki adımlar uygulanmıştır;

- Girdi ve çıktı özelliklerinin belirlenmesi
- Eğitim yönteminin seçilmesi
- Ağ topolojisinin seçilmesi
- Gizli tabaka sayısının seçilmesi
- Nöron sayısının seçilmesi
- Aktivasyon fonksiyon seçimi

Malzeme besleme yöntemi seçiminde literatürde farklı girdiler incelenmiş ve uygulama yapılan firmada mevcutta tercih edilen girdiler değerlendirilerek aşağıda belirtilen beş farklı girdi türünün problemin tamamını temsil edeceği düşünülmüştür:

- Tedarik şekli: Pilot montaj hattında kullanılacak malzemelerin bir kısmı fabrika içerisindeki talaşlı imalat makinelerinde üretilirken bir kısmı tedarikçi firmalardan satın alınmaktadır.
- Yıllık talep adeti: Malzemelerin bir yılda ne kadar talebinin olacağı önemlidir. Yıllık talep hacmi yüksek olan ürünlerin taşıma maliyetini azaltmak amacıyla hat yanında bulunması tercih edilebilirken, yıllık talebi az olan ürünlere ihtiyaç olduğunda ambardan tedarik edilmesi hat yanındaki alan kullanımını açısından tercih edilebilir.

- Bitmiş ürün referans sayısı: Montaj hattında üretilen nihai ürün, tipine göre 100-150 alt malzemeden oluşmaktadır. Her malzeme bir veya daha fazla bitmiş ürünün alt malzemesi olabilmektedir.
- Ön montajda kullanım durumu: Nihai ürünler alt malzemelerden oluşabildiği gibi yarı montajlı malzemelerden de oluşabilmektedir. Ön montaj adımı montaj adımından belirli bir süre önce başlamalıdır. Pilot hat ile aynı zaman diliminde malzeme beslenmesi hattaki üretim planına uyumda problem yaratabilir.
- Parça boyutunun kit arabası ile uyumu: Her malzeme farklı boyutlarda olabilmektedir. 0,01 mm'den 1000 mm'ye kadar farklı boyutlarda ürünler montajlanmaktadır. Kit arabasının hacmi, her ürün için uygun tasarlanmadığı için kit arabası ile taşımaya uygun olmayan ürünler değerlendirilmelidir.

Malzeme besleme yöntemi için belirlenen girdilerin özellikleri Çizelge 4.1'de belirtilmiştir.

Çizelge 4.1. Malzeme besleme yöntemi için seçilen girdi parametrelerinin özellikleri

No	Girdi	Aralık/Değer	Açıklama
1	Tedarik şekli	0-1	1: Fabrikada üretiliyor 0: Tedarikçiden satın alınıyor
2	Yıllık talep adeti	1-2-3-4	1: Talep hacmi yüksek 2: Talep hacmi orta 3: Talep hacmi düşük 4: Talep hacmi yok
3	Bitmiş ürün referans sayısı	1-2-3	1: Bitmiş ürün sayısı yüksek 2: Bitmiş ürün sayısı orta 3: Bitmiş ürün sayısı az
4	Ön montajda kullanım durumu	0-1	1: Sadece ilgili hatta kullanılıyor 0: Ön montajda kullanılıyor
5	Parça boyutunun kit arabası ile uyumu	0-1	1: Kit arabasına uygun 0: Kit arabasına uygun değil

Yıllık talep adeti, bitmiş ürün referans sayısı sayısal verilerden oluşurken, tedarik şekli, ön montajda kullanılıp kullanılmadığı ve parça boyutunun kit arabası ile uyumu kriterleri için aralık tanımlanmıştır.

Referans bazlı yıllık talep adeti, toplam talep adetine göre bir analiz yapılarak sayısal ifadeye çevrilmiştir. Yıllık talep adeti için belirlenen değerler aşağıda açıklanmıştır. Talep kriteri için karar verilen aralıklar aşağıda belirtilmiştir:

- 1: Tüm ürünlerin toplam talep hacminin 75% -100 %'ü ise talep hacmi "yüksek"
- 2: Tüm ürünlerin toplam talep hacminin 46% -74%'ü ise talep hacmi "orta"
- 3: Tüm ürünlerin toplam talep hacminin 10%- 45 %'i ise talep hacmi "düşük"
- 4: Tüm ürünlerin toplam talep hacminin 0%- 9%'u ise talep hacmi yok

Bitmiş ürün referans sayısı kriteri için tanımlanan aralıkları aşağıda belirtilmiştir:

- 1: 20' den fazla bitmiş ürün referans sayısı içeriyorsa "yüksek"
- 2: 10'dan fazla bitmiş ürün referans sayısı içeriyorsa "orta"
- 3: 10 ve daha az bitmiş ürün referans sayısı içeriyorsa "düşük"

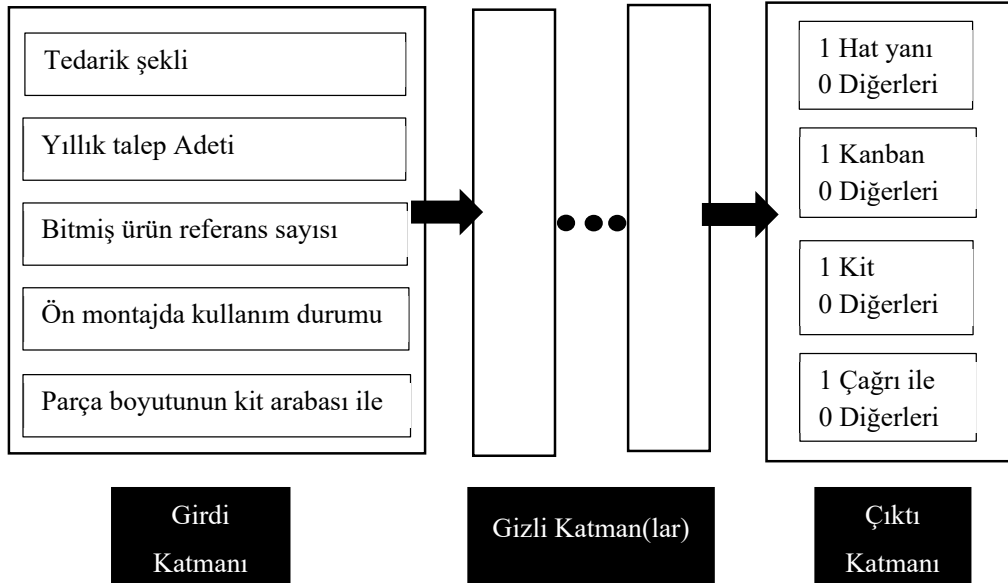
Çıktı için literatürde tanımlanan yöntemlerden fabrikanın ürün hacmine uygun olabilecek dört temel yöntem çıktı olarak seçilmiştir. Dört basamaklı çıktı tanımlanmıştır. Basamakların her biri farklı bir hat besleme seçimini temsil etmektedir. Birinci basamak hat yanından, ikinci basamak kanban, üçüncü basamak kit ve dördüncü basamak çağrı ile ihtiyaca dayalı besleme yöntemini ifade etmektedir. Çıktılar sıfır ya da bir değerini almaktadır. İlgili yöntem seçilecekse 1 seçilmeyecekse 0 şeklindedir.

Malzeme besleme yöntemi için belirlenen çıktıların özellikleri Çizelge 4.2' de belirtilmiştir.

Çizelge 4.2. Malzeme besleme yöntemi için seçilen çıktı özellikleri

No	Değer	Açıklama
1	0-1	İlgili malzemenin besleme yöntemi hat yanından besleme yapılıyorsa 1 değerini alır, aksi halde 0 değerini alır.
2	0-1	İlgili malzemenin besleme yöntemi kanban ile besleme yapılıyorsa 1 değerini alır, aksi halde 0 değerini alır.
3	0-1	İlgili malzemenin besleme yöntemi kit ile besleme yapılıyorsa 1 değerini alır, aksi halde 0 değerini alır.
4	0-1	İlgili malzemenin besleme yöntemi çağrı ile ihtiyaca dayalı besleme yapılıyorsa 1 değerini alır, aksi halde 0 değerini alır.

Malzeme besleme yöntemi seçim çalışması için oluşturulan yapay sinir ağı yapısı Şekil 4.1'deki gibidir.



Şekil 4.1. Malzeme besleme yöntemi seçim çalışması için oluşturulan YSA yapısı

Uygulama yapılan firmada malzemeler için geçmişte uygulanmış hat besleme yöntemi seçim bilgileri toplanarak veri tabanı oluşturulmuştur. Çıktı değerleri bilindiği için eğitici öğrenme yöntemi kullanılmıştır.

