



Giyisi Endüstrisinde Üretim Performansının Tahmininde Yapay Sinir Ağlarının Kullanılması

Cengiz Sertkaya^{1*}, Samet Akçay²

^{1*} Ostim Teknik Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, Ankara, Türkiye, (ORCID: 0000-0001-7459-2473),

cengiz.sertkaya@ostimteknik.edu.tr

² Ostim Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yazılım Mühendisliği Anabilim Dalı, Ankara, Türkiye (ORCID: 0000-0001-5646-0629),

200801008@ostimteknik.edu.tr

(1st International Conference on Applied Engineering and Natural Sciences ICAENS 2021, November 1-3, 2021)

(DOI: 10.31590/ejosat.979656)

ATIF/REFERENCE: Sertkaya, C. & Akçay, S. (2021). Giysi Endüstrisinde Üretim Performansının Tahmininde Yapay Sinir Ağlarının Kullanılması. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 34-39.

Öz

Digitalleşme çağında işletmeler kendilerini yeni teknolojilere adapte etmek istemektedirler. Bu yeni teknolojilere uyum sağlamak, verimlilik ve karlılığı arttırmak için verilerin işlenmesi ve akıllı karar verme sistemleri ile durumun analiz edilmesine ihtiyaç vardır. Özellikle büyük bir üretim hacmine sahip olan giysi endüstrisinde hem geleneksel işlemlerin devam etmesi hemde iş akışlarının insan performansına doğrudan bağlı olması verimliliği önemli bir ölçüde etkilemektedir. Böylece beklenen performans değerleri ile gerçek çıktılar arasında ciddi farklar görülmektedir.

Bu çalışmada veri madenciliği teknikleri uygulanarak örnek bir giysi endüstrisinde yer alan bir işletmeye ait veriler üzerinde analizler yapılmıştır. Bu işletmede işçilerin çalışma durumları incelenerek gerçek üretim performansını tahmin etmeye yönelik bir yapay sinir ağı modeli oluşturulmuştur. Sonuçlar incelendiğinde %85 doğruluk değerine ulaşılmıştır. Modelin işletmelerin gerekli düzeltmeler ile üretim performanslarını ve verimliliklerini artırmasına ve aynı zamanda kayıpları minimum seviyeye indirmesine katkı sunacağı gösterilmiştir.

Anahtar Kelimeler: Üretim Performansı, Tahmin, Yapay Sinir Ağları

Using Artificial Neural Networks in Prediction of Production Performance in the Garment Industry

Abstract

In the age of digitalization, businesses want to adapt themselves to new technologies. In order to adapt to these new technologies and increase efficiency and profitability, there is a need for data processing and analysis of the situation with intelligent decision-making systems. Especially in the garment industry, which has a large production volume, both the continuation of traditional processes and the direct dependence of work flows on human performance affect productivity significantly. Thus, there are serious differences between the expected performance values and the actual outputs.

In this study, data mining techniques were applied and analyzes were made on the data of a business in a garment industry. In this enterprise, an artificial neural network model was created to predict the real production performance by examining the working conditions of the workers. When the results were examined, an accuracy value of 85% was reached. It has been shown that the model will contribute to increasing the production performance and efficiency of the enterprises with the necessary corrections and at the same time reducing the losses to the minimum level.

Keywords: Production Performance, Prediction, Artificial Neural Networks

* Sorumlu Yazar: cengiz.sertkaya@ostimteknik.edu.tr

1. Giriş

Günümüzde gelişen teknoloji ile nesnelerin interneti, verilerin kayıt edilmesi ve optimizasyon gibi kavramlar hayatımızın ayrılmaz bir parçası olmuştur. Endüstride sıklıkla gördüğümüz bu uygulamalar hem işletmelerin iş akışlarında iyileşme hemde kaynakların verimli kullanılmasını sağlamaktadır(Zhiqiang ve diğer. 2017). Türkiye ekonomisinde 11 milyar dolar üzerinde ihracat hacmine sahip giysi endüstrisi dünyada 60 milyondan fazla çalışan sayısıyla optimizasyon ve kaynak yönetiminin direk uygulama alanı olarak konumlandırılmaktadır(Bashimov 2014)(Lai ve Christiani 2013).

