

Dijital Dönüşüm Sürecinde Akıllı Üretim Planlama: Yapay Sinir Ağları ve Genetik Algoritma Bütünleşik Yaklaşımı

Kübra TÜMAY ATEŞ^{1*}

¹Çukurova Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Adana

¹<https://orcid.org/0000-0002-3337-7969>

*Sorumlu yazar: ktumay@cu.edu.tr

Araştırma Makalesi

Makale Tarihiçesi:

Geliş tarihi: 30.10.2025

Kabul tarihi:02.02.2026

Online Yayınlanma:15.06.2026

Anahtar Kelimeler:

Yapay sinir ağları
Genetik algoritma
Optimizasyon
Akıllı üretim
Üretim planlama

ÖZ

Günümüzün yoğun rekabet ortamında üretim planlama süreçlerinin etkinliği, işletmelerin sürdürülebilirliği ve operasyonel verimliliği açısından kritik bir öneme sahiptir. Bu çalışmada, İstanbul'da faaliyet gösteren orta ölçekli bir makine üretim tesisinde üretim planlama kararlarını iyileştirmek amacıyla Yapay Sinir Ağları (YSA) ve Genetik Algoritma (GA) yöntemlerini bütünleştiren hibrit bir yapay zeka modeli geliştirilmiştir. Önerilen model iki aşamadan oluşmaktadır: ilk aşamada, sipariş adedi, ürün tipi, stok miktarı ve iş gücü kullanımı değişkenlerine dayalı olarak üretim süresi YSA modeli ile tahmin edilmiştir ($R^2 = 0.91$, MAPE = %8.7). İkinci aşamada ise, elde edilen tahmin değerleri GA tabanlı optimizasyonda kullanılarak siparişlerin üç üretim hattına kapasite kısıtları altında dengeli biçimde atanması sağlanmıştır. Evrimsel operatörler (seçim, çaprazlama, mutasyon) aracılığıyla çalışan GA modeli, iş yükü dengesizliğini minimize ederek genel planlama verimliliğini artırmıştır. Karşılaştırmalı analizler, önerilen yaklaşımın manuel planlamaya göre ortalama üretim süresini %18.6, teslimat gecikmelerini %45.6 ve toplam işçilik maliyetini %11.9 oranında iyileştirdiğini göstermektedir. Sonuç olarak, geliştirilen YSA-GA tabanlı model, küçük ve orta ölçekli işletmeler için düşük maliyetli, uygulanabilir ve dijital dönüşüm sürecine bir karar destek aracı olarak değerlendirilmektedir.

Intelligent Production Planning in the Digital Transformation Process: An Integrated Approach of Artificial Neural Networks and Genetic Algorithm

Research Article

Article History:

Received: 30.10.2025

Accepted: 02.02.2026

Published online:15.06.2026

Keywords:

Artificial neural networks
Genetic algorithm
Optimization
Intelligent manufacturing
Production planning

ABSTRACT

In today's highly competitive industrial environment, the efficiency of production planning processes plays a critical role in ensuring the sustainability and operational performance of enterprises. This study develops a hybrid artificial intelligence model that integrates Artificial Neural Networks (ANN) and Genetic Algorithms (GA) to enhance production planning decisions in a medium-sized machine manufacturing company operating in Istanbul. The proposed model consists of two stages: in the first stage, production time is predicted using an ANN model based on variables such as order quantity, product type, stock level, and labor utilization ($R^2 = 0.91$, MAPE = 8.7%). In the second stage, the predicted values are utilized in a GA-based optimization process to achieve a balanced assignment of orders to three production lines under capacity constraints. The GA model, operating through evolutionary operators (selection, crossover, and mutation), minimizes workload imbalance and improves overall scheduling efficiency. Comparative analyses indicate that the proposed approach reduces average production time by 18.6%, delivery

delays by 45.6%, and total labor costs by 11.9% compared to the manual planning method. Consequently, the developed ANN–GA-based model is evaluated as a low-cost, applicable decision-support tool that contributes to the digital transformation process of small and medium-sized enterprises (SMEs).

To Cite: Tümay Ateş K. Dijital Dönüşüm Sürecinde Akıllı Üretim Planlama: Yapay Sinir Ağları ve Genetik Algoritma Bütünleşik Yaklaşımı. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 2026; 9(3): 1696-1707.

1. Giriş

Küresel rekabetin hızla arttığı günümüz endüstriyel ekosisteminde, üretim planlama süreçlerinin etkinliği işletmelerin sürdürülebilirliği ve rekabet gücü açısından kritik bir rol oynamaktadır. Üretim hatlarının dengeli şekilde çalıştırılması, teslimat sürelerinin kısaltılması ve kaynak kullanım verimliliğinin artırılması, özellikle küçük ve orta ölçekli işletmeler (KOBİ) için stratejik öncelikler arasında yer almaktadır. Ancak geleneksel üretim planlama yöntemleri, karmaşık ve dinamik üretim koşullarında optimal sonuçlar üretmekte yetersiz kalmaktadır (Pinedo, 2016). Bu nedenle, yapay zeka (YZ) tabanlı modelleme ve optimizasyon teknikleri, son yıllarda üretim sistemlerinin karar destek süreçlerinde yaygın biçimde kullanılmaya başlanmıştır (Del Gallo ve ark., 2023).