Veri tabanındaki girdi ve çıktı deęerleri için eğitim yapılacağı ve geri besleme bağlantısı bulunmadığı için ileri sürümlü ağ yapısı seçilmiştir. Geri yayılma algoritması ile gizli katmandaki ağırlıkların istenen çıktıyı ayarlaması sağlanmıştır. İleri yayılım aşamasında elde edilen hata deęeri dikkate alınarak katmanlar arasındaki ağırlıklar ve yanlılık deęerleri çıktı katmanından başlayarak girdi katmanına doğru güncellenir. Ağırlıklar güncellenerek gerçek çıktı deęeriyle tahmin edilen çıktı deęerinin arasındaki farkın belirlenen hata deęerine ulaşması amaçlanır.

Malzeme besleme yöntemi seçimi için tek gizli katman farklı düęüm sayıları ile başlanarak gizli katman sayısı ve düęüm sayıları artırılarak istenilen hata miktarına ulaşana kadar denemelere devam edilmiştir.

Düęüm sayısı arttıkça ağıın öğrenme için gereken eğitim süresi artmaktadır, bununla birlikte genelleme yapma yeteneęi artar.

4.2.2. Yapay sinir ağıının eğitimi

Yapay sinir ağı eğitim sırasında verilen bilgi çözülmek istenilen problemin tamamını örnekleyecek şekilde seçilmelidir. Az eğitim verisi ile ağıın doğru modellenmesi engellenir. Verilerin tutarlılığı ağıın güvenilirliği için önemlidir. Doğru bir sinirsel ağı modeli için eğitim parametrelerinin belirlenmesi önemlidir (Aksoy, 2005).

Geri yayılma yönteminde, aynı katmandaki farklı düęümler arasında bağlantı yoktur. Katmanlardaki her bir sinir hücresi bir sonraki katmandaki sinirlere ayrı ayrı baęlıdır (Özdemir, 2013).

Geri yayılma algoritmalarından literatürde oldukça sık kullanılan Levenberg- Marquardt (LM) algoritması ile denemelere başlanmıştır. Ölçeklenmiş Eşlenik Azaltma Algoritması (Scaled conjugate gradient, SCG), Bayes Düzenleme Algoritması (Bayesian regularization, BR) ve Momentumlu Eğim Azaltma Algoritması (gradient descent with momentum, GDM) ile denemeler yapılmıştır. Toplamda 1682 adet deneme yapılmıştır. Denemeler sonucunda Ölçeklenmiş Eşlenik Azaltma Algoritması en küçük hata deęerli

sonucu vermiştir. Transfer fonksiyonu olarak tanjant sigmoid ve log-sigmoid ile denemeler sonucunda tanjant sigmoid transfer fonksiyonu seçilmiştir.

Geri yayılma yönteminde; modelin hızı öğrenme oranı, momentum ile kontrol edilebilir (Aksoy, 2005).

- Öğrenme oranı (η): Öğrenme oranı $\{0-1\}$ arasında değerler alan, ağıdaki katmanların ağırlıklarının değişme hızını kontrol eden parametredir. Öğrenme oranı büyüdükçe hız artacağından adım sayısı azalır. 1'e yaklaştıkça öğrenme hızı artar fakat ağı sonuçlarının birbirine yakın sonuç verme olasılığı azalır. Öğrenme oranı 1'e yakınsa bir sonraki öğrenme önemli iken 0'a yakın olduğunda bir önceki öğrenmenin önemi daha yüksektir. Malzeme besleme yöntemi seçiminde 0,1 ve 0,5 arasındaki değerlerinde denemeler yapılmıştır.
- Momentum oranı (α): Hatayı minimize etmek amacıyla iterasyon sayısını kontrol eden parametredir. Dönüm noktalarındaki hatalarda iterasyona son vermeyi engeller. Momentum oranı arttıkça toplam hatayı en küçükleme kabiliyeti arttığından malzeme besleme yöntemi seçiminde 0,9'dan başlayarak 0,5'e kadar değerler verilerek denemeler yapılmıştır.
- Algoritmadan çıkış: Belirlenen adette iterasyon gerçekleştikten sonra belirlenen hata seviyesine ulaşılmadığı takdirde modelin durdurulması için çıkış parametresi belirlenmiştir. Malzeme seçim probleminde uygulanacak maksimum iterasyon sayısı 10000 olarak belirlenmiştir.

Yapay sinir ağı için veri tabanında bulunan 2221 adet verinin %70'i eğitim, %20'si doğrulama, %10'u test için kullanılmıştır. Pilot montaj hattında kullanılan malzemeler için örnek veri tabanı Ek-1'de yer almaktadır.

4.2.3. Yapay sinir ağının test edilmesi

Ağa daha önce gösterilmeyen veri tabanında yer alan 29 adet doğrulama verisi ile ağın eğitiminin başarılı olup olmadığı kontrol edilmiştir. Doğrulama verileri Ek-1'de yer alan verilere benzer yapıdadır.

4.2.4. Yapay sinir ağının performans değerlendirme kriteri

Tasarlanan ağın performansını değerlendirmek amacıyla istatistiksel hata tahmin yöntemleri kullanılmaktadır. Malzeme besleme yöntemi seçim probleminde tasarlanan yapay sinir ağının sonuçlarını değerlendirmek için ortalama karesel hata (Mean Squared Error, MSE) değeri kullanılmıştır. Bu değerler eşitlik 4.2' de verildiği gibi hesaplanmaktadır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.2)$$

Yukarıdaki eşitlikte y_i çıkış değerini, \hat{y}_i ise hedef çıkış değerini göstermektedir.

4.3. Uygulama

Modelin tasarımı ve eğitimi için MATLAB programında Neural Network araç kutusu (nntool) kullanılmıştır. Veri tabanında 2221 adet veri bulunmaktadır. Bu verilerin %70'i öğrenme, %20'si doğrulama, %10' u test için kullanılmıştır. Ek-1'de örnek eğitim verileri yer almaktadır. Ayrıca veri tabanında olmayan geçmiş verilerden 29 adet veri test için kullanılmıştır.

İleri beslemeli ağın eğitimi için geri yayılım algoritmalarından en çok tercih edilen Levenberg- Marquardt (LM) algoritması ile denemelere başlanmıştır. Tek gizli katmandan başlayarak üç gizli katmana kadar denemelere devam edilmiştir. Öğrenme oranı, momentum, gizli katman sayısı ve gizli katmandaki düğüm sayıları için de denemeler yapılmıştır. En iyi sonucu veren iki gizli katmanda karar kılınmıştır. Gizli katmandaki düğüm sayıları artırılarak denemelere devam edilmiştir. LM algoritması ile yapılan denemelerin bir kısmı Ek-2'de yer almaktadır. Toplamda 199 adet deneme yapılmıştır. Yapılan denemelerden elde edilen en iyi sonuçlar Çizelge 4.3'de gösterilmiştir.

Çizelge 4.3. LM algoritması ile yapılan denemelerde elde edilen en iyi sonuçlar

Deneme	Gizli katman sayısı	Gizli katman nöron sayısı	Momentum	Öğrenme oranı	İterasyon sayısı	Hata	Aktivasyon fonksiyonu
50	2	4-3	0,5	0,4	169	0,0056	tansig
55	2	4-5	0,5	0,4	1487	0,0054	tansig
63	2	4-8	0,9	0,1	127	0,0054	tansig
112	2	8-7	0,5	0,4	149	0,0057	tansig
179	2	4-8	0,5	0,4	129	0,0048	tansig
192	2	4-8	0,5	0,4	123	0,0051	tansig

YSA' da ağ ağırlıkları rassal belirlendiği için her iterasyon sonucunda ağ farklı bir çıktı değeri verebilmektedir. Bu nedenle ek bir kod yazılarak aynı ağ yapısının belirlenen tekrar sayısında tekrarlı çalıştırılması sağlanmıştır. Örneğin; iki gizli katman yapısına sahip, gizli katmanlarda sırasıyla dört ve üç düğüm bulunan, 0,6 momentum, 0,4 öğrenme oranına sahip ağ 10 tekrar olacak şekilde çalıştırılmıştır. Her tekrarda ağ yapısı iterasyonlar yaparak belirlenen hata değerine ulaştığında veya iterasyon sınır adeti dolduğunda durmakta ve bulunan hata değeri, ilgili iterasyon sayısı ile kaydedilmektedir. Aynı ağ yapısı için tekrarlanan çalıştırmalarda bulunan hata değerleri ve kaçınca iterasyonda yer aldığı bilgisine istinaden en küçük tekrarlayan hata oranı LM algoritması kullanılarak yakalanmaya çalışılmıştır. Toplamda 728 farklı deneme yapılarak en küçük hata oranı 0,004 olarak bulunmuştur. LM algoritması ile yapılan tekrarlı iterasyon denemelerinin bir kısmı Ek-3'de bulunmaktadır. LM algoritması ile yapılan tekrarlı iterasyonlarda bulunan en iyi değerler Çizelge 4.4'de verilmiştir.