Giysi endüstrisi ağırlıklı olarak sıralı proseslere dayanmaktadır. Bu prosesler en temelde tasarım, örnek doğrulama, tedarik, hat planı, market planlama, dağıtma ve kesme, dikim, yıkama, nihai işlem ve paketlemeden oluşmaktadır(Rahim ve diğer. 2021)(Lee ve diğer. 2016). Halihazırda bu sektörde bir çok işlem manuel olarak yapılmaktadır. Bunun en önemli sebebi proseslerin hemen her bölümünde insana dayalı kısımların bulunmasıdır. Bahsedilen bu kısımlar verilerin kaydedilmesi, saklanması, işlenmesi ve verilerin yorumlanmasıdır. Bu işlemler günümüzde klasik yöntemler; örneğin çeklist, veri giriş formları gibi yöntemler kullanılarak gerçekleştirilmektedir.

Veriler digital ortama aktarılmadığından dolayı çalışanların günlük ve periyodik çalışma istekleri, gelirleri, teşvik ve primleri, psikolojik durumları, kültürleri, ekip çalışmasına yatkınlıkları ve iletişim becerileri gibi etmenler efektif bir biçimde takip edilememektedir. Böylece işletmeler girdiler, çıktılar ve verimlilik arasındaki ilişkiyi doğru kuramamakta ve üretim performanslarını arttıramamaktadırlar. Manuel yöntemlerle yapılan bu işlemleri pratik bir şekilde yapmak, iş gücünü azaltmak ve verimliliği arttırmak için veri madenciliği ve yapay zeka teknolojilerinden yararlanılmaktadır(Wiççek ve diğer. 2019).

Literatürde Danimarkada yapılan bir çalışmada, işçilerin çalışma ortamında karşılaştıkları sorunların işçi performansına ve iş bırakma oranlarına etkisi incelenmiştir. Bu çalışmada sonuç olarak ilk 5 yıl içinde firmalarını terk ettikleri tespit edilmiştir. Bu oranın %18 olarak bulunmuştur(Cottini ve diğer. 2011). İşe alım ve sosyal ekonomik duruma doğrudan etki eden endüstri alanı özelinde, Bangladeş'te yapılan bir çalışmada giysi endüstrisinde işçilerin yetenek durumu, doğru olmayan çalışma ortamı, sosyal uyumluluk gibi başlıca etkenlerin üretim performansına olan etkileri incelenmiştir. Çalışmada sadece %14 oranında iyi şartlarda olan giysi işçileri ile toplam ihracatın %81'i yapılmaktadır(Islam ve diğer. 2016).

Hibrit internet tabanlı analiz ve veri madenciliği yöntemi ile hata örüntüleri üzerine yapılan bir çalışmada akıllı kalite yönetim sistemi oluşturulmuştur(Lee ve diğer. 2013). Otomatik iş dağıtımı ve genel üretim kalitesini hedef alan bir diğer çalışmada ise beden tipi ve ölçüsü gibi antropometri bilimine dayalı özelliklerin etkileri incelenmiştir. Aşamalı küme ve istatistik yöntemleri kullanılmıştır. Ward minimum varyans metodu ve K-ortalama algoritması beraber kullanılarak çeşitli müşterilerin ihtiyacına yönelik iyileştirme yapılmıştır ve %95 kapsama oranına ulaşmışlardır(Hsu 2009).