Yapay sinir ağları (YSA), doğrusal olmayan ve çok değişkenli sistemlerin modellenmesinde önemli bir araç olarak görülmektedir. Özellikle üretim süresi, iş gücü tahmini ve operasyonel performans göstergelerinin öngörülmesinde YSA'nın yüksek doğruluk oranları sunduğu belirtilmektedir (Akyol ve Bayhan, 2007). Son yıllarda yapılan çalışmalar, YSA ve benzeri derin öğrenme modellerinin üretim süresi tahmininde artan doğruluk ve azalan belirsizlik düzeyleriyle umut verici sonuçlar ortaya koyduğunu göstermektedir (Wang ve ark., 2024). Örneğin, dikkat mekanizmalı ağ yapılarının üretim süresi tahmininde hata oranlarını önemli ölçüde düşürdüğü belirlenmiştir. YSA'nın geçmiş verilerden öğrenme yeteneği sayesinde süreçlerdeki gizli ilişkileri yakalayarak tahminleme doğruluğunu artırdığı ve üretim planlama kararlarının güvenilirliğini yükselttiği vurgulanmaktadır.

Optimizasyon aşamasında ise genetik algoritma (GA) gibi evrimsel hesaplama yöntemleri, geniş çözüm uzaylarında global optimuma yakın çözümler üretebilme yetenekleriyle öne çıkmaktadır (Goldberg, 1989). GA, üretim planlama ve çizelgeleme problemlerinde hem hesaplama verimliliği hem de esnekliği nedeniyle sıklıkla tercih edilmekte; literatürde iş yükü dengeleme, üretim hattı ataması ve teslimat süresi minimizasyonu gibi problemlerde başarılı sonuçlar verdiği gösterilmektedir (Gen ve Cheng, 2020). Ayrıca, hibrit metasezgisel yaklaşımların üretim ortamındaki çoklu kısıtlar altında da etkin çözümler ürettiği ve GA'nın bu kapsamda en uyarlanabilir yöntemlerden biri olduğu ifade edilmektedir (Roeva ve ark., 2024). Ojstersek ve ark., (2020) evrimsel hesaplama tabanlı yaklaşımların bu tür problemlerde yüksek çözüm kalitesi ve esneklik sunduğunu, özellikle hibrit modellerin performans açısından öne çıktığını belirtmiştir. Diğer yandan, Huang (1999), yarı iletken üretiminde yapay sinir ağları ile üretim performansını tahmin etmeye yönelik bir sistem geliştirerek, bu yöntemin karmaşık üretim süreçlerinde doğruluk ve karar desteği açısından önemli avantajlar sunduğunu ortaya koymuştur. Bu çalışmalar,

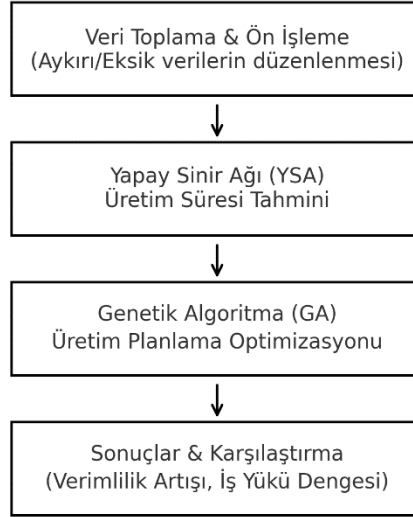
üretim sistemlerinin optimizasyonunda yapay zekâ tabanlı yöntemlerin bütünleşik kullanımının giderek artan bir eğilim olduğunu göstermektedir.

