

Toplam Ekipman Etkinliğine Etki Eden Faktörlerin Makine Öğrenim Yöntemleri ile Analizi

Özgül Vupa Çilengiroğlu¹ , İlke Genç² 

ÖZET

Amaç: Üretim sektöründeki bir firmanın 2018-2019 yılı orjinal verilerinden türetilmiş sıralı ölçekteki Toplam Ekipman Etkinliği (TEE) puanı üzerinde etkili olan değişkenlerin makine öğrenim algoritmaları ile modellenmesi, yorumlanması ve model performanslarının karşılaştırılması çalışmanın temel amacıdır.

Yöntem: TEE puanının modellemesinde karar ağaçları (CART, CHAID), lojistik regresyon (LogR) ve yapay sinir ağları (YSA) kullanılmıştır. Kurulan modellerin performans değerleri "duyarlılık", "seçicilik", "kesinlik" ve "doğruluk" kriterlerine göre hesaplanmıştır. Modelleri yorumlarken karar ağaçları ve YSA sonuçları için yüzdeliden, LogR için odds oranından yararlanılmıştır.

Bulgular: Modellerde TEE puanı üzerinde "saat", "üretim", "tecrübe" ve "kayıp metre" değişkenleri incelenmiştir. Performans karşılaştırmasında en iyi sonuç veren algoritmanın sıralı LogR olduğu ve bu modele göre üretimin düşük ve çalışanlarının daha az tecrübeli olduğu firmalarda daha "düşük" TEE puanı elde edilirken, kayıp metresi daha az olan firmalarda daha "yüksek" TEE puanı alma şanslarının olduğu saptanmıştır.

Özgünlük: Literatürde sürekli olarak modellenen TEE puanının kategorik hale getirilerek sınıflar arasındaki farklılığın belirlenmesiyle firmaların kendi konumlarını belirlemesi sağlanmıştır. Böylece firmalar kategorisini belirleyip seçilen modeldeki önemlilik sırasındaki faktörlerini değiştirek bir üst kategoriye daha hızlı çıkabilecektir. Literatürde kategorik olan TEE puanını makine öğrenim algoritmaları ile çözümleyen modellerin olmaması bu çalışmanın özgünlüğünü olarak belirlenmiştir.

Anahtar Kelimeler: Toplam Ekipman Etkinliği, Karar Ağaçları, Sıralı Lojistik Regresyon, Yapay Sinir Ağları.

JEL Kodları: C02, C35, C44.

Analysis of the Factors Affecting the Total Equipment Efficiency with Machine Learning Methods

ABSTRACT

Purpose: The main purpose of the study was determined as modeling, interpreting and comparing the model performances of the variables with machine learning algorithms. Based on the original data in 2018-2019 from a company operating in the manufacturing sector, variables that are effective on the Overall Equipment Effectiveness (OEE) score in the ordinal scale obtained by the simulation study are used.

Methodology: Decision trees (CART, CHAID), logistic regression (LogR) and artificial neural networks (ANN) were used in modeling the OEE score. The performance values of the established models were calculated according to the criteria of "sensitivity", "specificity", "precision" and "accuracy". While interpreting the models, percentages were used for decision trees and ANN results, and odds ratio was used for LogR.

Findings: In the models, "hour", "production", "experience" and "lost meter" variables were examined on OEE score. By comparing the performance criteria, it was determined that the algorithm that gave the best results was ordinal LogR. It has been determined that those with low production and less experience have a "lower" OEE score, and those with less lost meters have a higher chance of getting a "higher" OEE score.

Originality: OEE, which is modeled as a continuous in the literature, was made categorical and the companies were able to determine their own positions by determining the difference between the classes. Thus, companies will be able to move up to the next category faster by determining their category and changing the variables in order of importance in the selected model. The lack of models in the literature that analyze categorical OEE with machine learning has been determined as the originality of this study.

Keywords: Overall Equipment Effectiveness, Decision Trees, Ordinal Logistic Regression, Artificial Neural Networks.

JEL Codes: C02, C35, C44.

¹ Dokuz Eylül Üniversitesi, Fen Fakültesi, İstatistik Bölümü, İzmir, Türkiye

² Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, Veri Bilimi Yüksek Lisans Programı, İzmir, Türkiye

Sorumlu Yazar-Corresponding Author: Özgül Vupa Çilengiroğlu, ozgul.vupa@deu.edu.tr

DOI: 10.51551/verimlilik.1266852

Araştırma Makalesi / Research Article | Geliş / Submitted: 17.03.2023 | Kabul / Accepted: 02.03.2024

Atıf/Cite: Vupa Çilengiroğlu, Ö. ve Genç, İ. (2024). "Toplam Ekipman Etkinliğine Etki Eden Faktörlerin Makine Öğrenim Yöntemleri ile Analizi", *Verimlilik Dergisi*, 58(2), 171-184.

