



**Araştırma Makalesi / Research Article**  
**JOB-SHOP SCHEDULING DESIGN WITH ARTIFICIAL NEURAL NETWORKS**

**Gökay AKKAYA<sup>\*1</sup>, Turay GÖKÇEN<sup>2</sup>**

<sup>1</sup>Atatürk Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, ERZURUM

<sup>2</sup>Yıldız Teknik Üniversitesi, Makine Fakültesi, Endüstri Mühendisliği Bölümü, Yıldız-İSTANBUL

**Geliş/Received: 13.06.2006 Kabul/Accepted: 28.11.2006**

---

**ABSTRACT**

Simulation, being capable of representing a system's behavior in an effective way, when combined with the neural networks, can provide an efficient decision making structure. In this paper, a system is developed in order to determine the machine, the material handling system and the priority rule that will be used in the system by using Simulation and neural network techniques in Job-Shop scheduling design. The backpropagation algorithm is chosen for the neural network model.

In this paper, first, a neural network that is capable of providing realistic results is obtained. Simulation technique is used in order to obtain the samples to train the neural network in computer environment. The next step includes the decision-making, determination of the ranges where the selected decision remains valid and the related comments. Trained neural networks are used in order to determine the hardware configuration and the scheduling strategy that are capable of providing a determined set of performance criteria. After the simulation of the result(s) that is (are) proposed by the neural network, the deviations of the performance criteria from their corresponding expected values are calculated and proposed in a tabular format. The criteria used in the performance measurement are the average flow time, average tardiness, maximum completion time and machine center usage ratios.

**Keywords:** Job – Shop scheduling, simulation, artificial networks.

**YAPAY SİNİR AĞLARI İLE ATÖLYE ÇİZELGELEME TASARIMI**

**ÖZET**

Bir sistemin davranışlarını iyi bir şekilde temsil kabiliyetine sahip bir modelleme tekniği olan benzetim, yapay zeka teknikleriyle beraber ele alındığında etkili bir karar verme yapısı oluşturmaktadır. Bu çalışmada, Atölye çizelgeleme tasarımında benzetim ve yapay sinir ağı kullanılarak, tezgah seçimi, malzeme taşıma sistemi seçimi ve sistemde kullanılacak öncelik kuralı seçimi için bir sistem geliştirilmiştir. Yapay sinir ağı modeli olarak geriye yayma algoritması (GYA - backpropagation) kullanılmıştır. Bu çalışmadaki yaklaşıma "Öncelik Kuralına Dayalı Yaklaşım" adı verilmiştir. Çalışmada, öncelikle gerçeğe uygun sonuçlar üretebilen, eğitilmiş yapay sinir ağları elde edilmiştir. Öncelik kuralı temel alınarak oluşturulan bu yaklaşımda, örnek setinde sadece seçilen bir öncelik kuralı ve Otomatik Güdümlü Araç (OGA) sayısı konfigürasyonu ile elde edilen değerlerin bulunduğu, öncelik kuralı-OGA sayısı kombinasyonuna göre yapay sinir ağı topolojisi oluşturulmuştur. Ağı eğitmek ve gerekli olan örneklerin elde edilmesi için bilgisayar ortamında benzetim tekniğinden faydalanılmıştır. Performans kriterlerinin belirli bir değerler kümesini sağlayabilecek olan, donanım konfigürasyonu ve çizelgeleme stratejisini belirleyebilmek için, eğitilmiş yapay sinir ağlarından yararlanılmıştır. Yapay sinir ağı tarafından teklif edilen sonuç ya da sonuçların benzetimi sonunda, performans kriterlerinin beklenen değerlerinden sapma miktarları hesaplanmış ve karar verme işlemi çizelgeler halinde sunulmuştur. Performans ölçümünde kullanılan kriterler; ortalama akış zamanı, ortalama gecikme, maksimum tamamlanma zamanı ve tezgah merkezleri kullanım oranlarıdır.

**Anahtar Sözcükler:** Atölye çizelgeleme, benzetim, yapay sinir ağları.

---

\* Sorumlu Yazar/Coressponding Autor: e-mail/e-ileti: gakkaya@atauni.edu.tr, tel: (0442) 231 45 68

## 1. GİRİŞ

Çizelgeleme, problemin verilen kısıtlarına bağlı olarak belli bir amaç fonksiyonunu optimum yapan birleşimin bulunması ile ilgilenmektedir. Örneğin, atölye tipi ve akış tipi üretimin çizelgelenmesinde amaç, süreç içi stok zamanını veya tüm işlerin birlikte tamamlanma zamanını (makespan) kısıtları (tesis maksimum kapasitesi, elverişli makine sayısı vb.) sağlayacak şekilde enküçükmektir. Rotalama, akış planlama vb. içeren kısıtlı optimum problemleri olarak ele alınabilecek bir çok üretim problemleri bulunmaktadır. Ayrıca fabrika yerleşimi ve yükleme problemleri de kısıtlı optimum problemleri olup, diğer problemlerle yakın ilgileri bulunmaktadır [1].

Bu çalışma bir atölye imalat sisteminde planlama, çizelgeleme ve analiz etme olarak kullanılan, benzetim-yapay sinir ağı temelli bir tasarım sistemidir. Atölye çizelgeleme tasarımı, çok sayıda tasarım alternatifini değerlendirmeyi gerektiren karmaşık bir karar verme prosesidir. Bir tasarımın performansı değişik metodlarla analiz edilebilir. Örneğin; sistemin küçük ölçekte bir fiziksel modelini yapmak, analitik araçlar uygulamak, benzetim vb. Bir atölye çizelgeleme sisteminin dinamik davranışını analiz etmek için en fazla kullanılan araç benzetimdir. Yeni bir atölye çizelgeleme tasarımı için benzetim, bütün sistemin tasarımında ve tasarım alternatiflerini değerlendirmesinde kullanılabilir [2]. Bir atölye çizelgeleme benzetiminin tipik sonuçları, kapasite değerlendirme, teçhizat kullanım oranlarını belirleme, sistemdeki darboğazları belirleme, alternatif tasarımların performanslarını karşılaştırma, atölye çizelgeleme tasarımında önemli olmayan unsurları görme ve çizelgeleme stratejilerini geliştirmektir [3].