Son dönemde yapılan araştırmalar, YSA ve GA yöntemlerinin entegrasyonunun üretim planlama süreçlerinde hibrit bir yapay zeka çerçevesi sunduğunu ortaya koymaktadır. Zhang ve arkadaşları (2021), üretim çizelgeleme problemlerine yönelik genetik programlama (GP) yaklaşımını sistematik biçimde ele almıştır. Springer tarafından yayımlanan bu kapsamlı kitapta, GP'nin karmaşık çizelgeleme ortamlarında kural keşfi, dinamik karar verme ve çok amaçlı optimizasyon için nasıl kullanılabileceği açıklanmıştır. Çalışma, üretim çizelgelemede geleneksel genetik algoritmalarından farklı olarak, GP'nin doğrudan çizelgeleme kurallarını evrimleştirerek yeni, uyarlanabilir karar stratejileri geliştirdiğini göstermektedir. Benzer şekilde, Georgy ve Basily (2008), inşaat projelerinde malzeme teslimat planlarını optimize etmek amacıyla genetik algoritma tabanlı bir model geliştirmiştir. Çalışma, lojistik kısıtlar ve tedarik belirsizliklerini dikkate alarak maliyet ve süre optimizasyonu sağlamış, genetik algoritmaların karmaşık inşaat planlama problemlerinde etkili ve esnek çözümler sunduğunu göstermiştir. Güncel çalışmalarda da, LSTM ağlarının GA ile entegre edilerek çizelgeleme sürecinin hesaplama verimliliğini artırdığı ve tahminleme ile optimizasyonun bütünleşik olarak yürütülmesinin üretim performansını geliştirdiği gösterilmiştir (Bubak ve ark., 2025). Mahmud (2023), tedarik zinciri ve üretim çizelgeleme süreçlerinin entegrasyonunun sistem verimliliğini artırdığını göstermiş; hibrit optimizasyon yaklaşımlarının bu alanda etkili çözümler sunduğunu belirtmiştir. Kamble ve ark., (2023) yapay zekâ temelli karar destek sistemlerinin akıllı üretim ortamlarında dijital dönüşümün temel itici unsurlarından biri olduğunu vurgulamaktadır. Bu bağlamda, önerilen modelin KOBİ'ler için uygulanabilir bir dijital dönüşüm aracı sunduğu söylenebilir.

Bu çalışma, literatürdeki bu yaklaşımlardan esinlenerek İstanbul'da faaliyet gösteren orta ölçekli bir makine üretim tesisinde üretim planlama sürecini YSA ve GA yöntemlerinin bütünleşik kullanımıyla optimize etmeyi amaçlamaktadır. Geliştirilen model, üretim süresinin YSA ile tahmin edilmesi ve bu tahminlerin GA aracılığıyla üç üretim hattına optimal biçimde dağıtılması esasına dayanmaktadır.

2. Materyal ve Metot

Bu çalışmada, İstanbul'da faaliyet gösteren orta ölçekli bir makine üretim tesisinde üretim planlama süreçlerinin yapay zeka destekli yöntemlerle optimize edilmesi amaçlanmıştır. Bu amaç doğrultusunda iki aşamalı bir metodolojik yaklaşım benimsenmiştir. İlk aşamada üretim süresinin öngörülmesi için YSA tabanlı bir tahmin modeli geliştirilmiş; ikinci aşamada ise bu tahmin değerleri kullanılarak üretim hattı atamalarının GA temelli optimizasyonu gerçekleştirilmiştir. Şekil 1'de önerilen yöntemin uygulama akış şeması görülmektedir.



Şekil 1. Önerilen Yöntem için Uygulama Akış Şeması

2.1. Yapay Sinir Ağı (YSA) Optimizasyon Yöntemi

Bu çalışmada üretim süresinin öngörülmesi amacıyla geliştirilen yapay sinir ağı modeli, denetimli öğrenme yaklaşımına dayalı, ileri beslemeli çok katmanlı ağ mimarisisiyle tasarlanmıştır. Model, geçmiş 12 aylık üretim verileri üzerinde eğitilmiş olup, giriş katmanında üretim performansını doğrudan etkileyen sipariş adedi, ürün tipi, stok miktarı ve iş gücü kullanımı olmak üzere dört bağımsız değişken yer almaktadır: Bu değişkenler sırasıyla üretim yükünü, ürün çeşitliliğini, hammadde mevcudiyetini ve insan kaynağı kullanım düzeyini temsil etmekte olup, modelin tahmin doğruluğu açısından kritik girdiler olarak değerlendirilmiştir.

Modelin çıktı katmanında ise bağımlı değişken olarak tahmini üretim süresi (saat) yer almaktadır. Böylece ağ, verilen girdi kombinasyonlarına karşılık olarak üretim süresini nicel biçimde tahmin edebilmektedir. Ağ mimarisi, dört nöronlu bir giriş katmanı, beş nöronlu tek gizli katman ve bir nöronlu çıkış katmanından oluşmaktadır. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu tercih edilmiş; bu sayede model, doğrusal olmayan ilişkileri yakalayabilme kapasitesine sahip olmuştur. Modelin ağırlıkları, Excel Solver aracılığıyla geriye yayılım algoritması mantığında optimize edilmiş, hata kareleri toplamı (SSE) minimize edilerek öğrenme süreci tamamlanmıştır. Elde edilen tahmin fonksiyonu aşağıdaki şekilde formüle edilmiştir:

$$\hat{Y} = \sum_{j=1}^5 v_j \sigma \left(\sum_{i=1}^4 w_{ij} x_i \right) + b_0 \quad (1)$$

Burada \hat{Y} , tahmini üretim süresini; x_i terimleri modelin giriş değişkenlerini; w_i değerleri her değişkene ait ağırlıkları ve b ise bias terimini ifade etmektedir. Modelin performans değerlendirmesi, eğitim ve test verileri üzerinden gerçekleştirilmiştir.