Çizelge 4.4. LM algoritması ile yapılan tekrarlı denemelerde elde edilen en iyi sonuçlar

Deneme	Gizli katman sayısı	Gizli katman nöron sayısı	Momentum	Öğrenme oranı	İterasyon sayısı	Hata
192	2	13-12	0,5	0,4	47	0,0042
551	2	14-12	0,5	0,4	50	0,0044
13	2	15-10	0,5	0,4	35	0,0048
468	2	15-12	0,5	0,4	1350	0,0048
403	2	11-14	0,5	0,4	123	0,0049
390	2	11-14	0,5	0,4	26	0,005
452	2	4-8	0,5	0,4	222	0,005
55	2	9-11	0,5	0,4	102	0,005
143	2	9-7	0,5	0,4	34	0,0051
293	2	11-15	0,5	0,2	106	0,0051

Malzeme besleme yöntemi seçmek için yazılan Matlab bildirimi Şekil 4.2’de verilmiştir.

Tekrarlı iterasyon sayısı için yazılan Matlab kodu Şekil 4.3’de verilmiştir.

```

Editor - C:\Users\mcicha\Desktop\YSA2\neuralnetwork4.m *
find_mse.m  neuralnetwork4.m *  +
2   veriler=xlsread('Kitting_4.xlsx'); % verilerin hangi excelden alındığını gösteriyor.
3   input=veriler(:,1:5); %girdiler 1 ile 5. sutundakiler
4   target=veriler(:,6:9); % çıktılar 6 ile 9. sutundakiler
5   x=input'; % girdiler x ile ifade edilecek
6   t=target'; % çıktılar t ile ifade edilecek
7   trainFcn='trainscg'; %yapay sinir algoritmasındaki transfer fonk tanımlanmakta
8   hiddenLayerSize=[10,12]; % gizli katman sayısı 2 ve düğüm sayıları 10 ve 12
9   net=feedforwardnet(hiddenLayerSize,trainFcn);
10  net.layers{1}.transferFcn= 'tansig'; %1. gizli katman transferfonk
11  net.layers{2}.transferFcn= 'tansig'; %2. gizli katman transferfonk
12  %net.layers{3}.transferFcn= 'tansig';
13  net.input.processFcns={'removeconstantrows', 'mapminmax'}; %normalize ediliyor.
14  net.output.processFcns={'removeconstantrows', 'mapminmax'}; %normalize ediliyor.
15  net.divideFcn='dividerand'; % verileri rastgele bölüyoruz.
16  net.divideMode='sample';
17  net.divideParam.trainRatio=70/100; % 70 i eğitim
18  net.divideParam.valRatio=20/100; % 20 si validasyon
19  net.divideParam.testRatio=10/100; % 10 u test
20  net.trainParam.show=100; %100 er 100 er sonuçları gösterecek
21  net.trainParam.lr=0.4; % öğrenme oranı 0.4
22  net.trainParam.epochs=10000; %100000 iterasyon sonra duracak
23  net.trainParam.goal=0.001; % 0.001 hata değerine ulaşmayı hedefliyor
24  net.trainParam.max_fail=50; % doğrulama kontrol sayısı
25  net.trainParam.mc=0.5; % momentum
26  net.trainParam.min_grad=0; % maksimum performans gradyanı
27  net.PerformFcn='mse'; % hata için mean squared error performans fonksiyonu kullanılacak
28  net.plotFcns={'plotperform', 'plottrainstate', 'ploterrhist'...
29  'plotregression', 'plotfit'}; % grafikler için
30  [net,tr]=train(net,x,t); % x girdi t hedef değişkenleri ile ağız eğitimi yapılıyor,
31  % net ağızdan gelen tahmin değerleri oluşturuluyor, tr eğitim kaydını oluşturuyor.
32  y=net(x); % ağız testini gerçekleştiriyoruz, her girdi değerine göre tahmin yaparak her değer y e eşitleniyor.
33  performance=perform(net,t,y); % gerçek t ve tahmin y değerleri ile net ağızın performans ölçümü yapılıyor

```

Şekil 4.1. Malzeme besleme yöntemi seçimi için oluşturulan Matlab bildirimi


```
Editor - C:\Users\mciha\Desktop\YSA2\find_mse.m
find_mse.m x neuralnetwork4.m x +
1 clear all
2 clc
3
4 n=30; %%iterasyon sayisi
5 out=zeros(n,2);
6 for i=1:n
7     run('neuralnetwork4.m')
8     out(i,1)=tr.best_vperf; %%run icindeki en iyi deger
9     out(i,2)=tr.best_epoch; %%run icindeki en iyi degerin yapay zeka iterasyonu
10 end
11
12 [M,I]=min(out(:,1));
13
14 M; %%maksimum deger
15 I; %%maksimum bulundugu satir(Run)
16 it=out(I,2); %%maksimum degerin yapay zeka iterasyonu
17 Find=["Min",M;"AI Iteration",it;"Row(Run)",I]; %%maksimum deger info matrisi
18 out; %%butun runlar tek sutun
```

Şekil 4.2. Tekrarlı denemeler için oluşturulan Matlab bildirimi

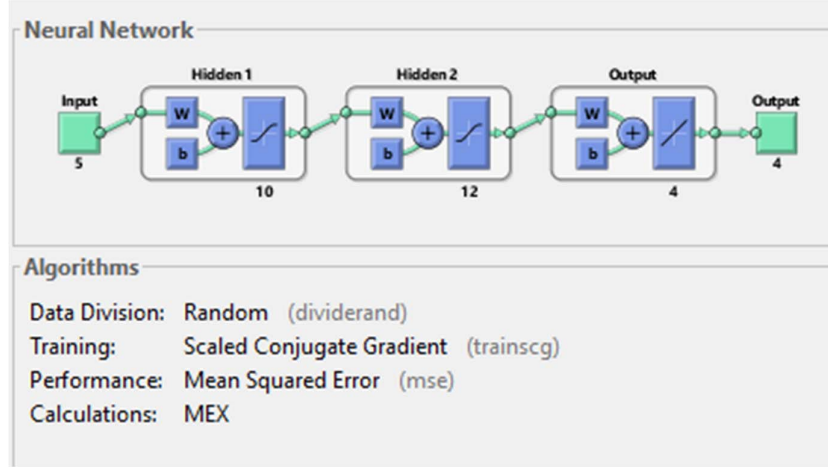
Yapılan iterasyonlarda hedeflenen hata değeri olan 0,001'e ulaşamayınca sırayla Bayes Düzenleme Algoritması (BR), Ölçeklenmiş Eşlenik Azaltma Algoritması (SCG), Momentumlu Eğitim Azaltma Algoritması (GDM) ile tekrarlı çalıştırmalar yapılmıştır. Toplamda 755 farklı deneme yapılmıştır. BR, SCG, GDM Algoritmaları ile yapılan tekrarlı iterasyon denemelerinin bir kısmı Ek-4'de bulunmaktadır. Tekrarlı çalıştırmada bulunan en iyi sonuçlar Çizelge 4.5'de verilmiştir.

Çizelge 4.5. BR, SCG, GDM algoritmaları ile yapılan tekrarlı çalıştırmalarda elde edilen en iyi sonuçlar

Deneme	Gizli katman nöron sayısı	Momentum	Öğrenme oranı	İterasyon sayısı	Hata	Eğitim Algoritması
195	13-12	0,5	0,4	1122	0,0032	SCG
754	10-12	0,5	0,4	485	0,0032	SCG
196	13-12	0,5	0,4	1292	0,0033	SCG
525	12-12	0,5	0,4	386	0,0036	SCG
61	13-12	0,5	0,4	108	0,0040	BR
532	12-12	0,5	0,4	242	0,0047	SCG
467	11-14	0,5	0,4	449	0,0047	SCG
33	16-13	0,5	0,4	31	0,0050	BR
158	13-12	0,5	0,4	10000	0,0054	GDM
97	13-12	0,5	0,4	85	0,0058	BR
53	13-12	0,5	0,4	85	0,0058	BR
190	13-12	0,5	0,4	10000	0,0067	GDM
151	13-12	0,5	0,4	10000	0,0068	GDM
164	13-12	0,5	0,4	10000	0,0077	GDM

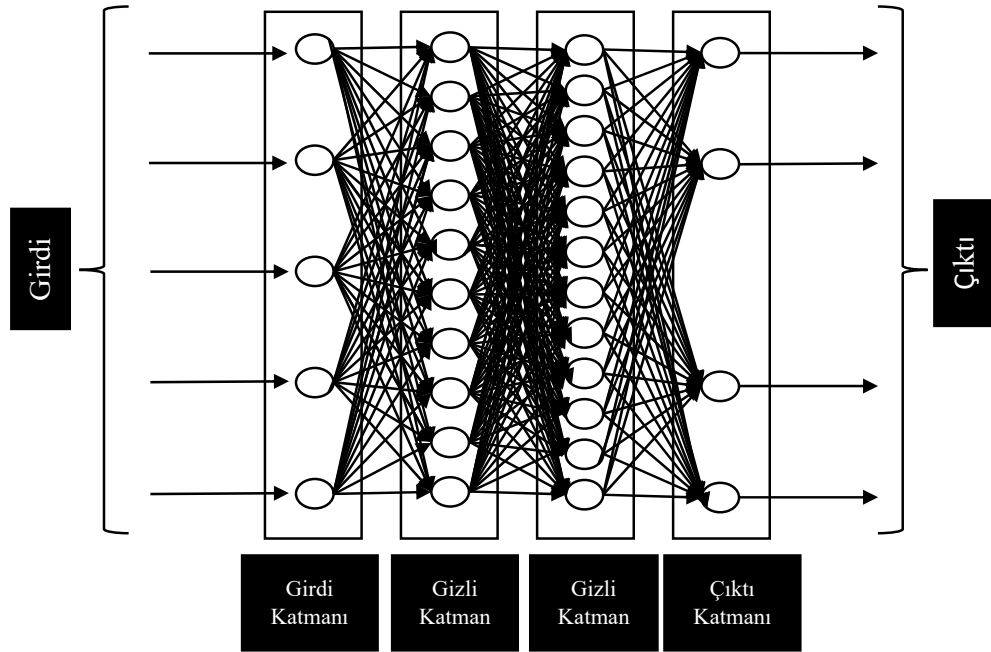
En küçük hatayı veren Ölçeklenmiş Eşlenik Azaltma Algoritması (SCG), seçilmiştir. Gizli katmanlarda “tansig” aktivasyon fonksiyonu kullanılmıştır. Tekrarlı iterasyonlarda en küçük 0,003 hata değerine ulaşılmıştır.