Benzetim, yapay zeka teknikleriyle beraber ele alındığında etkili bir karar verme yapısı oluşturabilir. Yapay zeka teknikleri, tasarımda gerekli olan bilgi kaynakları setinin geliştirilmesi ve tasarım prosesinin organizasyonu gibi problemleri çözme kabiliyetini artırma özelliklerine sahiptir. Bir yapay sinir ağı tek başına veya başka bir uygulama programı ile beraber icra edilebilir. Yapay sinir ağları, ürün ve proses tasarımı, çizelgeleme ve üretim sistemi tasarımı gibi problemlerin çözümünde uygulanmaktadır.

Atölye çizelgeleme problemleri kombinatorik problemlerdendir. Bu tip problemlerde kısıtlar arttıkça çözüm uzayı sonsuza doğru gitmeye başlar ve tam optimum çözümü bulmak gittikçe zorlaşır. Bu nedenle son yıllarda bu tip problemleri çözmek için sezgisel algoritmalarla yararlanılmaya başlanılmıştır. Yapay sinir ağları da bu sezgisel algoritmalarındandır. İlk olarak, Hopfield ve Tank [4], çizelgeleme problemlerini yapay sinir ağları ile çözmeye çalışmışlardır. Ama ağın yerel optimuma düşmesi gibi problemler ile karşılaşmışlardır. Bu problemi gidermek amacı ile bu sinir ağı modeli geliştirilerek, toplam akış süresini enküçükleyen Gaussian yöntemi geliştirilmiştir [5]. Sabuncuoğlu ve Gürgün [6] Hopfield ağlarını kullanarak, Paralel yapay sinir ağları (PNN-Parallized Neural Network) adı verilen bir ağın tasarımını sunmuşlardır. Burada, işlerin sırasını ve pozisyonunu gösteren bir  $(n \times n)$  nöron matrisi geliştirilmiştir. Ayrıca  $m$  tezgah sayısı olmak üzere  $m \times n \times n$  büyüklüğünde üç boyutlu bir matris de geliştirilmiştir. Ağ tasarımında aktivasyon fonksiyonu sigmoid ve çizelgelenen operasyonların en büyük tamamlanma süresi o ağın enerjisi olarak kullanılmıştır. Sonuçta, ağın pek çok atölye çizelgeleme problemleri için optimum çözümler ürettiği yazarlar tarafından ortaya koyulmuştur. Yine Tank ve Hopfield ağı geliştirilerek, atölye çizelgeleme problemlerine bir çözüm getirilmeye çalışılmıştır [7]. Yang ve Wang [8], genel atölye çizelgeleme problemleri için CSANN (Constraint Satisfaction Adaptive Neural Network) algoritmasını ve sezgisel algoritmaların birleştirilmesi ile bir çalışma yapmışlardır. Bu çalışmada atölye çizelgeleme problemi için önerilen yaklaşımlarda, birkaç sezgisel algoritma ve CSANN algoritması birleştirilmiştir. Atölye çizelgeleme problemlerinin çözümü için diğer bir yaklaşım da yapay sinir ağları ile genetik algoritmanın birlikte kullanılarak melez bir çözüm tekniği elde edilmesidir. Buradaki sinir ağının yapısı da kısıtlı bir ağ yapısıdır (CNN – Constraint Neural Network). CNN burada atölye başlangıç zamanlarını ve başlangıç sıralamasını bulmak için kullanılmıştır. Buradan elde edilen değerler, daha optimum bir

sıralama bulmak için genetik algoritma ile birleştirilmiştir. Bu çalışma pratik uygulamalar da ve birçok benzetim çalışmaları test edilmiş ve çok iyi sonuçlar elde edilmiştir [9]. Başka bir çalışmada, bir üretim faaliyet çizelgelemesinin tasarlanması, geliştirilmesi ve uygulanması için çok katmanlı algılayıcı (ÇKA) (MLP – Multi-Layered Perceptron) yapay sinir ağı kullanılmıştır. Burada, bir işin işlem sırası ve işlem zamanını bulmak için bir veri tabanından yararlanılmıştır. Yerel minimum çözümleri kontrol etmek için GYA kullanılmıştır. Ayrıca başlangıç üretim çizelgelemesi için bir sezgisel algoritma geliştirilmiştir. Bu çalışmada sunulan üretim faaliyet çizelgeleme sistemi, gerçek bir üretim ortamında da test edilmiş, faydalı ve mümkün çözümler elde edilmiştir. Bu sistem aynı zamanda şirketlerin, üretim faaliyet kontrollerini, müşteri hizmetlerini ve karlılığını geliştirmede de yardımcı olmaktadır [10]. Başka bir çalışmada ise, atölye çizelgeleme problemlerini çözerken, yapay sinir ağı başlangıç çözümü üretmek amacı ile kullanılmıştır. Daha sonra bu başlangıç çözümü tavlama benzetimi metodu ile geliştirilerek, optimum ya da optimuma yakın çözümler elde edilmeye çalışılmıştır [11]. Hem çizelgeleme öncelikli kuralını, hemde tezgah sayılarını belirleyen yapay sinir ağı sistemleri daha önce de geliştirilmiştir. Ama bu sistemler, genel olarak imalat sistemlerinin tasarlanmasında [12], esnek imalat sistemleri [13] ve akış tipi sistemlerde kullanılmışlardır. Ama bu çalışmada bunlardan farklı olarak atölye tipi bir sistemde bu seçimler yapılmıştır.