Bir tekstil firmasında çalışanların performansını tahmin etmek amacıyla yapılan çalışmada Naive Bayes, GBT rastgele ağaç, ağaç topluluk gibi veri madenciliği teknikleri ile ağaç topluluk yöntemi ve gradyan yükseltme ağaç yapay zeka modeli

kullanılmıştır. Elde edilen sonuçlarda doğruluk değeri %86.39 bulunmuştur(Rahim ve diğer. 2021). Başka bir tekstil firmasında yapılan çalışmada pantolon üretiminde çalışan 198 işçinin uzun çalışma saatlerine maruz kaldıklarında üretim adedi ve işçilerin performanslarının düştüğü saptanmıştır. Çalışmada yapay sinir ağları(YSA), çoklu lineer regresyon analizi, sınıflandırma ve regresyon ağaçları(CART) algoritması ve ki-kare otomatik etkileşim(CHAID) algoritma modelleri kullanılmıştır(Ersoz ve diğer. 2017).

İşçilerin gerçek üretkenlik değerini derin sinir ağı modeli ile tahmin eden çalışmada 0.086 ortalama hata karesi değeri elde edilmiştir(Imran ve diğer 2019). Altı aylık pilot bir çalışmada, bulanık birliktelik kuramı ve özyinelemeli veri madenciliği kullanılarak küçük, büyük ve kritik kalite hatalarında sırasıyla %7, %20 ve %24 azalma, aynı zamanda üretim zamanı ve yeniden işlem maliyetinde de sırasıyla %26 ve %30 iyileştirme sağlanmıştır(Lee ve diğer. 2014).

Bu çalışmada giysi endüstrisi için işçilerinin üretkenliğini ifade eden performans değerlerini tahmin etmek amacıyla yapay zeka yöntemlerinden yapay sinir ağı kullanılmıştır. Yapay sinir ağı modelinin başarısını yükseltmek amacıyla kullanılan veri seti üzerinde veri madenciliği yöntemleri uygulanmıştır.

2. Materyal ve Metot

Bu çalışmada Şekil 1'de gösterilen adımlar uygulanmıştır.



Şekil 1. Çalışmada izlenen adımlar

2.1. Veri Toplama

Bu çalışmada kullanılan veri seti UCI(UC Irvine Machine Learning Repository) makine öğrenmesi veri tabanından elde edilmiştir. Veri seti içerisinde bir giysi üretim firmasının üç ay boyunca günlük gerçek üretim verileri toplanarak oluşturulmuştur. Toplamda 1153 örnek ve 15 adet öznitelikten oluşmaktadır(PPGE 2021). Öznitelikler ve açıklamaları Tablo 1'de sunulmaktadır.

Tablo 1. Öznitelikler ve açıklamaları

Öznitelik	Açıklama
Tarih	Gün/Ay/Yıl olarak verinin alındığı tarih
Gün	Haftanın günleri
Çeyrek	Ayın bölümleri. Ay dört çeyrekte oluşmaktadır
Departman	İlgili birim, dikiş veya bitirme işlemi
Takım No	Takım numarası
Stil değişme sayısı	Üründe stil değişiklik sayısı
Hedef üretkenlik	Yönetici tarafından her takım için her güne atanan hedef değer
Görev süresi	Dakika üzerinden her görev için ayrılan zaman
Devam eden iş sayısı	Bitmemiş işlerin sayısı
Süre aşımı	Her takımın dakika olarak yaptığı süre aşımı
Teşvik	Motive edici finansal yardım

Bekleme zamanı	İşin farklı sebeplerden dolayı bölünmesi sonucu oluşan bekleme zamanı
Bekleyen işçi	İşin farklı sebeplerden dolayı bölünmesi sonucu oluşan bekleyen işçi sayısı
İşçi sayısı	Her takımdaki çalışan sayısı
Gerçek üretkenlik	Gerçek üretkenlik değeri 0 - 1 arasında

2.2. Sayısallaştırma

Verilerin yapay zeka modellerinde işlenebilmesi için sayısal hale dönüştürülmesi gerekmektedir. Bu aşamada sayısal olmayan öznitelikler Tablo 2’de gösterildiği gibi sayısal hale getirilmiştir.