Yapılan denemelerde öğrenme oranı 0,4; momentum 0,5; gizli katman sayısı iki ve gizli katmanlarda sırasıyla 10 ve 12 adet düğüm bulunan ağ yapısı istenen sonuca en yakın sonucu vermiştir. Elde edilen yapının Matlab görüntüsü Şekil 4.4’de verilmiştir.



Şekil 4.3. Malzeme besleme yöntemi seçimi için oluşturulan Matlab ağ yapısı

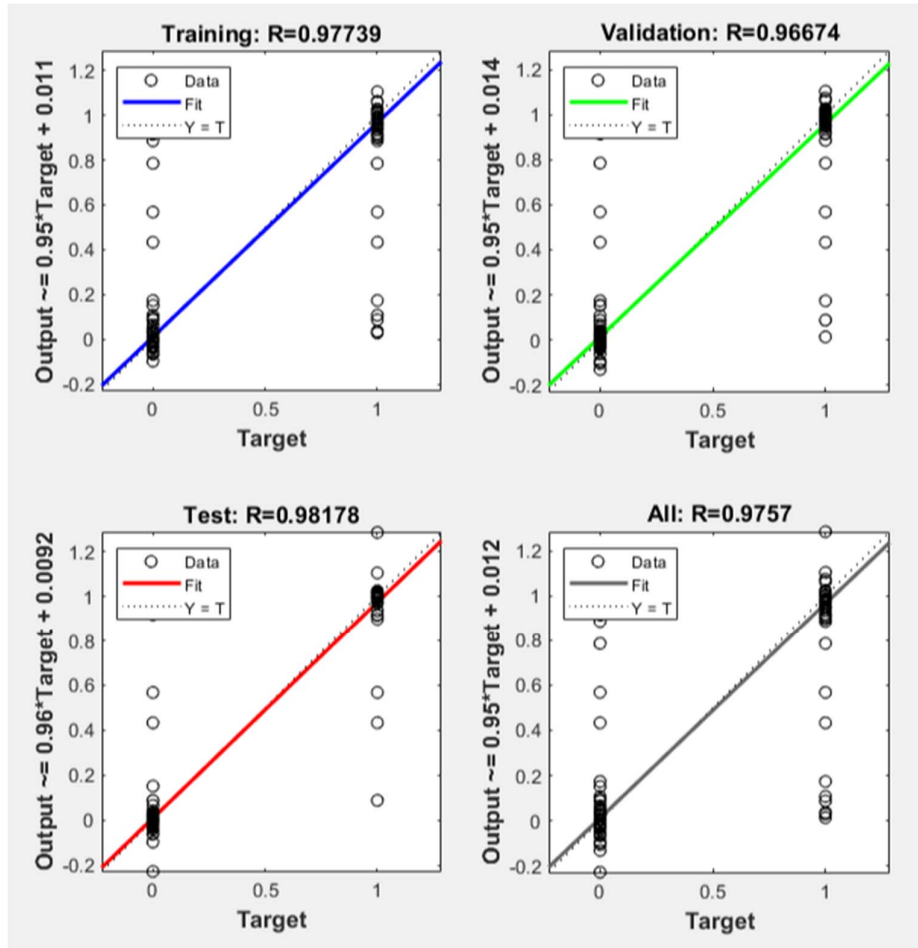
En iyi çözümü veren ağın ağ yapısı Şekil 4.5’de verilmiştir.



Şekil 4.4. Malzeme besleme yöntemi seçimi için oluşturulan ağ yapısı

Ağın verileri ezberleyip ezberlemediğini anlamak amacıyla doğrulama verisi kullanılmıştır. Doğrulama verisi ağa daha önce gösterilmeyen verilerden oluşmaktadır. Doğrulama verilerinin sonucunda ağın verdiği hata aynıdır.

Yapılan denemeler sonucunda iki gizli katmanı olan gizli katmanlarda 10 ve 12 adet düğüm bulunan ileri beslemeli geri yayılım algoritmali ağ yapısı problem için uygun çözüm olarak seçilmiştir. Seçilen ağın performansının gösterildiği eğitim, doğrulama, test ve tüm veriler için korelasyon katsayısı grafikleri Şekil 4.6'da verilmiştir. Korelasyon katsayısı (R) değerleri eğitim (Training) verileri için 0,97739; doğrulama (Validation) verileri için 0,996674; test (Test) verileri için 0,98178 ve tüm (All) veriler için 0,9757 olarak bulunmuştur. Yapılan denemeler sonucunda elde edilen değerler ile gerçek değerler arasında farkın kabul edilebilir olduğu belirlenmiştir.



Şekil 4.5. Seçilen ağ için eğitim, doğrulama, test ve tüm veriler için korelasyon katsayısı grafikleri

Uygulama aşamasında ađın eđitim ve dođrulama sırasında grmediđi test verileri ile ađ test edilmiřtir. 29 adet test verisi iin gerek ıktı deđerleri ve ađın rettiđi ıktı deđerleri karřılařtırılmıř olup fark grlmemiřtir. 29 adet test verisinin gerek ve ađın rettiđi ıktı deđerleri izelge 4.6'da verilmiřtir.

izelge 4.6. 29 adet test verisinin gerek ıktı deđerleri ve ađın rettiđi ıktı deđerleri

rnek No	GEREK IKTI DEđerİ				AđIN RETTİđİ IKTI DEđerİ				Sonu
	1	2	3	4	1	2	3	4	
1	0	1	0	0	0,0221	1,0255	-0,0066	-0,0435	Kanban
2	0	1	0	0	0,0008	0,9365	0,0040	-0,0177	Kanban
3	0	1	0	0	0,0294	0,9666	-0,0072	0,0110	Kanban
4	0	0	0	1	-0,0238	0,0537	-0,0185	0,9834	ađrı ile ihtiyaca dayalı
5	1	0	0	0	0,9841	0,0142	-0,0023	-0,0005	Hat yanı
6	0	0	0	1	-0,0372	-0,0338	-0,0365	1,0930	ađrı ile ihtiyaca dayalı
7	0	0	0	1	-0,0175	-0,0046	0,0855	0,9175	ađrı ile ihtiyaca dayalı
8	0	1	0	0	0,0071	1,0256	-0,0157	-0,0085	Kanban
9	0	0	1	0	-0,0167	0,0245	0,9811	0,0076	Kit
10	0	0	0	1	0,0533	-0,0390	-0,0168	1,0056	ađrı ile ihtiyaca dayalı
11	0	0	0	1	-0,0433	0,0450	0,0055	1,0083	ađrı ile ihtiyaca dayalı
12	0	1	0	0	-0,0002	0,9919	0,0181	-0,0032	Kanban
13	0	1	0	0	-0,0028	1,0101	-0,0008	-0,0092	Kanban
14	0	1	0	0	-0,0017	1,0228	-0,0019	-0,0220	Kanban
15	0	0	1	0	0,0128	-0,0042	0,9807	0,0090	Kit
16	1	0	0	0	0,8804	0,0542	0,0181	0,0441	Hat yanı
17	0	1	0	0	0,0057	1,0159	-0,0135	-0,0049	Kanban
18	0	1	0	0	-0,0018	0,9958	-0,0003	0,0044	Kanban
19	0	1	0	0	-0,0227	0,9981	-0,0097	0,0358	Kanban
20	0	0	0	1	-0,0063	-0,0341	0,0169	1,0309	ađrı ile ihtiyaca dayalı
21	0	0	0	1	-0,0031	-0,0408	-0,0011	1,0428	ađrı ile ihtiyaca dayalı
22	0	0	1	0	0,0065	-0,0069	1,0254	-0,0269	Kit
23	0	0	1	0	0,0008	-0,0038	1,0279	-0,0263	Kit
24	0	0	0	1	0,0073	0,0615	-0,0098	0,9364	ađrı ile ihtiyaca dayalı
25	1	0	0	0	1,0412	-0,0086	-0,0077	-0,0237	Hat yanı
26	0	1	0	0	-0,0024	1,0024	-0,0002	0,0056	Kanban
27	1	0	0	0	0,9562	0,0062	0,0065	0,0311	Hat yanı
28	1	0	0	0	0,8731	-0,0014	-0,0008	0,1230	Hat yanı
29	0	0	0	1	0,0136	0,0048	0,0065	0,9807	ađrı ile ihtiyaca dayalı