## **2. YAPAY SİNİR AĞLARI**

Yapay sinir ağı beynin bazı fonksiyonlarını ve özellikle öğrenme yöntemlerini benzetim yolu ile gerçekleştirmek için tasarlanmış ve geleneksel yöntem ve bilgisayarların yetersiz kaldığı sınıflandırma, kümeleme, duyu-veri işleme gibi alanlarda başarılı sonuçlar vermiştir. Yapay sinir ağlarının özellikle tahmin problemlerinde kullanılabilmesi için çok fazla bilgi ile eğitilmesi gerekmektedir. Ağların eğitimi için çeşitli algoritmalar geliştirilmiştir [13].

Yapay sinir ağı, yukarıda da belirttiğimiz gibi insan sinir sisteminin biyolojik yapısından esinlenmiş bir yapıya sahiptir. Yani, yapay sinir ağı, insan sinir sistemindeki sinir hücrelerinin fonksiyonunu gören temel elemanlardan oluşmaktadır. Bu elemanlar insan beyninin anatomisine benzer şekilde organize edilmişlerdir. Bu büyük benzerliğin yanı sıra, yapay sinir ağı, şaşırtıcı derecede insan beyninin birçok özelliklerini taşır. Örneğin, tecrübe ile öğrenirler, daha önce öğrenilen bilgileri genele indirgeyerek yeni çıkarımlar yaparlar. Bu yeni çıkarımlardan gereksiz kısımları atarak önemli olan öz kısmını alırlar. Fakat bütün bu fonksiyonel benzemelere rağmen, yapay sinir ağlarının yakın bir gelecekte insan beyninin fonksiyonlarını aynen yerine getirebileceği söylenemez. Bugün bu alanda gelinen nokta, insan zekasının derinlemesine bir incelemesinin, yapay sinir ağı alanında devrim niteliğinde uygulamaları da beraberinde getireceğini göstermektedir. Yapay sinir ağlarına son yıllarda büyük bir ilgi gösterilmektedir. Mühendislik, tıp, felsefe, psikoloji gibi alanlarda çalışanlar yapay sinir ağını kendi uzmanlık alanlarına taşıyarak, kendi alanlarında uygulamalarını geliştirmeye başlamışlardır. Bu ilgi, teorik ve uygulama alanlarındaki başarılarla daha da pekiştirilmiştir. İnsan zekasına has gibi görünen bazı alanların sayısal olarak ifade edilebileceği ve böylece makinelerin insan zekasına şaşırtıcı derecede benzer yollarla öğrenme ve hatırlama işlerini yapabileceği görülmüştür [14].

### **2.1.1. Geriye Yayma Algoritması**

Bu çalışmada yapay sinir ağı olarak Geriye Yayma Algoritması (GYA- Backpropagation) kullanılmıştır. Yıllarca çok katmanlı yapay sinir ağı ile ilgili çalışmalardan bir sonuç alınamamıştır. Tek katmanlı yapay sinir ağı ancak birkaç sınırlı imkanı tanıyabilmiştir. Fakat daha ötesine gidilememiştir. GYA'nın keşfi yapay sinir ağlarına olan ilgiyi tekrar canlandırmıştır. GYA çok katmanlı yapay sinir ağı için sistematik bir metottur ve çok güçlü

bir matematik temele sahiptir. Bunun yanında her türlü kısıta rağmen GYA yapay sinir ağlarının uygulanabildiği problem aralığının genişlemesine yol açmış ve çok sayıda başarılı ve güçlü uygulamaların üretilmesine imkan vermiştir.

GYA algoritmasının ilginç bir tarihsel gelişimi vardır. Rumelhart, Hinton ve Williams 1986 yılında GYA algoritmasını açık ve net bir biçimde ortaya koymuşlardır. Bu araştırmaya ilk başlayanlardan birisi Parker olmasına rağmen, bu algoritmayı ilk olarak 1974 yılında Werbos ortaya koymuştur. Rumelhart ve Parker, Werbos'un bu çalışmasını geliştirerek, algoritmayı daha sağlam bir yapıya oturtmuşlardır. Yapay sinir ağları, konu itibariyle disiplinler arası olması nedeniyle daha ciddi bir yapıya sahiptir. Disiplinler arası olması, her yere kolayca adapte edilebilmesi sebebiyle çok çabuk gelişmiş ve konuyla ilgili kayda değer çalışmalarda bulunulmuştur. Bu da konunun gelişimini otomatik olarak hızlandırmıştır [14].