Tablo 2. Gerçekleştirilen sayısallaştırma işlemi

	İfadeler	Sayısal Değer
Gün	Pazartesi	0
	Salı	1
	Çarşamba	2
	Perşembe	3
	Cumartesi	4
	Pazar	5
Çeyrek	Birinci Çeyrek	1
	İkinci Çeyrek	2
	Üçüncü Çeyrek	3
	Dördüncü Çeyrek	4
Departman	Dikiş	0
	Bitirme işlemi	1

2.3. Veri Temizleme ve Ayıklama

Ham verilerde gürültü, eksik veri veya uygun olmayan veriler bulunabilmektedir. Değeri girilmemiş(eksik) ve doğru kayıt edilmediği düşünülen(gürültülü) veriler kurulacak olan yapay zeka modelinde başarıyı etkileyen önemli faktörlerdir. Bu nedenle eksik ve gürültülü verilerin verisetinden temizlenmesi gerekmektedir(Heaton 2008).

Veri temizleme sürecinde eksik ve gürültülü veri temizliğine ek olarak öznitelikler de incelenmiştir. Buna göre örneğin tarih özniteliği için tutulan verilerin birbirini takip eden günlerde verileri gün/ay/yıl şeklinde kayıt altına alınarak elde edildiği görülmüştür. Bu çalışmada zaman serisi tahmini yapmak amaçlanmadığından tarih alanı tahminde bulunacağımız olguya yardımcı olmamaktadır. Bu nedenle tarih alanı veri setinden çıkarılmıştır. Böylece 14 adet öznitelik ile diğer aşamalara geçilmiştir.

Özniteliklerin herbiri için ayrı grafikler oluşturularak verilerin değişimi değerlendirilmiştir. Bu sayede veri içindeki aşırılık noktaları tespit edilip modelin eğitilmesinde problem oluşturacak gürültülü olarak tanımlanan bu noktalar veriden temizlenmiştir. Her bir öznitelik için yapılan işlemler sonucu toplamda 152 adet örnek veri silinmiştir. Geriye kalan 1001 adet veri örneği modelin oluşturulmasında kullanılmıştır.

2.4. Normalizasyon

Elde kalan veriler kullanılarak her bir öznitelik için verilerin aralıklarını gösteren minimum ve maksimum değerleri hesaplanmıştır. Hesaplanan değerler Tablo 3’te gösterilmektedir.

Tablo 3. Özniteliklerin değer aralıkları

Öznitelik	Minumum Değer	Maksimum Değer
Gün	0	5
Çeyrek	1	4
Departman	0	1
Takım No	1	12
Stil değişme sayısı	0	2
Hedef üretkenlik	0,35	0,8
Görev süresi	2,9	30,48
Devam eden iş sayısı	0	1500
Süre aşımı	0	10620
Teşvik	0	113
Bekleme zamanı	0	5
Bekleyen işçi	0	30
İşçi sayısı	8	60
Gerçek üretkenlik	0,31	1,00

Tablo 3’te görüldüğü üzere özniteliklerin değer değişimlerinin birbiri arasında önemli farklar bulunmaktadır. Verinin bu şekilde yapay zeka modeline verilmesi modelin geliştirilmesinde olumsuz etkiler oluşturacağından özniteliklerin aynı aralığa getirilmesi amacıyla normalizasyon işlemi uygulanabilmektedir(Aksu ve diğer. 2019). Bu amaçla Denklem 1’de verilen normalizasyon formülü kullanılarak öznitelikler 0-1 aralığına getirilmiştir.

$$X_{nor} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Burada X_{nor} normalize edilmiş değeri, X öznitelik değerini, X_{min} özniteliğin minimum, X_{max} ise maksimum değerini ifade etmektedir.