Üç farklı örnek için test sonuçları Matlab ekran görüntüsü Şekil 4.7’de görülmektedir. Örnek 1’de malzeme besleme yöntemi seçilmek istenen malzemenin özellikleri; tedarik şekli fabrikada üretiliyorsa, yıllık talep hacmi yok ise, bitmiş ürün referans sayısı az ise, ön montajda kullanılıyorsa ve kit arabasına uygun değil ise sonuç için tanımlanan basamaklardan 1’e en yakın değer alan dördüncü besleme yöntemi olan çağrı ile ihtiyaca dayalı yöntem seçilmektedir. Örnek 2’de ilgili malzeme fabrikada üretiliyorsa, talep hacmi yoksa, bitmiş ürün referans sayısı yüksekse, sadece ilgili montaj hattında kullanılıyorsa ve kit arabasına uygun ise sonuç basamaklarından 1’e en yakın değer alan birinci besleme yöntemi olan hat yanı besleme yöntemi seçilmektedir. Örnek 3’de ilgili malzeme, fabrika içerisinde üretiliyorsa, talep hacmi yüksekse, bitmiş ürün sayısı az ise, sadece ilgili hatta kullanılıyorsa ve kit arabasına uygun değilse sonuç basamaklarından 1’e en yakın değer alan ikinci besleme yöntemi olan kanban seçilmektedir.

```
Command Window
>> input=[1;4;3;0;0];
>> a=sim(net,input)

a =

    -0.0023
     0.0088
    -0.0068
     0.9925

>> input=[1;4;1;0;1];
>> a=sim(net,input)

a =

     0.8975
     0.0025
    -0.0005
     0.1049

>> input=[1;1;3;1;0];
>> a=sim(net,input)

a =

    -0.0146
     0.9882
     0.0030
     0.0242
```

Şekil 4.7. Malzeme yöntemi seçim probleminde örnekler için elde edilen Matlab bildirimi

Geliştirilen çözüm yaklaşımı ile, uygulama yapılan montaj hattında 513 adet farklı tip malzemenin hat yanında stoklanması, 751 adet farklı tip malzeme için kanban uygulanması, 461 adet farklı tip malzeme için kit uygulanması, 496 adet farklı tip malzeme çağrı ile ihtiyaca dayalı besleme yapılması önerilmektedir. Mevcut durumda 103 farklı tip malzeme iki kutu sistemi ile kanban prensibinde yönetilirken 1047 farklı tip malzeme hat yanında stoklanmaktadır, ayrıca 1071 farklı tip malzeme montaj hattında ilgili malzemeye ihtiyaç duyulduğunda çağrı ile merkezi depodan tedarik edilmektedir. Önerilen çözüm yaklaşımı ile hat yanında bulunacak malzeme tipi sayısında yaklaşık %48,9 azalma (1047 tipten 513 tipe inecektir) sağlanırken bu durum hat yanında alan kazancı da sağlayacaktır. Kanban sistemi ile ek bir planlama yönetim ihtiyacı olmadan tedarigi sağlanacak malzeme sayısında artış olacak, 461 adet malzeme montaj hattına hazır geleceği için montaj operatörünün katma değersiz işlerinde azalma olacaktır.

5. SONUÇ

Günümüzde işletmeler rekabet koşullarında tercih edilmeleri için sürekli gelişmeleri gerekmektedir. Rekabet edebilmeleri için kaliteyi artırarak maliyet ve teslimat süresini azaltarak verimliliklerini arttırmaları önemli rol oynamaktadır. Parça besleme sistemleri verimliliği etkileyen önemli parametrelerdendir. İşletmelerde uygun parça besleme sistemleri seçildiğinde katma değersiz işlerde ve kalite problemlerinde azalış, ürün çıktısında artış, ergonomik koşullarda iyileşme, müşteriye hızlı cevap verme potansiyelinde gelişme gözlenir.

Literatürde yer alan çalışmalarda hat yanı, kanban, kitleme, çağrı ile ihtiyacı dayalı, tam zamanında, melez yaklaşımlar ile besleme gibi birçok malzeme besleme yönteminden bahsedilmiştir.

Kanban, minimum maksimum stoğu tanımlı çekme prensibine dayalı bir malzeme besleme sistematiğidir. Ek bir planlama ihtiyacına gerek duymaz. İstenen adetteki stoğun tanımlı yerde mevcut olduğunu kabul eder.

Hat yanı besleme yöntemi, malzemelerin montaj hattı yanında ulaşılabilir olması ve herhangi bir problemde malzemeye kolayca ulaşabilme yönünden avantajlı olmakla birlikte hat yanında alan kaplaması ve malzeme arama bulma için geçirilen sürenin katma değersiz olması nedeniyle dezavantajlıdır.

Çağrı ile ihtiyaca dayalı besleme yönteminde, malzemeler montaj hattında kullanılacağı zaman merkezi bir depodan talep edilmekte, talep edilen malzemeler kutu içinde gelerek içerisinden ihtiyaç kadar malzeme tüketilmekte ve kalan malzeme montaja tekrar teslim edilmektedir. Montaj hattı yanında alan kaplamamasına rağmen malzeme hareketi nedeniyle verimsizliğe neden olmaktadır.

Kitleme; montaj hattı için gerekli olan malzemelerin belirlenen adette, tanımlı bir kasaya konularak belirlenen zamanda, belirlenen yere teslimatını sağlayan bir malzeme besleme

yöntemidir. Ürün çeşitliliğinin çok, ürün talep hacminin düşük olduğu işletmelerde avantajlı bir yöntemdir. Malzeme ara stoklarını azaltarak, parça aramak için harcanan süreyi azaltır. Katma değersiz faaliyetleri azaltarak verimliliği artırır. Tanımlı ve görsel bir yönetim sunarak eksik veya yanlış montajı engellemeye yardımcı olur. Kitleme hazırlama süresi ve işçilik gereksinimi yöntemin dezavantajıdır. İşletmelerde doğru uygulanmadığında veya tedarik zinciri boyunca kitleme sistemi yeterli olgunluğa sahip olmadığında montaj hattı duruşuna sebep olabilmektedir.

Yapılan tez çalışmasında, hidrolik motor üreten ürün çeşitliliği yüksek, ürün talep hacmi düşük olan bir firmada uygulama yapılmıştır. Firmaya uygun olabilecek melez yaklaşımlar araştırılmış olup kanban, hat yanı besleme, çağrı ile ihtiyaca dayalı ve kitleme yöntemleri incelenmiştir.

Firmaya yeni gelecek makine ve montaj hatları için alan ihtiyacına gerek olmakla birlikte montaj operatörlerinin verimlilikleri artırılarak çıktı sayısının artırılması talep edilmektedir. Ayrıca fabrikadaki farklı değer akışlarındaki montaj hatları için kolay uygulanabilir, karar verme süresi kısa bir malzeme besleme sistemi ihtiyacı bulunmaktadır.

Yapay sinir ağları, paralel çalışabilen, farklı değişken sayılarında etkin olabilen ve eksik verilere rağmen genelleme yapabilme yeteneğine sahip yapay zeka tabanlı çözüm yaklaşımlarındandır. Bu nedenle problemin çözümünde YSA tercih edilmiştir. Çalışma kapsamında uygulama yapılan montaj hattında malzemeler için uygun malzeme besleme yöntemi seçilmesi amaçlanmıştır. Malzemelerin tedarik şekli, yıllık talep adeti, bitmiş ürün referans sayısı, ön montajda kullanılıp kullanılmadığı, parça boyutunun kit arabası ile uyumu girdi parametrelerini oluştururken, hat yanı besleme, kitleme, çağrı ile ihtiyaca dayalı ve kanban ile malzeme besleme yöntemleri çıktıyı oluşturmaktadır. Probleme uygun ağ yapısının belirlenmesi için farklı aktivasyon fonksiyonları, eğitim algoritmaları, gizli katman sayıları, gizli katmanlardaki düğüm sayıları, momentum değerleri, öğrenme oranları için toplamda 1682 farklı deneme Matlab programında yapılmıştır. Denemeler sonucunda iki gizli katmana sahip birinci gizli katmanda 10, ikinci gizli katmanda 12

düğüm bulunan 0,4 öğrenme oranına sahip, 0,5 momentuma sahip ağ istenen hata değerine en yakın hata değeri ile en uygun sonucu vermiştir.