### 3. ATÖLYE ÇİZELGELEME VE BENZETİM

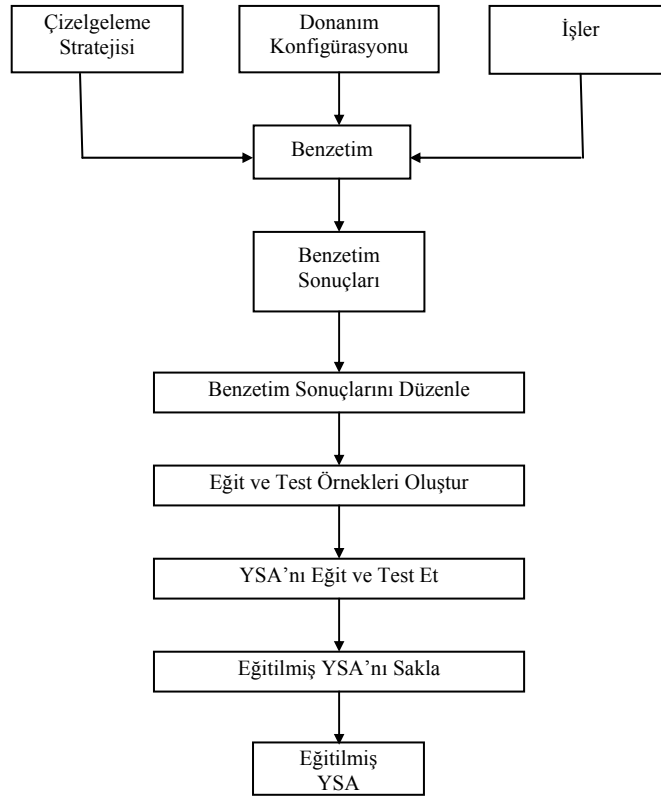
Yaklaşık yirmi yıldan beri bilgisayarlar benzetim imalat sistemlerinin tasarım ve analizinde kullanılmaktadır. Son on yıl boyunca benzetimin, sınırlı kapasiteli çizelgeleme konusunda kullanımı yaygınlaşmıştır. Sınırlı kapasiteli çizelgeleme, geleneksel bir benzetim analizinden bazı yönleri ile farklıdır: Geleneksel bir benzetim analizinde karar değişkenleri genellikle gerekli tezgah sayısı ya da kullanılması gereken malzeme taşıma teçhizatı gibi tasarımla ilgili kararlardır. Benzetim tabanlı atölye çizelgeleme sisteminde ise karar değişkenleri, işin atölyeye ne zaman gönderileceği, bir tezgahdaki işlerin hangi sırayla işleneceği, parçanın atölyede hangi rotayla dolaşacağı, çizelge zamanının aşılması gibi işlemsel kararlardır. Benzetim tabanlı atölye çizelgelemenin girdileri tipik iş emirleri ve teslim tarihleridir. Çıktısı genel benzetim özet istatistikleri değil, her tezgaha işlerin ne zaman başlayacağı, hangi siparişlerin zamanında teslim edilebileceği gibi bilgileri gösteren detaylı bir çizelgedir. Şunu belirtmek gerekir ki, benzetim tabanlı atölye çizelgeleme en iyi çizelgeyi oluşturmaz. Bunun yerine değişik "eğer-ne" senaryolarını deneyerek en uygun çizelgeyi oluşturmayı seçmeyi sağlar. Bir benzetim tabanlı çizelgeleme, geleneksel benzetim modellerinden daha kısa bir süre için çalışır ve daha sık çalıştırılır. Ayrıca mevcut sistem bilgilerini alabilmek için imalat veri tabanları ile etkileşim içinde olması uygundur. Özellikle yüksek teknolojlili imalat sistemlerinde benzetim tabanlı çizelgelemenin kullanılması faydalıdır. MRP, MRP-II gibi sistemlerden alınacak bilgiler ve atölyeden gelen anlık durum bilgilerini kullanarak alternatif çizelgelerin hazırlanması, bunların denenerek en uygununun seçilmesi gibi hızla yapılması gereken işlemler benzetim tabanlı çizelgeleme yardımıyla hızlı ve kolay şekilde gerçekleştirilir. Özellikle tezgahların boş beklemelerinin, işlerin gecikmesinin çok önemli maddi kayıplar oluşturduğu pahalı ve yüksek teknolojlili sistemlerde benzetim kullanılarak çizelgeleme yapılması karar vermeyi kolaylaştırarak maddi kayıpların en aza inmesini sağlar.

Bir atölyedeki sistemin genel yapısı şöyledir. Atölyeye gelen işler çizelgelenmiş tezgahların bekleme hattına alınırlar. Tezgah boşaldığı zaman öncelik kuralına göre seçilen işler tezgaha atanırlar ve işlem bittikten sonra işleneceği diğer tezgahın bekleme hattına taşıma aracı ile taşınırlar. İşlemleri tamamlanan işlerin gerekirse montajı yapılarak ürün elde edilir. Bu tip bir sistemi çizelgeleyebilmek için öncelikle modelini oluşturmak gerekir. Çizelgeleme ve kontrol amacıyla kullanılan modellere işlemsel (operational) modeller denir. Atölyenin benzetimi, benzetim saatini artırarak atölyenin tüm çalışmasının taklit edilmesi işlemidir. Her artırımda model parametrelerindeki gerekli değişiklikler yapılır. Her değişiklik bir olay anlamına gelir. Bir tezgah, operatör ya da iş istasyonu bir operasyonu tamamlayınca, daha sonra ne yapacağı konusunda bir karar vermelidir. Her varlık bir sonraki operasyonunu seçmelidir. Bu seçim bir yükleme ya da çizelgeleme kuralına göre yapılır. Atölye çizelgelemede kullanılan yükleme kurallarının etkinliği hakkında pek çok çalışma yapılmıştır. [15]. Bu çalışmada, En Kısa İşleme Zamanı (EKİZ), En Erken Teslim Tarihi (EETT), İlk Gelen İlk İşlem Görür (İGİG) kuralları kullanılmıştır.