2.2. Genetik Algoritma Optimizasyon Yöntemi

Yapay sinir ağı modelinden elde edilen üretim süresi tahminleri, çalışmanın ikinci aşaması olan üretim planlama optimizasyonunda kullanılmıştır. Bu aşamada, siparişlerin üç farklı üretim hattına nasıl dağıtılacağı belirlenmesi, evrimsel hesaplama temelli bir yaklaşım olan GA yöntemiyle gerçekleştirilmiştir. GA, biyolojik evrim prensiplerine dayanan ve büyük çözüm uzaylarında optimal veya optimal yakınsama sağlayan bir meta-sezgisel optimizasyon tekniğidir (Goldberg, 1989). Optimizasyon problemi, her siparişin yalnızca bir iş istasyonuna atanabileceği ve siparişlerin parçalanamayacağı bir atama yapısı şeklinde tanımlanmıştır. Ayrıca her iş istasyonunun kapasitesi 300 saat ile sınırlandırılmıştır. Amaç fonksiyonu, üretim hatları arasındaki toplam iş yükü dengesizliğini ve maksimum yük farkını minimize etmeye yöneliktir. Bu kapsamda uygunluk fonksiyonu aşağıdaki biçimde formüle edilmiştir:

$$\text{Fitness} = \frac{1}{(\max(S_1, S_2, S_3) + \lambda \cdot \text{Dengesizlik})} \quad (2)$$

Burada S_i , i . iş istasyonunun toplam iş yükünü, λ ise dengesizlik bileşeninin göreceli ağırlığını ifade etmektedir. Bu fonksiyon, iş yükü dengesini iyileştiren çözümlere daha yüksek uygunluk değerleri atayarak arama sürecini yönlendirmiştir. Parametre değeri, ön deneme çalışmalarıyla iş yükü dengesi ve yakınsama davranışı göz önünde bulundurularak belirlenmiştir. λ parametresi 0.5 olarak belirlenmiş olup, farklı değerler üzerinde yapılan ön denemeler sonucunda iş yükü dengesini en iyi sağlayan değer olarak seçilmiştir. Genetik algoritma süreci, rastgele oluşturulmuş 50 bireyden oluşan başlangıç popülasyonu ile başlatılmıştır. Her birey, siparişlerin üretim hatlarına atanma sırasını temsil eden bir üretim planı olarak değerlendirilmiştir. Her nesilde, uygunluk değeri en yüksek olan bireyler seçilmiş, çaprazlama işlemi ile yeni bireyler üretilmiş ve popülasyonun %10'u oranında mutasyon uygulanarak çözüm çeşitliliği korunmuştur. Bu evrimsel süreç toplam 200 nesil boyunca tekrarlanmış ve her nesilde en iyi birey kaydedilerek yakınsama eğrisi izlenmiştir. Algoritmanın yakınsama davranışı, 150. nesilden sonra uygunluk fonksiyonu değerlerinde durağanlaşma eğilimi göstermiştir. Bu durum, modelin küresel optimuma yakın bir çözüme ulaştığını ve parametre ayarlarının uygun biçimde belirlendiğini göstermektedir.

2.3. Yapay Sinir Ağı Modelleme Süreci

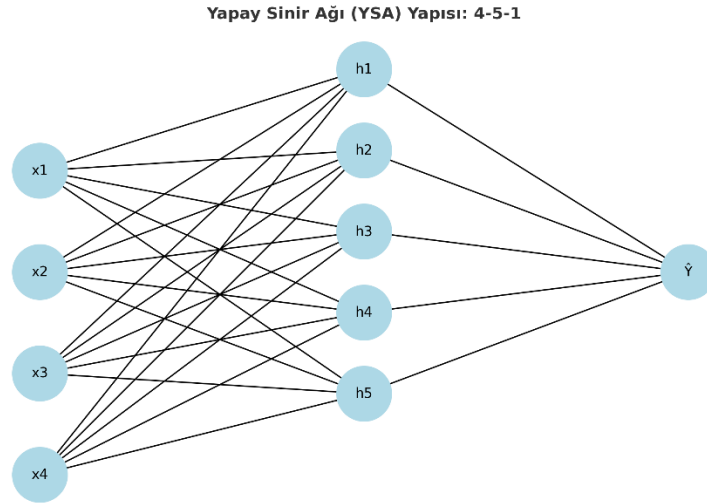
2.3.1. Modelin Genel Yapısı

Bu çalışmada üretim süresinin tahmin edilmesi amacıyla ileri beslemeli çok katmanlı algılayıcı yapısında bir YSA modeli geliştirilmiştir. Model, geçmiş 12 aylık üretim verilerinden öğrenerek sipariş bazında üretim süresini tahmin edecek şekilde yapılandırılmıştır (Şekil 2). Ağ yapısı; dört nöronlu giriş katmanı, beş nöronlu tek gizli katman ve bir nöronlu çıkış katmanı olmak üzere üç katmandan oluşmaktadır.