2.5. Öznitelik Seçimi

Yapay zeka modelleri kurulurken girişte verilen özniteliklerin hangilerinin çıkış özniteliği ile ilgili olduğu öznitelik seçimi ile belirlenmektedir. Literatürde bu amaçla en yaygın kullanılan tekniklerden Temel Bileşen Analizi(TBA) yöntemi bu çalışma kapsamında kullanılmıştır(Tamilselvi ve Kalaiselvi 2013). TBA hesaplanırken iki değişken arasında doğrusal ilişkinin yönünü ve gücünü belirten korelasyon hesaplaması yapılmaktadır. Sonrasında belirlenen bir eşik değer üzerinden giriş özniteliklerinden ilişki değeri eşik değer altında kalan öznitelikler modelden çıkarılmaktadır. Bu yönüyle TBA aynı zamanda giriş özellik azaltma yöntemi olarak da bilinmektedir(Kumar ve Chong 2018). Kullanılan korelasyon formülü Denklem 2’de gösterilmektedir.

$$C_{(x,y)} = \frac{\sum(x-\bar{x})*(y-\bar{y})}{\sqrt{\sum(x-\bar{x})^2*\sum(y-\bar{y})^2}} \quad (2)$$

$C_{(x,y)}$ korelasyon değerini, x giriş değerini, y çıkış değerini, \bar{x} ve \bar{y} sırasıyla giriş ve çıkış değer ortalamalarını göstermektedir.

TBA hesaplaması sonucu elde edilen değerler Tablo 4' te gösterilmektedir.

Tablo 4. TBA sonuçları

Giriş Özneliği	Çıkış
	Gerçek üretkenlik
Gün	-0,009
Çeyrek	-0,080
Departman	0,087
Takım No	-0,105
Stil değişme sayısı	-0,211
Görev süresi	-0,101
Devam eden iş sayısı	0,003
Süre aşımı	-0,041
Teşvik	0,269
Bekleme zamanı	-0,072
Bekleyen işçi	-0,074
İşçi sayısı	-0,059
Gerçek üretkenlik	0,432

TBA sonuçları incelendiğinde girişler ve çıkış arasında doğrusal ilişkinin oldukça düşük seviyelerde olduğu görülmektedir. Bu durum incelenen problemin de zor bir problem olduğunu göstermektedir. İlişki düzeyinin düşük olması nedeniyle eşik değer çok fazla öznelik kaybı yaşamamak adına 0.05 olarak tercih edilmiştir. Tablo 4'te kırmızı renkte işaretlenmiş öznelikler eşik değerinin altında kaldığından verisetinden çıkarılmıştır. Buna göre model oluşturma işlemine 10 giriş ve 1 çıkış özneliği ile devam edilmiştir.

Veri madenciliği teknikleri uygulandıktan sonra geliştirilecek olan yapay zeka modelinde kullanılmak üzere elde kalan veri setinin tamamı üzerinden eğitim ve test veri oluşturulmuştur. Bu işlemde literatürde yaygın olarak kullanılan metodlardan veri setinin %70'i eğitim ve %30'u test olmak üzere ayırma yöntemi izlenmiştir(Crowther ve Cox 2005). Buna göre toplamda 1001 satır örnek bulunan veriseti, eğitim için 700 ve test için 301 olmak üzere veri setleri oluşturulmuştur.


2.6. Yapay Sinir Ağı Modeli

Yapay sinir ağı(YSA) model oluşturma işlemlerinde literatürde yaygın olarak kullanılan Matlab programının nntool aracı tercih edilmiştir(MATH 2021).

Oluşturulması planlanan YSA türü belirlenirken, yapılan denemeler sonucu en iyi sonuca ulaşılan ileri beslemeli geri yayımlı (FFBP) YSA seçilmiştir.

YSA ile yapılan çalışmalarda nöron sayısı, katman sayısı, eğitim ve adaptasyon fonksiyonları gibi parametrelerin seçimi modelin başarısını doğrudan etkilediğinden oldukça önemlidir. Ancak bu parametrelerin seçiminde belirgin bir metod bulunmadığından seçim işlemi genellikle rastgele olmaktadır. YSA modeli oluşturulurken ara katmanlardaki nöron sayıları

seçiminde ise bilgisayar mimarisine en uygun olan 2^n tekniği kullanılmaktadır(Sheela ve Deepa 2018). Yapılan denemeler sonucunda en iyi sonucu verdiği için iki ara katmandan oluşan ve her bir ara katmanda sırasıyla 128, 8 nöronun bulunduğu bir YSA modeli oluşturulmuştur. Parametrelerin seçimi sonrası oluşan YSA modeli Şekil 2'de gösterilmektedir.