#### 4. DENEYSEL ÇALIŞMA VE UYGULAMA


##### 4.1. İncelenen Modelin Atölye ve Yapay Sinir Ağı Yapısı

İncelenen atölyede 4 iş merkezi vardır ve her iş merkezindeki tezgah sayısı bir ile beş arasında değiştirilerek alternatif konfigürasyonlar elde edilmiştir. Tezgahlar bir anda yalnız bir parça işleyebilir ve o parçanın operasyonları bitirilinceye kadar diğer bir parçanın operasyonuna başlanamaz. Parçalar yükleme/boşaltma merkezinden sisteme girerler. İş merkezindeki bir tezgah kullanılabilir bir hale geldiği zaman, parça girdi alanından tezgaha otomatik olarak hareket ettirilir ve operasyon başlatılır. Bir parçanın operasyonu tamamlandığında, eğer merkezin çıktı alanında boş yer varsa, parça otomatik olarak tezgahın çıktı alanına hareket ettirilir. Eğer bir sonraki merkezin girdi alanında boşluk var ise parçayı doğrudan bir sonraki merkeze taşımak amacıyla bir OGA (Otomatik Güdümlü Araç) istenilir. Boşluk yoksa parçayı yükleme/boşaltma merkezine taşımak için bir OGA istenilir. Parçaya bütün operasyonlar bir kez icra edildikten sonra parça çıkış merkezine aktarılır ve burada sistemden ayrılır. İşlenmek üzere bekleyen parçalardan, öncelikle hangisinin işlem göreceğini belirlemek için kullanılan çizelgeleme kuralları yukarıda da belirtildiği gibi En Kısa İşleme Zamanı (EKİZ), En Erken Teslim Tarihi (EETT) ve İlk Gelen İlk İşlem Görür (İGİG)'dir. Ayrıca, yükleme-boşaltma merkezi ve OGA kuyruğu için kuyruk öncelik kuralı İGİG'dir. Burada, her iş merkezi için yapay sinir ağı topolojisi oluşturulmuş ve bütün donanım-çizelgeleme stratejisi kombinasyonlarına ait değerler bir örnek setinde yer almıştır. Çalışmanın algoritma şeması şekil -1'de gösterilmiştir.



Şekil 1. Yapay sinir ağının oluşturulması ve test edilmesi

Bu yaklaşım "Öncelik Kuralına Dayalı Yaklaşım" olarak isimlendirilmiştir. Bu yaklaşımın yapay sinir ağı yapısı şekil-2'de gösterilmiştir.



Şekil 2. İş merkezine dayalı yaklaşım için yapay sinir ağı yapısı

#### 4.2. Benzetim Deneyleeri

Eğitilmiş yapay sinir ağı elde etmeden önce öğrenilmesi istenen yapının örneklerinin bulunması gereklidir. Bu örneklerin elde edilmesi için bilgisayar ortamında benzetim tekniğinden faydalanılmıştır. Benzetim modülünün girdileri; atölye ortamında hangi tip tezgahtan ne kadar bulunduğu gibi bilgileri içeren donanım konfigürasyonu, işlerin atölye ortamına nasıl dahil olduğu, hangi iş merkezlerinde işlem gördüğü, bu işlemlerin ne kadar sürdüğü gibi bilgileri içine alan işlerin yapısı, ayrıca atölyeye dahil olan işlerin hangi sıra ile işlem göreceğini belirleyen çizelgeleme stratejisi gibi bilgilerdir. Benzetim işleminin çıktıları sistemi değerlendirme ve karar verme işlemlerinde kullanılmak üzere seçilmiş olan performans kriterlerinin gerçekleşen değerleridir. Yapay sinir ağı eğitime ve test etme işlemleri için gerekli olan örnekler benzetim çıktılarının düzenlenmesi ile elde edilir. Bu düzenlemede yapay sinir ağının girdileri, istenen performans kriterlerinin gerçekleşen değerleri, çıktılar ise iş merkezlerinde kullanılacak olan tezgah sayılarıdır. Yapay sinir ağı tarafından teklif edilen sonuç ya da sonuçlar, farklı alternatifler için benzetim yolu ile tekrar deneyerek performans kriterlerinin beklenen değerlerinden sapma miktarları yüzde olarak hesaplanır. Hedeften sapma yüzdesi ile birlikte diğer hesaplanan değerler bir çizelge halinde karar verme işlemi için sunulacaktır. Karar verme işlemi karar vericinin belirlediği bir kritere göre yapılabilir. Bu çalışmada, hedeften sapma yüzdesinin ortalama mutlak değeri karar verici için bir kriter olarak kullanılmıştır. Aynı zamanda birden fazla kriter göz önüne alınabilir. Ortalama gecikmelerin minimum değeri ve ortalama mutlak sapma değerlerinin minimum değeri gibi.

Benzetim ve yapay zeka tekniklerinin birlikte kullanımı ile, zeki benzetim modelleri elde edilebilir [7]. Benzetim deneyleri, atölye çizelgeleme konfigürasyonu ve iş öncelik kuralı kararının, performans kriterleri (akış zamanı, gecikmeler, maksimum tamamlanma zamanı ve iş istasyonu kullanım oranları) üzerindeki etkisini görmek üzere tasarlanmıştır. İş merkezi tezgah sayısı, taşıyıcı sayısı ve iş öncelik kuralı parametrelerinin manipülasyonu yoluyla alternatif konfigürasyonlar elde edilmiştir. Benzetim sonucunda dikkate alınan değerler, ortalama akış zamanı, ortalama gecikme, maksimum tamamlanma zamanı ve iş merkezi tezgah kullanım oranlarıdır. Seçilen her alternatif konfigürasyon için benzetim yapılarak sonuçlar elde edilmiş ve düzenlenerek örnek setleri oluşturulmuştur.

### 4.3. Yapay Sinir Ağı Eğitime ve Test Sonuçları

Benzetim sonuçlarından elde edilen değerlerle eğitime ve test örnekleri oluşturularak GYA ile yapay sinir ağları eğitilmiştir. Yapay sinir ağlarının eğitilmesinde iyi sonuçlar elde edilmiştir. Burada, örnek setinde sadece seçilen bir öncelik kuralı ve OGA (Otomatik Güdümlü Araç) sayısı konfigürasyonu ile elde edilen değerlerin bulunduğu, öncelik kuralı-OGA sayısı kombinasyonuna göre yapay sinir ağı topolojisi oluşturulmuştur. Bu yaklaşıma da "Öncelik Kuralına Dayalı Yaklaşım" adı verilmiştir. Her ağı girdi değerleri performans ölçüleri, çıktı değeri ise iş merkezi tezgah sayılarıdır. Eğitilmiş olan her ağ üzerinde aynı girdi değerleri (istenilen performans ölçüleri) girilerek, bu performans ölçülerini gerçekleyebilecek olan iş merkezleri tezgah sayıları elde edilmiştir. Elde edilen bu tezgah sayıları, OGA Sayısı-Öncelik Kuralı ikilisinin kombinasyonuna göre (1-OGA- EETT, 2-OGA-EETT, 3-OGA-EETT, 1-OGA- EKİZ, 2-OGA-EKİZ, 3-OGA-EKİZ, 1-OGA-İGİG, 2-OGA-İGİG, 3-OGA-İGİG), ayrı ayrı benzetim yapılarak istenilen performans ölçülerinden minimum mutlak sapma gösteren donanım ve çizelgeleme stratejisi (Tezgah Sayısı-OGA Sayısı-Öncelik Kuralı) belirlenmiştir.