Giriş katmanındaki değişkenler, üretim sisteminin temel girdilerini temsil etmektedir:

- x_1 : Sipariş adedi – üretim yükünü belirler.
 - x_2 : Ürün tipi – üretim sürecinin karmaşıklığını etkiler.
 - x_3 : Stok miktarı – üretim hazırlık süresiyle ilişkili bir faktördür.
 - x_4 : İş gücü – üretim süresine doğrudan etki eden bir emek girdisidir.

Modelin çıktısı, bu değişkenlerin etkileşimi sonucunda tahmin edilen üretim süresi (\hat{Y}) değeridir.



Şekil 2. Modelin YSA Ağ Yapısı

Aynı zamanda ürün tipi değişkeni (A, B ve C), yapay sinir ağı modeline one-hot encoding yöntemiyle sayısallaştırılarak dahil edilmiştir.

2.3.2. Modelin Matematiksel Gösterimi

Yapay sinir ağının çalışma prensibi, giriş değişkenlerinden elde edilen ağırlıklı toplamların bir aktivasyon fonksiyonuna uygulanmasıyla gerçekleşir. Gizli katmandaki her bir nöronun net girdisi aşağıdaki şekilde ifade edilir (Haykin, 1999):

$$Z_j = \left(\sum_{i=1}^4 w_{ij} x_{ij} \right) + b_j, j=1,2,3,4,5 \quad (3)$$

Burada w_{ij} her bir girdi değişkeni ile gizli nöron arasındaki bağlantı ağırlığını, b_j ise bias terimini göstermektedir. Aktivasyon fonksiyonu olarak doğrusal olmayan ilişkileri öğrenebilme yeteneği nedeniyle sigmoid fonksiyonu tercih edilmiştir (Bishop, 2006):

$$h_j = \sigma(Z_j) = \frac{1}{1 + e^{-z_j}} \quad (4)$$

Bu işlemin ardından gizli katmandan çıkan aktivasyon değerleri, çıkış katmanına iletilir ve tahmini üretim süresi şu şekilde hesaplanır:

$$Y' = \sum_{i=1}^5 v_j h_j + b_0 \quad (5)$$

Burada v_j , gizli katmandaki j . nöron ile çıkış katmanı arasındaki ağırlığı, b_0 ise çıkış katmanına ait bias terimini göstermektedir. Elde edilen tahmini değer (Y'), her siparişin tamamlanma süresine ilişkin öngörü değeridir.

2.3.3. Modelin Eğitimi ve Performans Ölçümü

Modelin öğrenme süreci, Excel Solver aracı kullanılarak geri yayılım algoritması mantığında gerçekleştirilmiştir. Veri seti, modelin genelleme kabiliyetini değerlendirmek amacıyla %70 eğitim ve %30 test verisi olacak şekilde rastgele bölünmüştür. Solver, hata fonksiyonu olarak tanımlanan ortalama karesel hatayı (MSE) minimize edecek şekilde ağırlık değerlerini optimize etmiştir:

$$E = 1/n (\sum_{i=1}^n y_k - y'_k)^2 \quad (6)$$

Bu süreçte ağırlık parametreleri güncellenmiş, her iterasyonda tahmin hatası azaltılarak modelin yakınsaması sağlanmıştır. Modelin doğruluk performansı R^2 ve Ortalama mutlak yüzde hata (MAPE) olmak üzere iki temel ölçütle değerlendirilmiştir:

2.3.4. Model Parametre Seçimi

Modelin mimarisi belirlenirken, farklı gizli katman nöron sayıları (3–8 arası) denenmiş ve elde edilen sonuçlar karşılaştırmalı olarak analiz edilmiştir. Deneysel değerlendirmeler sonucunda, 5 nöronlu yapı, MSE değerini en düşük, R^2 değerini ise en yüksek düzeyde gerçekleştirmiştir. Bu yapı, modelin karmaşıklığı ile tahmin doğruluğu arasında en uygun dengeyi sağlayarak aşırı uyum riskini minimize etmiştir. Dolayısıyla 5 gizli nöronun seçilmesi, hem giriş değişkenlerinin sayısına hem de veri setinin ölçeğine göre optimum hata düzeyini ve genel genelleme kabiliyetini sunmuştur. Elde edilen bulgular, daha az veya daha fazla nöron içeren alternatif yapılara kıyasla bu konfigürasyonun daha yüksek doğruluk ve daha düşük hata oranı sağladığını ortaya koymuştur. Modelleme sürecinde kullanılan tüm parametreler, ağ mimarisi, optimizasyon kısıtları ve performans ölçütleri ayrıntılı biçimde tanımlanmış; böylece deneysel kurgunun anlaşılabilirliği ve yeniden uygulanabilirliği desteklenmiştir.