Geliştirilen çözüm yaklaşımı ile, uygulama yapılan montaj 513 adet farklı tip malzeme hat yanında stoklanması, 751 adet farklı tip malzeme kanban uygulanması, 461 adet farklı tip malzeme için kit uygulanması, 496 adet farklı tip malzeme çağrı ile ihtiyaca dayalı besleme yapılması önerilmektedir. Hat yanında bulunacak malzeme sayısı 1047 tipten 513 tipe inmiştir. Hat yanında bulunacak malzeme tip sayısı yaklaşık %48,9 azalırken ürünlerin hacimleri ve saklandığı kutular göz önünde bulundurulduğunda 100 m² üretim alanında kazanç hesaplanmıştır, merkezi depoda 50 m² yer ek olarak harcanması gerekmiştir. Toplam fabrikadaki stok alanı ihtiyacında azalma olmuştur. Malzeme arama için gereken zaman azalmıştır, katma değersiz işler azaltılarak personel verimliliği artmıştır. Tip dönme süresi kısılması kaynaklı %3'lük bir verimlilik artışı hesaplanmıştır. Bununla birlikte montaj hattı çıktı sayısında artış olmuştur. Kanban sistemi ile ek bir planlama yönetim ihtiyacı olmadan tedarigi sağlanacak malzeme sayısında artış olmuştur. Kitleme, firmanın mevcutta kullanmadığı bir yöntem olmakla birlikte firmanın pilot alandaki montaj hattında kullanılan 2221 adet malzemesinden 461'i için kitleme uygulaması önerilmiştir. Belirtilen ürünlerin montaj hattına kit ile beslenmesi durumunda ürünlerin zamanında sevk edilme potansiyeli artacak, ara stok miktarı azalacak, parçaların bulunurluğu artırılarak envanter sayımında ve üretim planlamada kolaylık sağlanacaktır. Mevcut durumda envanter sayımı için iki gün planlanarak günde 48 personel çalışmakta iken, önerilen yöntemle envanter sayımı tek güne indirilebilecektir. Parçaların gereken adetten fazla gelmesi ile tekrar kullanılmayan malzeme kutusunun ambara teslim işleminden doğan gereksiz taşımalar ortadan kaldırılacaktır.

Bu çalışma ile doğru hat besleme yöntemi karar probleminin insana bağımlılığı azaltılarak, süreç sistematik değerlendirmeye uygun hale getirilmiştir. Uygulama yapılan fabrika kitleme yöntemi ile malzeme beslemenin avantajlarını üretim yönetimi açısından kazanmıştır. Gelecek çalışmalarda farklı değerlendirme parametreleri eklenerek, örneğin toplam iş gücü ile maliyet, karar değerlendirme sürecinin kapsamı genişletilebilir.

KAYNAKLAR

- Aksoy, A. (2005). *Tam zamanında üretim ortamında tedarikçi seçimi ve değerlendirmesi* [Yayınlanmamış yüksek lisans tezi]. Uludağ Üniversitesi. <https://acikerisim.uludag.edu.tr/handle/11452/5815>
- Amasyalı, M. (2015). Yapay sinir ağlarında parçalı eğitim. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 8(1), 25-34. <https://dergipark.org.tr/tr/download/article-file/398998>
- Arı, A., ve Berberler, M. E. (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *Acta Infologica*, 2(1) 55-73. <https://dergipark.org.tr/tr/pub/acin/issue/33868/335553>
- Baller, R., Hage, S., Fontaine, P., ve Spinler, S. (2020). The assembly line feeding problem: An extended formulation with multiple line feeding policies and a case study. *International Journal of Production Economics*, 222. <https://doi.org/10.1016/j.ijpe.2019.09.010>
- Ballı, M.T. (2014). Yapay sinir ağları ile talep tahmini ve gıda sektöründe uygulanması. (Tez No. 378374) [Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi]. YÖK Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>
- Battini, D., Faccio, M., Persona, A., ve Sgarbossa, F. (2009). Design of the optimal feeding policy in assembly system. *International Journal of Production Economics*, 121(1), 233-254. <https://doi.org/10.1016/j.ijpe.2009.05.016>
- Bayır, F. (2006). *Yapay sinir ağları ve tahmin modellemesi üzerine bir uygulama* (Tez No. 215542) [Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi]. YÖK Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>
- Bozer, Y., ve McGinnis, L. (1992). Kitting versus line stocking: A conceptual framework and a descriptive model. *International Journal of Production Economics*, 28(1), 1-19. [https://doi.org/10.1016/0925-5273\(92\)90109-K](https://doi.org/10.1016/0925-5273(92)90109-K)
- Brynzer, H., ve Johansson, M. (1995). Design and performance of kitting and order picking systems. *International Journal of Production Economics*, 41(1-3), 115-125. [https://doi.org/10.1016/0925-5273\(95\)00083-6](https://doi.org/10.1016/0925-5273(95)00083-6)
- Can, S.N., ve Şahin, A.Ş. (2021). Yapay sinir ağları metodu ile günlük çığ noktası sıcaklığı tahmini. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 11(4), 1154-1163. <https://dergipark.org.tr/en/download/article-file/1536986>
- Caputo, A.C., ve Pelagagge, P.M. (2008). Effects of product design on assembly lines performances: A concurrent engineering approach. *Industrial Management & Data Systems*, 108(6), 726-749. <https://doi.org/10.1108/02635570810883987>
- Caputo, A.C., ve Pelagagge, P.M. (2011). A methodology for selecting assembly systems feeding policy. *Industrial Management & Data Systems*, 111(1), 84-112. <https://doi.org/10.1108/02635571111099749>
- Caputo, A.C., Pelagagge, P.M., ve Salini, P. (2015). A decision model for selecting parts feeding policies in assembly lines. *Industrial Management & Data Systems*, 155(6), 974-1003. <https://doi.org/10.1108/IMDS-02-2015-0054>

- Caputo, A.C., Pelagagge, P.M., ve Salini, P. (2018). Selection of assembly lines feeding policies based on parts features and scenario conditions. *International Journal of Production Research*, 56(3), 1208-1232. <https://doi.org/10.1080/00207543.2017.1407882>
- Choobineh, F., ve Mohebbi, E. (2004). Material planning for production kits under uncertainty. *Production Planning and Control*, 15(1), 63-70. <https://doi.org/10.1080/09537280310001659164>
- Choy, K.L., Lee, W.B., ve Lo, V. (2003). Design of an intelligent supplier relationship management system: A hybrid case based neural network approach. *Expert Systems with Applications*, 24, 225-237. <https://isiarticles.com/bundles/Article/pre/pdf/19107.pdf>
- Çelik, B. (2008). *Yapay sinir ağları metodolojisi ile zaman serileri analizi: teori ve uygulama* (Tez No. 227201) [Yüksek Lisans Tezi, Marmara Üniversitesi]. YÖK Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>
- Çevikcan, E., Sol, E., Satoğlu, Ş.I., ve Durmuşoğlu, M.B. (2018). Fabrika içi lojistik süreçlerinin set yapma esaslı tasarımı ve bir uygulama. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 23(4), 83-98. <https://doi.org/10.17482/uumfd.456038>
- Çorakçı, M. A. (2008). *An evaluation of kitting systems in lean production* [Yayınlanmamış yüksek lisans tezi]. University of Boras. <https://www.diva-portal.org/smash/get/diva2:1311122/FULLTEXT01.pdf>
- Çörekçiöğlü, M., Ercan, E., ve Elibüyük, S. A. (2021). Yapay sinir ağı yöntemlerinin tekstil sektöründe kullanım uygulamaları. *Teknik Bilimler Dergisi*, 11(2), 14-20. <https://doi.org/10.35354/tbed.884531>
- Dongare, A.D., Kharde, R.R., ve Kachere, A.D. (2012). Introduction to artificial neural network. *International Journal of Engineering and Innovative Technology*, 2(1), 189-194. <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.1082.1323&rep=rep1&type=pdf>
- Efe, M.Ö., Abadoğlu, E., ve Kaynak, O. (1999). A novel analysis and design of a neural network assisted nonlinear controller for a bioreactor. *International Journal of Robust and Nonlinear Control*, 9(11), 799-815. [https://doi.org/10.1002/\(SICI\)1099-1239\(199909\)9:11<799::AID-RNC441>3.0.CO;2-U](https://doi.org/10.1002/(SICI)1099-1239(199909)9:11<799::AID-RNC441>3.0.CO;2-U)
- Ergezer, H., Dikmen, M., ve Özdemir, E. (2003). Yapay sinir ağları ve tanıma sistemleri. *Pıvolka (Başkent Üniversitesi İktisadi ve İdari Bilimler Fakültesi)*, 6, 14-17. <http://uibf.erciyes.edu.tr/kutuphane/petas/petas.php?skip=0&keyword=HAL%C4%B0T+ERGEZER++MEHMET+D%C4%B0KMEN++ERKAN+%C3%96ZDEM%C4%B0R&type=5>
- Faccio, M., Gamberi, M., Persona, A., Regattieri, A., ve Sgarbossa, F. (2013). Design and simulation of assembly line feeding system in the automotive sector using supermarket, kanbans and tow trains: a general framework. *Journal of Management Control*, 24, 187-208. <https://doi.org/10.1007/s00187-013-0175-1>