Bu yaklaşım için öncelik kuralı ve OGA sayısı kombinasyonlarından oluşan dokuz adet yapay sinir ağı tasarlanmıştır. Bu yapay sinir ağlarının kısaltılmış olarak kullanılan isimleri ve açıklmaları ise şöyledir:

EETT1: Öncelik kuralı "En Erken Teslim Tarihi", OGA sayısı "bir"  
EETT2: Öncelik kuralı "En Erken Teslim Tarihi", OGA sayısı "iki"  
EETT3: Öncelik kuralı "En Erken Teslim Tarihi", OGA sayısı "üç"  
EKİZ1 : Öncelik kuralı "En Kısa İşleme Zamanı" , OGA sayısı "bir"  
EKİZ2 : Öncelik kuralı "En Kısa İşleme Zamanı" , OGA sayısı "iki"  
EKİZ3 : Öncelik kuralı "En Kısa İşleme Zamanı" , OGA sayısı "üç"  
İGİG1 : Öncelik kuralı "İlk Gelen İlk İşlem Görür", OGA sayısı "bir"  
İGİG2 : Öncelik kuralı "İlk Gelen İlk İşlem Görür", OGA sayısı "iki"  
İGİG3 : Öncelik kuralı "İlk Gelen İlk İşlem Görür", OGA sayısı "üç"

Bu dokuz yapay sinir ağının her biri ayrı ya da aynı sonucu üretebilir. Her yapay sinir ağının sonucu, istenen performans kriterlerini gerçeklemek için gerekli olan tezgah sayılarının bütün iş merkezleri için belirlenmesidir. Her bir eğitime seti için, deneme-yanılma ile belirlenen farklı iterasyon sayısı ve öğrenme oranları uygulanarak eğitilip test edilen sonuçlar ayrı ayrı çizelgelerde yapılmıştır. Burada örnek olması açısından aşağıdaki Çizelge-1 verilmiştir. Burada sol taraftaki çizelge eğitim seti sonuçlarını, sağ taraftaki çizelge test seti sonuçlarını göstermektedir. Bu çizelgelerde yer alan ifadeler kısaca aşağıda açıklandığı gibidir.

**Girdi sayısı:** Bütün yapay sinir ağları için girdi sayısı "yedi" adettir. Bunlar seçilen performans kriterlerinin benzetim sonucunda elde edilen ve gerçekleştiren değerleri ifade eder. Bu kriterler; "Ortalama Akış Süresi", "Ortalama Gecikme Süresi", "Maksimum Tamamlanma Süresi", "Birinci İş Merkezi Kullanım Oranı", "İkinci İş Merkezi Kullanım Oranı", "Üçüncü İş Merkezi Kullanım Oranı" ve "Dördüncü İş Merkezi Kullanım Oranı" dır.

**Çıktı sayısı:** Çıktı katmanında bulunan yapay sinir hücresi sayısını ifade eder. Dolayısıyla bu yaklaşım için bu sayı "dört" tür.Yani, iş merkezlerinde kullanılması gerekli olan tezgah sayıları yapay sinir ağının çıktısı olarak elde edilir.

**Öğrenme oranı ( $\lambda$ ) ve Momentum katsayısı ( $\alpha$ ):** Öğrenme, her ikisi de 0 ile 1 değeri arasında değer alan öğrenme oranı ve momentum katsayısı ile kontrol edilir. Öğrenme işleminde son derece önemli olan bu katsayılar her ağ için ayrı ayrı olarak, yine deneme-yanılma yolu ile belirlenmiştir.

**İterasyon sayısı :** Devir sayısı (Epoch), örnek setinin bir defa yapay sinir ağına gösterilmesidir. İterasyon ise her örneğin bir defa yapay sinir ağına gösterilmesidir. İterasyon sayıları genel olarak 200 devir sayısından sonra öğrenme işleminde istenen seviye sağlanıncaya kadar kademeli olarak artırılarak elde edilen sayıları ifade eder.

**İterasyon süresi:** Öğrenme işlemi sırasında geçen sürenin dakika cinsinden ifadesidir. İterasyon süresi için, bir karar verme işleminde uzun sayılmayacak sonuçlar elde edilmiştir.

**Toplam örnek sayısı ve toplam grup sayısı:** Aslında grup sayısı ile ifade edilen yapay sinir ağı açısından örnek sayısıdır. Ancak, burada her örnekte bulunan dört iş merkezi sonucunun hepsi de ayrı ayrı önemli olduğundan başarı oranının bu açıdan hesaplanabilmesi için, her örnek grup ismi altında incelenmiştir. Böylece 75 grup (yani örnek seti büyüklüğü), her grupta 4 çıktı bulunduğundan 300 örnek olarak değerlendirilmiştir. Bu şekilde daha hassas sonuçlar elde edilmeye çalışılmıştır.

**Hatalı örnek sayısı ve hatalı grup sayısı:** Hatalı örnek sayısı yapay sinir ağının 4 çıktısından kaç tanesinin gerçek değerden farklı olduğunun toplam sayısını, hatalı grup sayısı ise, bu şekildeki çıktıların kaç adet olduğunu ifade eder.