3. Bulgular

Bu bölümde, yapay zeka destekli üretim planlama modelinin uygulanması sonucu elde edilen bulgular ayrıntılı biçimde sunulmaktadır. Çalışmanın amacı doğrultusunda, YSA modeliyle tahmin edilen üretim süreleri, GA tabanlı optimizasyon sürecine entegre edilerek üretim hatları arasında dengeli bir iş yükü dağılımı sağlanmıştır. Analiz, modelin tahmin doğruluğu, üretim sürelerinin optimize edilme düzeyi ve manuel planlama yöntemine kıyasla performans iyileşmelerini karşılaştırmalı olarak ortaya koymaktadır. Böylece, üretim süreçlerinde veri odaklı ve öğrenilebilir bir planlama mekanizmasının nasıl daha etkin sonuçlar üretebileceği ampirik olarak değerlendirilmiştir. Deneysel tasarım kapsamında,

YSA modelinin tahmin performansı eğitim ve test verileri üzerinde değerlendirilmiş; GA optimizasyon süreci ise yakınsama davranışı ve iş yükü dengesi açısından analiz edilmiştir.

Tablo 1, araştırma kapsamında kullanılan değişkenleri, bunların türsel özelliklerini ve analizde üstlendikleri rolleri sistematik biçimde ortaya koymaktadır. Çalışmada, üretim süresinin öngörülmesinde bağımlı değişken olarak üretim süresi tanımlanmış; bu değişkenin tahmini amacıyla dört temel bağımsız değişken kullanılmıştır: sipariş adedi, ürün tipi, stok miktarı ve iş gücü kullanımı. Söz konusu değişkenler, üretim sisteminin operasyonel yükünü, kaynak kullanım düzeyini ve ürün çeşitliliğini temsil etmektedir.

Tablo 1. Kullanılan Değişkenler ve Tanımları

Değişken	Açıklama
Sipariş Adedi	Bir siparişte üretilmesi gereken ürün miktarı
Ürün Tipi	Ürünün tipi (A, B, C)
Stok Miktarı	Mevcut stok durumu
İş Gücü Kullanımı	Üretim için harcanan işçilik süresi
Üretim Süresi	YSA modelinde tahmin edilmek istenen hedef değişken

Tablo 2, geliştirilen YSA modelinin performans göstergelerini sunmaktadır. Modelin eğitim ve test verisi üzerinde elde ettiği MAPE ve R^2 değerleri, modelin yüksek tahmin doğruluğu düzeyine ulaştığını göstermektedir. Özellikle $R^2 \approx 0.91$ değeri, modelin üretim süresi değişkenini açıklamada güçlü bir doğrusal ilişki yakaladığını göstermektedir. Bu sonuç, YSA modelinin üretim planlama süreçlerinde kullanılabilir bir öngörülme araç olduğunu ortaya koymaktadır.

Tablo 2. YSA Model Performans Sonuçları

Veri Seti	MAPE (%)	R^2	Ortalama (Saat)	Hata	Doğruluk (%)	Oranı
Eğitim Verisi	9.5	0.92	0.38		90.5	
Test Verisi	8.7	0.91	0.34		91.3	

Model performansı, tahmin edilen üretim sürelerinin gözlenen değerlere yakınlığını göstermekte olup, $R^2 \approx 0.91$ seviyesinde güçlü bir tahmin kapasitesi sunmuştur.

Tablo 3, GA tabanlı üretim planlama sürecinde kullanılan temel parametreleri özetlemektedir. Başlangıç popülasyonu, nesil sayısı, çaprazlama ve mutasyon oranları, algoritmanın arama uzayındaki çeşitliliğini

ve yakınsama hızını belirleyen temel kontrol parametreleridir. Ayrıca, maksimum iş istasyonu kapasitesi kısıtı altında uygunluk fonksiyonunun tanımlanması, üretim hatları arasında iş yükü dengesini optimize etmeye yöneliktir. Bu parametrelerin uygun şekilde belirlenmesi, GA'nın çözüm kalitesini ve optimizasyon başarısını doğrudan etkilemektedir.

Tablo 3. GA Optimizasyon Sürecinin Temel Parametreleri

Parametre	Değer
Başlangıç Popülasyonu	50
Nesil Sayısı	200
Çaprazlama Oranı	%70
Mutasyon Oranı	%10
Maksimum İş İstasyonu Kapasitesi	300 saat
Uygunluk Fonksiyonu	$1 / (\max(S1,S2,S3) + \lambda \cdot \text{Dengesizlik})$

Tablo 4, yapay zeka destekli planlama modeli ile firmanın mevcut manuel üretim planlama yönteminin performans karşılaştırmasını göstermektedir. Sonuçlar, önerilen modelin ortalama üretim süresi, maksimum iş yükü, teslimat gecikme oranı, malzeme israfı ve toplam işçilik maliyeti gibi göstergelerde önemli iyileşmeler sağladığını ortaya koymaktadır. Bu bulgular, geliştirilen yaklaşımın üretim verimliliğini artırmakla kalmayıp aynı zamanda kaynak kullanım dengesini de optimize ettiğini göstermektedir.