- Faccio, M. (2014). The impact of production mix variations and models varieties on the parts-feeding policy selection in a jit assembly system. *The International Journal of Advanced Manufacturing Technology*, 72(1-4), 543-560. <https://doi.org/10.1007/s00170-014-5675-0>
- Gürbüz, F. B. (2020, Mayıs 19). Kohonen ağı (kohonen network) (kn). *Medium*. <https://medium.com/@batincangurbuz/kohonen-a%C4%9F%C4%B1-kohonen-network-kn-c7a3ab2637bc>
- Hagan, M.T., Demuth, H.B., Beale, M.H., ve Jesus, O.D. (1996). *Neural network design* (2.baskı), MA: PWS Publishing. <https://hagan.okstate.edu/NNDesign.pdf>
- Hanson, R., ve Brolin, A. (2013). A comparison of kitting and continuous supply in in-plant materials supply. *International Journal of Production Research*, 51(4), 979-992. <https://doi.org/10.1080/00207543.2012.657806>
- Hanson, R., Medbo, L., ve Medbo, P. (2012). Assembly station design: a quantitative comparison of the effects of kitting and continuous supply. *Journal of Manufacturing Technology Management*, 23(3), 315-327. <https://doi.org/10.1108/17410381211217399>
- Hua, S., ve Johnson, D. (2010). Research issues on factors influencing the choice of kitting versus line stocking. *International Journal of Production Research*, 48(3), 779-800. <https://doi.org/10.1080/00207540802456802>
- Kilic, H.S., ve Durmusoglu, M.B. (2015). Advances in assembly line parts feeding policies: a literature review. *Assembly Automation*, 35(1), 57-68. <https://doi.org/10.1108/AA-05-2014-047>
- Koçan, A. (2014). *İç lojistikte setleme/sıralama sisteminin tasarımı ve otomotiv sektöründe bir uygulama* (Tez No. 353753) [Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi]. YÖK Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezDetay.jsp?id=hH-S-2mhPBVoVTyHZIf14w&no=WZpVxplwHKY6nyt8RURTzA>
- Koyuncu, İ., ve Tuna, M. (2016, Ekim 20-23). *Gömülü yapay sinir ağı uygulamaları için FPGA üzerinde elliott-2 tabanlı tanjant sigmoid transfer fonksiyonunun gerçekleştirilmesi* [Konferans sunumu]. Uluslararası Bilgisayar Bilimleri ve Mühendisliği Konferansı, Tekirdağ, Türkiye. https://www.researchgate.net/publication/334095492_Implementation_of_Elliott_2_Based_Tangent_Sigmoid_Transfer_Function_For_Embedded_Artificial_Neural_Network_Applications_on_FPGA
- Kumar, C. S., ve Pannerselvam, R. (2007). Literature review of JIT-Kanban system. *The International Journal of Advanced Manufacturing Technology*, 32, 393-408. <https://doi.org/10.1007/s00170-005-0340-2>
- Limere, V., Landeghem, H.V., Goetshalckx, M., Aghezzaf, E., ve McGinnis, L. (2012). Optimising part feeding in the automotive assembly industry: deciding between kitting and line stocking. *International Journal of Production Research*, 50, 4046-4060. <https://doi.org/10.1080/00207543.2011.588625>

- Limere, V., Landeghem, H.V., ve Goetshalckx, M. (2015). A decision model for kitting and line stocking with variable operator walking distances. *Assembly Automation*, 35 (1), 47–56. <https://lib.ugent.be/en/catalog/pug01:5919707#reference-details>
- Mamizadeh, S., ve Aslan, Z. (2019). Yapay sinir ağı ile yüzey sıcaklık ve albedo modellemesi. *Aurum Mühendislik Sistemleri ve Mimarlık Dergisi*, 3(2), 227-241. <https://www.idealonline.com.tr/IdealOnline/pdfViewer/index.xhtml?uId=109051&ioM=Paper&preview=true&isViewer=true#pagemode=bookmarks>
- Okkan, U., Serbeş, Z.A., ve Gedik, N. (2018). MATLAB ile Levenberg-Marquardt algoritması tabanlı YSA uygulaması: Aylık yağış-akış modellemesi. *Dicle Üniversitesi Mühendislik Fakültesi Dergisi*, 9(1), 351-362. <https://dergipark.org.tr/tr/pub/dumf/issue/36316/412696>
- Özdemir, H. (2013). Yapay sinir ağı ve dokuma teknolojisinde kullanımı. *Tekstil Teknolojileri Elektronik Dergisi*, 7(1), 51-68. <https://silo.tips/download/yapay-sinir-alar-ve-dokuma-teknolojisinde-kullanm-artificial-neural-networks-and>
- Öztemel, P. D. (2012). *Yapay sinir ağı*. Papatya Yayıncılık. http://www.papatya.gen.tr/PDF/yapay_sinir_aglari.pdf
- Sali, M., Sahin, E., ve Patchong, A. (2015). An empirical assessment of the performances of three line feeding modes used in the automotive sector: line stocking vs. kitting vs. sequencing. *International Journal of Production Research*, 53(1),1439–1459. <https://doi.org/10.1080/00207543.2014.944630>
- Sevinçtekin, E. (2014). *İmalat sektöründe yapay sinir ağı uygulaması* (Tez No. 364178) [Yüksek lisans tezi, Yıldız Teknik Üniversitesi]. YÖK Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>
- Taşoğlu, E. (2020). *Devrek ilçesi'nin (Zonguldak) yapay sinir ağı ile heyelan duyarlılık değerlendirmesi*. (Tez No. 643626) [Yüksek lisans tezi, Karabük Üniversitesi]. YÖK Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>
- Wänström, C., ve Medbo, L. (2008). The impact of materials feeding design on assembly process performance. *Journal of Manufacturing Technology Management*, 20(1), 30-51. <https://doi.org/10.1108/17410380910925398>
- Yaqub, M., Eren, B., ve Eyüpoğlu, V. (2016) Assessment of neural network training algorithms for the prediction of polymeric inclusion membranes efficiency. *Sakarya Üniversitesi Fen Bilimleri Dergisi*, 20(3), 533-542. https://www.researchgate.net/publication/307867894_Assessment_of_Neural_Network_training_algorithms_for_the_prediction_of_Polymeric_Inclusion_Membranes_Efficiency
- Zammori, F., Braglia, M., ve Castellano, D. (2015). Just-in-time parts feeding policies for paced assembly lines: Possible solutions for highly constrained layouts. *International Transactions In Operational Research*, 23(4), 691-724. <https://doi.org/10.1111/itor.12173>
- Zennaro, I., Finco, S., Battini, D., ve Calzavara M. (2020). A parts feeding model for big size products: the active and idle assembly islands strategy. *International Journal of Advanced Operations Management*, 12(3), 211-236. <https://www.inderscience.com/info/inarticle.php?artid=109798>

EKLER

- EK 1** Pilot montaj hattında kullanılan malzemeler için örnek eğitim verileri
- EK 2** LM algoritması ile yapılan denemelerin bir kısmı
- EK 3** LM algoritması ile yapılan tekrarlı denemelerin bir kısmı
- EK 4** BR, SCG, GDM Algoritmaları ile yapılan tekrarlı denemelerin bir kısmı

EK 1 Pilot montaj hattında kullanılan malzemeler için örnek eğitim verileri

Malzeme No	Tedarik şekli	Yıllık talep adeti	Bitmiş ürün referansı sayısı	Ön montajda kullanım durumu	Parça boyutunun kit arabası ile uyumu	Besleme yöntemi
1	1	4	1	0	1	hat yanı
2	1	3	1	1	1	hat yanı
3	1	1	1	1	1	kanban
4	1	4	1	0	1	hat yanı
5	1	1	3	1	1	hat yanı
6	1	4	1	0	0	hat yanı
7	1	3	1	1	1	hat yanı
8	1	4	3	0	0	hat yanı
9	1	3	1	0	1	hat yanı
10	1	3	1	1	1	hat yanı
11	1	1	3	1	1	hat yanı
12	1	3	3	0	1	hat yanı
13	1	3	3	0	1	hat yanı
17	1	1	3	1	1	hat yanı
18	1	1	1	0	1	kanban
19	1	4	3	1	1	hat yanı
20	1	1	1	0	1	kanban
21	1	3	1	1	1	hat yanı
22	1	1	1	1	1	kanban
23	1	4	3	1	1	hat yanı
24	1	1	1	1	1	kanban
26	1	1	1	1	1	kanban
29	1	1	1	0	1	kanban
30	1	4	1	0	1	hat yanı
31	1	1	1	0	1	kanban
54	1	1	1	1	1	kanban
65	1	1	1	0	1	kanban
76	1	1	1	0	1	kanban
83	1	1	1	1	1	kanban
104	1	1	1	1	1	kanban
1080	0	3	2	0	1	çağrı ile
1081	0	4	2	1	1	çağrı ile
1082	0	4	2	1	1	çağrı ile
1083	0	3	2	0	1	çağrı ile
1088	0	2	3	0	1	çağrı ile
1089	0	1	2	1	1	çağrı ile
1091	0	2	2	0	1	çağrı ile
2221	1	3	2	1	1	hat yanı