Şekil 2. FFBP YSA model yapısı

Problemimiz gradyan azaltma ve denetimli öğrenme yapay zeka modeline uygun olduğundan ve aynı zamanda en iyi sonucu verdiğinden bu öğrenme fonksiyonu seçilmiştir. Eğitim fonksiyonu için Denklem 3'te gösterilen momentum gradyan düşüş ve ayarlanabilir öğrenme hızı algoritması(3) seçilmiştir(Arthur ve diğer 2020).

$$dM = \gamma * (dM_{\text{önceki}}) + \alpha * \gamma * \frac{dQ}{dM} \quad (3)$$

Burada $dM_{\text{önceki}}$ ağırlık veya sapmada bir önceki değişimi, γ momentum sabiti, α öğrenme hızı, Q performansı temsil etmektedir.

Adaptasyon fonksiyonu için Denklem 4'te verilen momentum ağırlık ve sapma ile çalışan gradyan düşüş formülü kullanılmıştır.

$$dW = mc * dW_{\text{önceki}} + (1 - mc) * lr * gW \quad (4)$$

dW hesaplanan ağırlık değişimi, gW gradyan ağırlık, lr öğrenme hızı, mc momentum sabitini ve $dW_{\text{önceki}}$ öğrenme durumunda bir önceki kayıt edilen ağırlık değişimini temsil etmektedir.

Aktivasyon fonksiyonu olarak Denklem 5'te gösterilen tanjant sigmoid formülü kullanılmıştır. Fonksiyonun değişim aralığı olan $[-1, 1]$ arasında toplam girişe bağlı olarak lineer olmayan bir değişim göstermektedir.

$$fn = \frac{2}{1 + \exp(-\lambda n)} - 1 \quad (5)$$

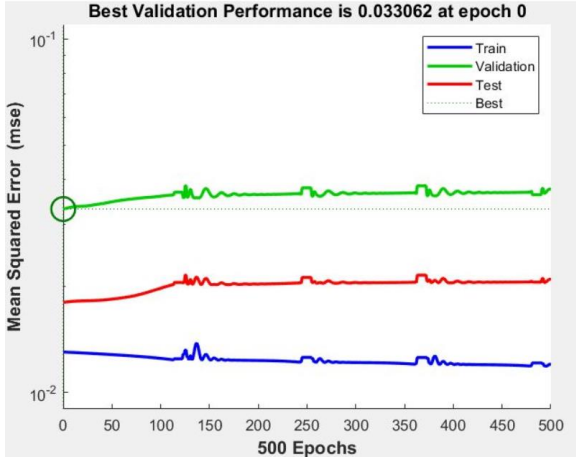
Burada λ diklik veya eğim katsayısını ifade etmektedir.

Modelin eğitim sürecinin izlenmesi ve değerlendirilmesi için Denklem 6'da gösterilen ortalama hata karesi(MSE) metodundan faydalanılmıştır.

$$MSE = \frac{1}{N} \sum_{i=0}^N (Y_i - \hat{Y}_i)^2 \quad (6)$$

Burada N veri sayısını, Y_i gerçek değeri ve \hat{Y}_i tahmin edilen değeri temsil etmektedir. MSE sonucunda model başarısının iyi olması için bu değerlerin sıfıra yakın olması beklenmektedir.

YSA modelinin simülasyonu sırasında elde edilen MSE değerlerini gösteren grafik Şekil 3'te sunulmaktadır.