**Hatalı örnek oranı ve hatalı grup sayısı oranı:** Gerçek değerlerden farklı olan hatalı örnek veya grup sayılarının toplamı, örnek veya grup sayılarına bölünmesi ile elde edilir.

**Sapma toplamı:** Yapay sinir ağının çıktıları tam değer olarak ifade edildiğinden hatalı olmayan örnekler dahil olmak üzere bütün örnekler için çok küçük de olsa bir miktar sapma olabilecektir. Sonuç üzerinde büyük bir etkisi olmamasına rağmen ağın başarı oranı hakkında fikir vermesi açısından değerlendirmeye dahil edilmiştir. Çizelgelerden de görüleceği üzere çok küçük sapma değerleri elde edilmiştir.

**Ortalama sapma ve ortalama grup sapma oranı:** Hesaplanan sapma miktarının yukarıda açıklanan toplam örnek sayısı ve toplam grup sayısına bölünmesi ile elde edilir.

**Çizelge 1.** EETT1 YSA eğitim ve test sonuçları

Girdi sayısı	7
Çıktı sayısı	4
Gizli birim sayısı	35
Öğrenme oranı	0.30
Momentum katsayısı	0.70
İterasyon sayısı	499912
İterasyon süresi	5.54 dk
Hatalı örnek sayısı	0
Toplam örnek sayısı	300
Hatalı örnek oranı	0.00
Hatalı grup sayısı	0
Toplam grup sayısı	75
Hatalı grup sayısı oranı	0.00
Sapma toplamı	2.12
Toplam örnek sayısı	300
Ortalama sapma	0.007
Toplam grup sayısı	75
Ortalama grup sapma oranı	0.028

Girdi sayısı	7
Çıktı sayısı	4
Gizli birim sayısı	35
Öğrenme oranı	0.30
Momentum katsayısı	0.70
İterasyon sayısı	499912
İterasyon süresi	5.54 dk
Hatalı örnek sayısı	4
Toplam örnek sayısı	400
Hatalı örnek oranı	0.00
Hatalı grup sayısı	4
Toplam grup sayısı	100
Hatalı grup sayısı oranı	0.04
Sapma toplamı	4.32
Toplam örnek sayısı	400
Ortalama sapma	0.011
Toplam grup sayısı	100
Ortalama grup sapma oranı	0.043

Çizelge-2'de istenen performans kriteri değerlerine göre belirlenen konfigürasyon ve bu konfigürasyona göre benzetim işlemi sonucunda beklenen değerlerden sapmalar yüzde olarak gösterilmektedir. Karar çizelgesinde verilen hata yüzdesi şu şekilde hesaplanmıştır:

$$\text{Hata Yüzdesi} = (\text{Beklenen Değer} - \text{Gerçekleşen Değer}) / \text{Beklenen Değer} \quad (1)$$

Karar verilirken ortalama minimum mutlak sapma dikkate alındığından, seçim kararı olabilecek olan minimum mutlak sapma bu çalışmada dikkate alınmıştır.

Yukarıdaki çizelge, performans kriterlerinin istenen değerlerine en yakın değerleri elde edebilmek için oluşturulan karar verme çizelgesidir. Seçilen bir karar verme kriterine göre, bu çizelge kullanılarak karar verme işlemi gerçekleştirilebilir. Yukarıdaki çizelgede, minimum



ortalama mutlak sapma kriterine göre mutlak değerce en küçük olan değerdir (bu değer çift yıldızla gösterilmiştir). Bu çizelgede, ortalama mutlak sapma kriterine göre seçim kararı için iki alternatif vardır. Birincisi için iş merkezi tezgah sayıları: 3, 2, 2, 3, öncelik kuralı: EETT ve OGA sayısı:1'dir. İkincisi için iş merkezi tezgah sayıları: 3, 2, 2, 3, öncelik kuralı: EETT ve OGA, sayısı:3'dür. Burada OGA sayısı 1 adet olan birinci seçenek aynı sonucu daha az maliyet ile sağlayacağından tercih edilmesi daha uygun olabilecek bir seçenektir.

**Çizelge 2.** Hata Analizi ve Karar Çizelgesi

İstenen Performans Değerleri										
F = 5000 T = 500 C <sub>max</sub> = 15000 mu1=0.90 mu2= 0.90 mu3= 0.90 mu4= 0.90										
Kural	OGA			Tezgah Sayısı						
EETT	1			3 2 2 3						
EETT	2			3 2 2 3						
EETT	3			3 2 2 3						
EKİZ	1			3 2 2 2						
EKİZ	2			3 2 2 2						
EKİZ	3			3 2 2 3						
İGİG	1			3 1 2 2						
İGİG	2			3 1 2 2						
İGİG	3			3 2 2 2						
Hata (%)	EETT1	EETT2	EETT3	EKİZ1	EKİZ2	EKİZ3	İGİG1	İGİG2	İGİG3	Min
F	-0.28	-0.26	-0.28	-0.59	-0.59	-0.28	-0.86	-0.87	-0.61	
T	-4.65	-4.59	-4.61	-7.79	-8.12	-5.73	-13.56	-14.26	-8.26	
C <sub>max</sub>	0.15	0.13	0.11	-0.07	-0.08	0.06	-0.42	-0.48	-0.08	
mu1	-0.01	-0.04	-0.01	0.16	0.15	0.02	0.38	0.44	0.21	
mu2	0.07	0.13	0.10	0.23	0.23	0.12	-0.03	-0.08	0.19	
mu3	0.03	0.01	0.01	0.19	0.14	0.05	0.37	0.39	0.20	
mu4	0.09	0.14	0.11	-0.02	-0.02	0.15	0.26	0.25	-0.04	
Ort.	0.75	0.76	0.75	1.29	1.33	0.92	2.27	2.40	1.37	0.75**

\*\* : Minimum ortalama mutlak sapma kriterine göre mutlak değerce en küçük olan değerdir