EK 2 LM algoritması ile yapılan denemelerin bir kısmı

Deneme	Gizli katman nöron sayısı	Momentum	Öğrenme oranı	İterasyon sayısı	Hata	Algoritma
179	4-8	0,5	0,4	129	0,0048	LM
192	4-8	0,5	0,4	123	0,0051	LM
55	4-5	0,5	0,4	1487	0,0054	LM
63	4-8	0,9	0,1	127	0,0054	LM
50	4-3	0,5	0,4	169	0,0056	LM
112	8-7	0,5	0,4	149	0,0057	LM
83	5-9	0,5	0,4	3301	0,0060	LM
196	4-6	0,5	0,4	266	0,0060	LM
199	4-6	0,5	0,4	79	0,0060	LM
77	5-6	0,5	0,4	90	0,0064	LM
80	5-7	0,5	0,4	88	0,0067	LM
102	7-7	0,5	0,4	82	0,0067	LM
136	10-8	0,5	0,4	92	0,0068	LM
103	7-8	0,5	0,4	127	0,0069	LM
197	4-6	0,5	0,4	208	0,0070	LM
119	9-4	0,5	0,4	100	0,0071	LM
131	10-4	0,5	0,4	116	0,0072	LM
184	4-8	0,5	0,4	3747	0,0073	LM
166	7-6-4	0,5	0,3	120	0,0073	LM
104	7-9	0,5	0,4	230	0,0078	LM
122	9-6	0,5	0,4	83	0,0079	LM
138	10-9	0,5	0,4	500	0,0080	LM
198	4-6	0,5	0,4	810	0,0080	LM
162	6-6-5	0,5	0,4	137	0,0081	LM
53	4-4	0,5	0,4	191	0,0081	LM
118	9-3	0,5	0,4	72	0,0082	LM
90	6-5	0,5	0,4	87	0,0083	LM
101	7-6	0,5	0,4	104	0,0084	LM
134	10-7	0,5	0,4	148	0,0084	LM
60	4-8	0,5	0,4	1091	0,0085	LM
173	7-6-4	0,5	0,4	94	0,0088	LM
175	5-6-4	0,5	0,4	112	0,0088	LM
111	8-6	0,5	0,4	88	0,0088	LM
99	7-4	0,5	0,4	85	0,0089	LM
163	6-6-7	0,5	0,4	307	0,0089	LM
120	9-5	0,5	0,4	72	0,0090	LM
94	6-9	0,5	0,4	207	0,0090	LM
195	4-7	0,5	0,4	448	0,0090	LM
123	9-6	0,5	0,4	601	0,0091	LM
98	7-3	0,5	0,4	101	0,0091	LM

EK 3 LM algoritması ile yapılan tekrarlı denemelerin bir kısmı

Deneme	Gizli katman nöron sayısı	Momentum	Öğrenme oranı	İterasyon sayısı	Hata	Algoritma
192	13-12	0,5	0,4	47	0,0042	LM
551	14-12	0,5	0,4	50	0,0044	LM
13	15-10	0,5	0,4	35	0,0048	LM
468	15-12	0,5	0,4	1350	0,0048	LM
403	11-14	0,5	0,4	123	0,0049	LM
390	11-14	0,5	0,4	26	0,0050	LM
452	4-8	0,5	0,4	222	0,0050	LM
55	9-11	0,5	0,4	102	0,0050	LM
143	9-7	0,5	0,4	34	0,0051	LM
293	11-15	0,5	0,2	106	0,0051	LM
175	13-12	0,5	0,4	1592	0,0053	LM
23	15-11	0,5	0,4	22	0,0053	LM
133	5-4	0,5	0,4	36	0,0054	LM
56	9-11	0,5	0,4	17	0,0054	LM
120	12-10	0,5	0,4	22	0,0055	LM
317	11-14	0,5	0,2	170	0,0056	LM
643	16-12	0,5	0,4	1694	0,0056	LM
221	11-15	0,5	0,4	57	0,0057	LM
673	16-12	0,5	0,4	37	0,0058	LM
25	15-11	0,5	0,4	20	0,0058	LM
148	9-7	0,5	0,4	58	0,0059	LM
321	11-14	0,5	0,2	72	0,0059	LM
376	11-14	0,5	0,4	84	0,0059	LM
424	4-8	0,5	0,4	111	0,0060	LM
570	14-13	0,5	0,4	75	0,0060	LM
603	14-13	0,5	0,4	37	0,0060	LM
138	5-4	0,5	0,4	407	0,0061	LM
439	4-8	0,5	0,4	57	0,0061	LM
649	16-12	0,5	0,4	8	0,0061	LM
245	11-15	0,5	0,4	27	0,0062	LM
255	11-15	0,5	0,4	36	0,0062	LM
270	11-15	0,5	0,2	61	0,0062	LM
315	11-14	0,5	0,2	46	0,0063	LM
339	11-14	0,5	0,2	51	0,0063	LM
624	12-12	0,5	0,4	50	0,0063	LM
43	9-11	0,5	0,4	577	0,0063	LM
102	12-10	0,5	0,4	2339	0,0064	LM
246	11-15	0,5	0,4	14	0,0064	LM
274	11-15	0,5	0,2	14	0,0064	LM

EK 4 BR, SCG, GDM Algoritmaları ile yapılan tekrarlı denemelerin bir kısmı

Deneme	Gizli katman nöron sayısı	Momentum	Öğrenme oranı	İterasyon sayısı	Hata	Algoritma
195	13-12	0,5	0,4	1122	0,0032	SCG
754	10-12	0,5	0,4	485	0,0032	SCG
196	13-12	0,5	0,4	1292	0,0033	SCG
525	12-12	0,5	0,4	386	0,0036	SCG
61	13-12	0,5	0,4	108	0,0040	BR
532	12-12	0,5	0,4	242	0,0047	SCG
467	11-14	0,5	0,4	449	0,0047	SCG
555	12-13	0,5	0,4	121	0,0047	SCG
107	13-12	0,5	0,4	587	0,0047	SCG
687	10-10	0,5	0,4	359	0,0048	SCG
634	11-11	0,5	0,4	148	0,0049	SCG
33	16-13	0,5	0,4	31	0,0050	BR
618	11-11	0,5	0,4	761	0,0050	SCG
202	14,12	0,5	0,4	253	0,0051	SCG
691	10-10	0,5	0,4	426	0,0052	SCG
114	13-12	0,5	0,4	138	0,0052	SCG
504	13-15	0,5	0,4	227	0,0052	SCG
568	12-13	0,5	0,4	540	0,0052	SCG
692	10-10	0,5	0,4	391	0,0053	SCG
360	17-16	0,5	0,4	155	0,0053	SCG
425	8-10	0,5	0,4	348	0,0054	SCG
158	13-12	0,5	0,4	10000	0,0054	GDM
596	12-11	0,5	0,4	301	0,0056	SCG
536	12-12	0,5	0,4	435	0,0057	SCG
325	17-18	0,5	0,4	346	0,0057	SCG
320	17-18	0,5	0,4	75	0,0057	SCG
224	14,12	0,5	0,4	505	0,0057	SCG
391	8-9	0,5	0,4	470	0,0058	SCG
97	13-12	0,5	0,4	85	0,0058	BR
53	13-12	0,5	0,4	85	0,0058	BR
355	17-16	0,5	0,4	431	0,0059	SCG
623	11-11	0,5	0,4	578	0,0059	SCG
577	12-11	0,5	0,4	337	0,0059	SCG
434	11-14	0,5	0,4	30	0,0060	SCG
79	13-12	0,5	0,4	59	0,0060	BR
709	10-12	0,5	0,4	276	0,0060	SCG
77	13-12	0,5	0,4	218	0,0060	BR

ÖZGEÇMİŞ

Adı Soyadı : Müge Sinem Çağlayan
Doğum Yeri ve Tarihi : Eskişehir,1994
Yabancı Dil : İngilizce

Eğitim Durumu
Lise : Çanakkale İbrahim Bodur Anadolu Lisesi
Lisans : Uludağ Üniversitesi Endüstri Mühendisliği
Yüksek Lisans : Bursa Uludağ Üniversitesi Endüstri Mühendisliği

Çalıştığı Kurum/Kurumlar : Bosch Rexroth Otomasyon Sanayi ve Tic. A.Ş.

İletişim (e-posta) : mugecagliyan@gmail.com

Yayımları :
Küçüköğlü, İ., Yağmahan, B., Çağlayan, M.S., Yıldız, A. ve Aktokluk, D. (2018).
İç lojistik sisteminde malzeme tedariki için geliştirilmiş matematiksel modelleme
yaklaşımı: Bir uygulama, *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*,
23(4), 159-174. <https://dergipark.org.tr/en/download/article-file/1536986>