Şekil 3. YSA model similasyonu MSE değişimi

Grafikten görüldüğü gibi model similasyonu sırasında elde edilen MSE değeri 0.033062 olarak bulunmuştur. MSE değerinin sıfıra yakın olması sistemin başarılı bir şekilde eğitildiğini göstermektedir.

3. Araştırma Sonuçları ve Tartışma

3.1. Sonuçlar

Geliştirilen YSA modelinin similasyonu sonucunda test verilerinin tahmini gerçekleştirilmiştir. Gerçek ve tahmin edilen değerlerin değişimini gösteren grafik Şekil 4'te gösterilmektedir.



Şekil 4. YSA test similasyonu

Şekil 4' teki grafikte görüldüğü üzere 301 adet test verisinin elde edilen tahmin ve gerçek üretim performansı değerlerinin birbirini ile uyumlu olduğunu göstermektedir.

Sistemin başarısının sayısal olarak ölçülmesi için gerçek ve tahmin edilen üretim değerleri üzerinden Denklem 7'de verilen doğruluk değeri hesaplanmıştır.

$$D = \left(\frac{O_i - E_{ort}}{O_i} \right) * 100 \quad (7)$$

Burada D doğruluk değerini, E_{ort} tahmin ve gerçek değer farkının ortalamasını ve O_i olması gereken aralığı temsil etmektedir. Geliştirilen modelin doğruluk değeri %85 olarak hesaplanmıştır.

3.2. Tartışma

Örnek bir giysi işletmesindeki gerçek veriler üzerinde yapılması gereken sayısallaştırma, temizleme, ayıklama ve normalizasyon gibi veri madenciliği aşamaları detaylı şekilde uygulanmıştır.

Elde edilen öznitelikler üzerinde TBA analizi yapılarak giriş ve çıkış öznitelikleri arasında ilişkiler ortaya çıkarılmıştır. Ayrıca TBA metodu ile giriş öznitelik sayısı azaltılarak önerilen YSA modelinin daha az öznitelik verisi işleme sağlanarak model çalışma performansı artırılmıştır.

Yapılan bu çalışmada önerilen YSA modeli ile %85 başarı değerine ulaşılmıştır. Bu anlamda geliştirilen yapay zeka modelinin giysi endüstrisinde çalışan işçilerin üretkenlik performans değerlerinin tahmininde kullanılabilir bir model olduğu gösterilmiştir.

Önerilen sistem ile işçi performansının tahmini gerçekleştirilerek bu sektörde faaliyet gösteren işletmelerin verimlilik, pratiklik ve digital dönüşüm açısından geliştirilmesine katkı sağlanabilir.

İleriki çalışmalarda farklı veri madenciliği teknikleri ve yapay zeka modelleri uygulanabilir. Bu şekilde elde edilen model similasyonu sonuçları karşılaştırılabilir.

Kaynakça

- Aksu, G., Güzeller, C. O., Eser, M. T. (2019), "The Effect of the Normalization Method Used in Different Sample Sizes on the Success of Artificial Neural Network Model", International Journal of Assessment Tools in Education, Vol. 6, No. 2, p. 170-192.
- Arthur, C. K., Temeng, V. A., Ziggah, Y. Y. (2020), "Performance Evaluation of Training Algorithms in Backpropagation Neural Network Approach to Blast-Induced Ground Vibration Prediction", Ghana Mining Journal, Vol. 20, No. 1, p. 20 – 33.
- Bashimov, G. (2014), "Tekstil ve Hazır Giyim Sektörünün Karşılaştırmalı Avantajı: Türkiye ve Pakistan Örneği", BEU.SBU.Derg., Cilt:3, Sayı:1.
- Cottini, E., Kato, T., Westergaard-Nielsen, N. (2011), "Adverse Workplace Conditions, High-Involvement Work Practices And Labor Turnover: Evidence From Danish Linked Employer–Employee Data", Labour Economics, Vol. 18, No. 6, p. 872-880.
- Crowther, P. S., Cox, R. J. (2005), "A Method for Optimal Division of Data Sets for Use in Neural Networks", 9th International Conference KES.
- Ersoz, F., Ersoz, T., Guler, E. (2017), "Knowledge Discovery And Data Mining Techniques In Textile Industry", World Academy of Science, Engineering and Technology, International Journal of Computer, Electrical, Automation, Control and Information Engineering, Vol. 11, No. 7, p. 906–910.
- Heaton, J. (2008), "Introduction to neural networks with Java", Heaton Research, Inc.; 2 edition.
- Hsu, C.H. (2009), "Data Mining To Improve Industrial Standards And Enhance Production And Marketing: An Empirical Study In Apparel Industry", Expert Systems with Applications, Vol. 36, No. 3, p. 4185–4191.
- Imran, A. A., Amin, M. N., Islam Rifat, M. R., Mehreen, S. (2019), "Deep Neural Network Approach for Predicting the Productivity of Garment Employees", 6th International Conference on Control, Decision and Information Technologies.
- Islam, M. S., Rakib, M. A., Adnan, A. T. M. (2016), "Ready-Made Garments Sector of Bangladesh: Its Contribution and