## 5. SONUÇLAR

Bu çalışma, bir atölye çizelgelemede, planlama, çizelgeleme ve analiz etme olarak kullanılan, benzetim-yapay sinir ağı temelli bir çalışmadır. Bu uygulama, kullanıcıya iş akış zamanı, gecikmeler, maksimum tamamlanma zamanı ve kaynak kullanımının hedeflenen değerlerine göre iş merkezlerinde bulunan tezgah sayıları ve sistemdeki taşıyıcı sayısı konfigürasyonunu yine sistemde kullanılacak öncelik kuralı ile birlikte değerlendirerek en uygun konfigürasyon tasarımını bulabilmesini sağlar. Bir benzetim-yapay sinir ağı yoluyla gözlem ve değerlendirmeyi, gecikmeler, darboğazlar, yüksek akış zamanına götüren durumları görebilmeyi mümkün kılar. Kullanıcı, fabrika modellerinin ve çizelgeleme politikalarının farklı durumlarını oluşturma ve analiz etme kabiliyetine sahip olur.

Benzetim veya uzman sistem-benzetim ya da diğer teknikler kullanılarak yapılan tasarım proseslerinde, amaçlara ulaşıncaya kadar işlemler tekrar edilir. Bu işlemler sırasında ise,

iyi bir uzmana veya uzmanlık bilgisine gereksinim duyulmaktadır. Bu çalışmada sunulan atölye çizelgeleme tasarımında, karar vermek için defalarca işlem yapmaya veya konunun iyi bir uzmanı olmaya gerek yoktur. Tüm işlemler kolaylıkla uygulanabilir ve sonuçları açıklanabilir. Bu çalışma, atölye çizelgeleme tasarımının nasıl olması gerektiği konusunda karar verme sırasında gerekli olan verileri ortaya koyarak, adeta sistemin bir haritasını çıkararak karar vericiye büyük ölçüde yardım eder. Karar vericinin çok defa tekrarlarla veya farklı işlemlere, başka bilgilere olan ihtiyacını en aza indirerek en uygun kararı alabilmesini sağlayacaktır.

Gelecekte yapılacak çalışmalar için; değişik örnek setleri ve farklı ağ yapısı düzenleme, karar verme işlemini daha kolay ve daha uygun kararlar alınabilir hale getirebilecektir. Bundan başka karar verme ve etki analizi sırasında, değerlendirme kriterlerinin tekli etkisi dışında, çoklu etkileri de araştırılarak daha farklı bir karar verme tablosu ortaya koyulabilir.

#### KAYNAKLAR

- [1] Özkazanç, A. Ü., Atölye Tipi Üretim Ortamında İşlerin Çizelgenmesi İçin Yapay Sinirsel Ağ Yaklaşımı, Yüksek Lisans Tezi, Osmangazi Üniversitesi, Eskişehir, 1999.
- [2] Law, A. M. ve Kelton, W. D., Simulation Modeling and Analysis, İkinci Basım, McGraw-Hill, New York, 1992, 696-699.
- [3] Pinedo, M., Scheduling: Theory, Algorithms and Systems, onuncu basım, Prentice Hall, New York, 1995, 125-133.
- [4] Hopfield, J. J. ve Tank, D. W., "Neural Computation of Decision in Optimization Problems", Biological Cybernetics, 52:141-152, 1985.
- [5] Arizono, I., Yamamoto, A. ve Ohta, H., "Scheduling for Minimizing Total Actual Flow Time by Neural Networks", International Journal of Production Research, 30: 503-511, 1992.
- [6] Sabuncuoğlu, İ. ve Gurgun, B., "A Neural Network Model for Scheduling Problems", European Journal of Operational Research, 93 (2): 288 – 299, 1996.
- [7] Foo, S. Y., Takefuji, Y., Szu, H., "Scaling Properties of Neural Networks for Job Shop Scheduling", Neurocomputing, 8: 79 – 91, 1995.
- [8] Yang, S. ve Wang D., "Constraint Satisfaction Adaptive Neural Network and Heuristics Combined Approaches for Generalized Job-Shop Scheduling", IEEE Transactions on Neural Networks, 11 (2): 474 – 486, 2000.
- [9] Yu, H. ve Liang, W., "Neural Network and Genetic Algorithm-Based Hybrid Approach To Expanded Job-Shop Scheduling", Computers & Industrial Engineering, 39 (3-4): 337-356, 2001.
- [10] Feng, S., Li, L., Ling C. L., et. al., "Using MLP networks to design a production scheduling system", Computers & Operations Research, 30 (6): 821-832, 2003.
- [11] Moghaddam, R.T., Jolai, F., Vaziri, F., et.al., "A Hybrid Method for Solving Stochastic Job Shop Scheduling Problems", Applied Mathematics and Computation, 170 (1), 185-206, 2005.
- [12] Çakar, T. "İmalat Sistemlerinin Tasarlanması ve Öncelik Kurallarının Belirlenmesinde Yapay Sinir Ağlarının Kullanılması", Doktora Tezi, İ.T.Ü, 1997.
- [13] Kurt, A., "Simülasyon – Yapay Sinir Ağı İle Esnek Üretim Sistemi Tasarımı", Gazi Üniv. Müh. Mim. Fak. Der., Cilt 18, No:2, 31-38, 2003.
- [14] Haykin, S., Neural Networks, Maxwell-McMillan, Sekizinci basım, Ontario-Canada, 1994, 1-45.
- [15] Dinçmen, M. ve Demirci, E., "Atölye Tipi Üretim Etkileşimli Benzetimi", Endüstri Mühendisliği Dergisi, 2(6): 3-10, 1990.
- [16] Haddock, J. ve O'Keefe, R. M., "Using Artificial Intelligence to Facilitate Manufacturing System Simulation", Computers and Industrial Engineering, 8 (3):275-283, 1990.