Tablo 4. Üretim Planlama Sonuçlarının Karşılaştırması

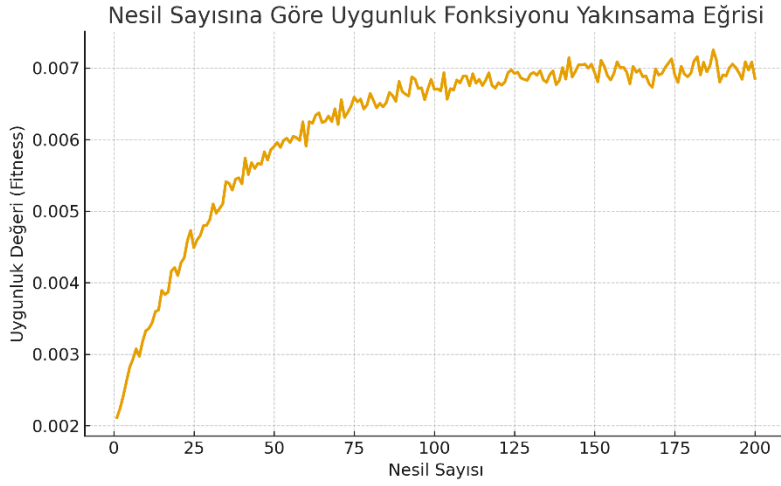
Performans Ölçütü	Mevcut (Manuel) Yöntem	Yapay Zeka Destekli Yöntem	İyileşme (%)
Ortalama Üretim Süresi (saat)	118	96	+18.6
Maksimum İş Yükü (saat)	310	276	+11.0
Teslimat Gecikme Oranı (%)	12.5	6.8	+45.6
Malzeme İsrافی (adet)	42	27	+35.7
Toplam İşçilik Maliyeti (€)	18,400	16,200	+11.9

Yapay zeka tabanlı planlama yaklaşımı, manuel planlamaya kıyasla üretim süresini kısaltmış, iş yükünü daha dengeli dağıtmış ve operasyonel maliyetleri azaltmıştır. Tablo 5, genetik algoritmanın yakınsama davranışını nicel olarak ortaya koymaktadır. Nesil sayısı arttıkça en iyi ve ortalama uygunluk

değerlerinin birbirine yaklaşması, algoritmanın istikrarlı bir çözüme ulaştığını göstermektedir. Bu durum, parametrelerin uygun biçimde ayarlandığını ve algoritmanın küresel optimuma yakın bir çözümü başarıyla yakaladığını göstermektedir.

Tablo 5. GA Optimizasyonunun Yakınsama Analizi

Nesil	En İyi Uygunluk Değeri	Ortalama Uygunluk	Standart Sapma
1	0.0023	0.0017	0.0004
50	0.0051	0.0042	0.0006
100	0.0064	0.0057	0.0003
150	0.0069	0.0061	0.0002
200	0.0071	0.0068	0.0001



Şekil 3. Nesil Sayısına Göre Uygunluk Fonksiyonu Yakınsama Eğrisi

Şekil 3, genetik algoritmanın 200 nesil boyunca yakınsama sürecini göstermektedir. Erken nesillerde uygunluk değerleri hızla artarken, 150. nesilden sonra artışın yavaşladığı ve modelin stabil bir çözüme ulaştığı görülmektedir.

4. Tartışma ve Sonuç

Bu çalışmada geliştirilen yapay zeka tabanlı üretim planlama modeli, küçük ve orta ölçekli üretim işletmelerinde dijital dönüşüm sürecine katkı sunabilecek pratik ve uygulanabilir bir karar destek aracı olarak değerlendirilmektedir. Çalışmanın özgün yönü, YSA ve GA yöntemlerinin Excel tabanlı, düşük maliyetli bir uygulama ortamında bütünleşik biçimde ele alınması ve tahmin ile optimizasyon süreçlerinin tek bir karar destek çerçevesi altında birleştirilmesidir. YSA modeli, geçmiş üretim ve sipariş verilerinden öğrenerek üretim süresini yüksek doğrulukla tahmin etmiş; elde edilen bu tahminler GA tabanlı optimizasyon sürecine girdi olarak kullanılarak üretim hatları arasında daha dengeli bir iş yükü dağılımı sağlanmıştır. Elde edilen bulgular, YSA modelinin üretim süresini yaklaşık %91