- Challenges Towards Development”, *Journal of Asian development studies*, Vol. 5, No. 2.
- Kumar, S., Chong, I. (2018), “Correlation Analysis to Identify the Effective Data in Machine Learning: Prediction of Depressive Disorder and Emotion States”, *International Journal of Environmental Research and Public Health*, Vol. 15.
- Lai, P.S. and Christiani, D.C. (2013), “Long Term Respiratory Health Effects In Textile Workers”, *Current Opinion in Pulmonary Medicine*, Vol. 19, No. 2, p.152.
- Lee, C. K. H., Choy, K. L., Ho, G. T., Chin, K. S., Law, K. M. Y., Tse, Y. K. (2013), “A Hybrid OLAP-Association Rule Mining Based Quality Management System For Extracting Defect Patterns In The Garment Industry”, *Expert Systems with Applications*, Vol. 40, No. 7, p. 2435-2446.
- Lee, C. K. H., Ho, G. T. S., Choy, K. L., Lam, C.H.Y. (2016), “A Slippery Genetic Algorithm-Based Process Mining System For Achievingbetter Quality Assurance In The Garment Industry”, *Expert Systems With Applications*, Vol. 46, p. 236–248.
- Lee, C. K. H., Ho, G. T. S., Choy, K. L., Pang, G. K. H. (2014), “A RFID-Based Recursive Process Mining System For Quality Assurance In The Garment Industry”, *International journal of production research*, Vol. 52, No. 14, p. 4216-4238.
- MATH,<https://www.mathworks.com/help/deeplearning/ref/nntool.html>, 22 Nisan 2021.
- PPGE,<https://archive.ics.uci.edu/ml/datasets/Productivity+Prediction+of+Garment+Employees>, 22 Nisan 2021.
- Rahim, M. S., Imran, A. A., Ahmed, T. (2021), “Mining The Productivity Data of Garment Industry”, *International Journal of Business Intelligence and Data Mining*.
- Sheela, K. G., Deepa, S. N. (2013), "Review on Methods to Fix Number of Hidden Neurons in Neural Networks", *Mathematical Problems in Engineering*, vol. 2013, p. 11.
- Tamilselvi, R., Kalaiselvi, S. (2013), “An Overview of Data Mining Techniques and Applications”, *International Journal of Science and Research (IJSR)*, Vol. 2, No. 2.
- Więcek, D., Burduk, A., Kuric, I. (2019), “The Use of ANN In Improving Efficiency and Ensuring The Stability of The Copper Ore Mining Process”, *Acta Montanistica Slovaca*, Vol. 24, No. 1, p. 1-14.
- Zhiqiang, G., Zhihuan S., Steven, X. D., Biao, H. (2017), *Data Mining and Analytics in the Process Industry: The Role of Machine Learning*, *IEEE Access*, Vol. 5, p. 20590 – 20616.