doğrulukla öngörebildiğini, GA algoritmasının ise maksimum kapasite dengesizliğini %11 oranında azalttığını göstermekte; bu durum hibrit yapay zeka modellerinin yalnızca tahmin doğruluğunu değil, aynı zamanda üretim sürecinin genel verimliliğini de artırdığını ortaya koymaktadır. Literatürdeki benzer çalışmalarla karşılaştırıldığında, önerilen yaklaşımın özellikle veri miktarının sınırlı olduğu küçük ölçekli işletmelerde, yüksek maliyetli yazılım altyapılarına ihtiyaç duyulmadan uygulanabilir olması önemli bir avantaj olarak öne çıkmaktadır. Bubak ve ark., (2025) tarafından önerilen LSTM tabanlı genetik algoritma yaklaşımı, tahmin ve optimizasyon süreçlerinin bütünleşik ele alınmasının üretim ve tedarik planlama performansını önemli ölçüde artırdığını ortaya koymaktadır. Bu çalışma kapsamında geliştirilen YSA–GA tabanlı model de benzer biçimde, üretim süresi tahmini ile planlama optimizasyonunu tek bir karar destek çerçevesinde birleştirerek hibrit yapay zeka yaklaşımlarının üretim sistemlerindeki potansiyelini doğrulamaktadır. Li ve ark. (2023), üretim çizelgeleme problemlerinde yapay sinir ağları ile genetik algoritmaların bütünleşik kullanımının, kapasite kısıtları altında daha dengeli ve etkin çözümler ürettiğini göstermiştir. Bu bulgu, çalışmamızda önerilen YSA–GA tabanlı yaklaşımın üretim planlama süreçlerindeki etkinliğini destekler niteliktedir. Bununla birlikte, çalışmada kullanılan genetik algoritma parametreleri (popülasyon büyüklüğü, nesil sayısı, çaprazlama ve mutasyon oranları), literatürde yaygın kabul gören değerler esas alınarak belirlenmiş olup, bu parametrelerin farklı kombinasyonlar altındaki davranışlarının incelenmesi modelin performansını daha da iyileştirme potansiyeli taşımaktadır. Benzer şekilde, veri setinin daha uzun bir zaman aralığını kapsayacak şekilde genişletilmesi, mevsimsellik etkilerinin modele daha etkin biçimde yansıtılmasına olanak sağlayacaktır. Üretim sürecindeki insan faktörü, makine arızaları ve dış tedarik gecikmeleri gibi dinamik unsurların ise, bulanık mantık, pekiştirmeli öğrenme veya stokastik optimizasyon yaklaşımlarıyla modele entegre edilmesi, sistemin gerçek üretim ortamlarına uyum kabiliyetini artıracak önemli bir gelişim alanı olarak değerlendirilmektedir.

Kaynakça

- Akyol DE., Bayhan GM. A review on evolution of production scheduling with neural networks. *Computers & Industrial Engineering* 2007; 53(1): 95-122.
- Bishop CM. *Pattern recognition and machine learning*. New York, NY: Springer 2006.
- Bubak A., Rolf B., Reggelin T., Lang S., Stuckenschmidt H. An LSTM network-based genetic algorithm for integrated procurement and scheduling optimisation. *International Journal of Production Research* 2025; 63(11): 4036-4065.
- Del Gallo M., Mazzuto G., Ciarapica FE, Bevilacqua M. Artificial intelligence to solve production scheduling problems in real industrial settings: A systematic literature review. *Electronics* 2023; 12(23): 4732.
- Gen M., Cheng R. *Genetic algorithms and engineering optimization*. Hoboken, NJ: John Wiley & Sons 2020.

- Georgy M., Basily SY. Using genetic algorithms in optimizing construction material delivery schedules. *Construction Innovation* 2008; 8(1): 23-45.
- Goldberg DE. *Genetic algorithms in search, optimization, and machine learning*. Reading, MA: Addison-Wesley 1989.
- Haykin S. *Neural networks: A comprehensive foundation* (2nd ed.). Upper Saddle River, NJ: Prentice Hall 1999.
- Huang CL. The construction of production performance prediction system for semiconductor manufacturing with artificial neural networks. *International Journal of Production Research* 1999; 37(6): 1387-1402.
- Kamble SS., Gunasekaran A., Sharma R. Analysis of the driving and dependence power of Industry 4.0 technologies in smart manufacturing. *Technological Forecasting and Social Change* 2023; 187: 122211.
- Li J., Wang Y., Zhang X. A hybrid artificial neural network and genetic algorithm approach for production scheduling under capacity constraints. *Expert Systems with Applications* 2023; 213: 118935.
- Mahmud S. *Modelling and optimizing supply chain integrated production scheduling problems*. University of New South Wales (Australia) 2023.
- Ojstersek R., Brezocnik M., Buchmeister B. Multi-objective optimization of production scheduling with evolutionary computation: A review. *International Journal of Industrial Engineering Computations* 2020; 11(3): 359-376.
- Pinedo M. *Scheduling: Theory, algorithms, and systems*. New York, NY: Springer 2016.
- Roeva O., Zoteva D., Roeva G., Ignatova M., Lyubenova V. An effective hybrid metaheuristic approach based on the genetic algorithm. *Mathematics* 2024; 12(23): 3815.
- Wang L., Liu H., Xia M., Wang Y., Li M. A machine learning-based EMA-DCPM algorithm for production scheduling. *Scientific Reports* 2024; 14(1): 20810.
- Zhang F., Nguyen S., Mei Y., Zhang M. *Genetic programming for production scheduling*. Singapore: Springer 2021.