EXTENDED ABSTRACT

Today, the importance and necessity of machine learning algorithms in collecting, storing, processing, analyzing and interpreting data is indisputable. Machine learning is used in the manufacturing industry to help companies compete, gain superiority, reduce costs or be more efficient. However, in the production sector, some criteria such as Overall Equipment Effectiveness (OEE), which is shown on a ratio scale and as a percentage, are used.

The main motivation of this study is to convert the OEE score, which is on a ratio scale, into an ordinal scale (low, normal, high) and model it with machine learning algorithms, interpret it and compare model performances. In this way, by determining the difference between classes, companies will be enabled to determine their own positions. Thus, companies will be able to move up to the next category faster by determining their category and changing the factors in the order of importance in the selected model. This system is especially important for companies to determine their priorities in terms of success and financial situation in the sector. The absence of models in the literature that analyze the categorical OEE score with machine learning algorithms was determined as the originality of this study.

The data is augmented from original data ($n=215$) of a company in the plastic production sector in İzmir, Türkiye, between 2018-2019. The derived data ($n=700$) includes the variables "production (meters)", "lost meters (meters)", "experience (years)", "season", "day" and "downtime (hours)". Performance comparisons of the algorithms (80% train and 20% test) were made with repeated measurements and criteria such as "sensitivity", "specificity", "precision" and "accuracy". In ordinal logistic regression, interpretations are made in terms of odds ratio, while performance comparisons of decision trees, ANNs and models are expressed as percentages.

In CART and CHAID algorithms, the effects of "hour" and "lost meter" variables on the OEE score were found to be negative, while the effects of "production" and "experience" variables on this score were found to be positive.

Since the OEE score is in three different categories in ordinal logistic regression models, two different logistic regression models were established. In the first model, the low category of OEE was taken as reference, and in the second model, the high category of OEE was taken as reference. Accordingly, in the first model, it was determined by the odds ratio that the chances of getting "normal" and "high" OEE scores were higher in cases where production was high, lost meters were low and work experience was high. Likewise, thanks to the second model, this interpretation was made for a "low" OEE score, similar and compatible with the first model.

In the established single and multi-layer ANN models, the activation function was determined as hyperbolic tangent in the hidden layer and softmax in the output layer. When the importance of the variables on the OEE scores was examined, it was determined that the most important variable in the ANN model was "production".

In comparing model performances, logistic regression and decision tree (CHAID) were found to be the best models for precision, logistic regression and ANN for sensitivity, and logistic regression for accuracy and specificity. Considering these performances, it was determined that logistic regression gave the best results.

Different machine learning algorithms can be used depending on industries. In this study, the category and interpretation of the OEE score of a company in the manufacturing sector in the logistic regression model is shown. If companies know their OEE category, they can use machine learning algorithms appropriate to their data set and purpose to rise from that category or stay the same by keeping the variables that affect the OEE score under control. They can also make improvements in their decision-making processes by looking at the impact strength of the effective variables. Accordingly, it is also recommended that in future studies, different sectors should be selected, the algorithm or model of that sector should be determined, and models containing time series should be established with the data to be collected annually. In addition, using logistic regression for category transitions or improvements can be planned for future studies, as well as modeling different decision trees with higher visuality, where companies can interpret their parameters more easily, with categorical OEE.

1. GİRİŞ

Günümüz dünyasında teknoloji vazgeçilmez ve çok hızlı gelişen bir unsur haline gelmiştir. Hızlı gelişen bu teknoloji ile verilerin toplanması ve depolanması daha kolay bir şekilde gerçekleşmektedir. Veriler teknoloji ve bilgisayarın etkileşimiyle daha kolay ve hızlı elde edilirken aynı zamanda tüm dünyada daha büyük boyutlarda depolanmaya başlanmıştır. Uluslararası Veri Şirketi (International Data Corporation, IDC) verilerin yıl bazında çok yüksek oranda büyüyeceğini ve hatta önmüzdeki 5 yılda yaklaşık 5 kat artabileceğini öngörmektedir. Bununla birlikte bu şirket verilerle iletişimde olan kullanıcı sayısının çok daha fazla olacağı da hesaplanmıştır (Ersöz ve Çınar, 2021).

Teknolojinin gelişmesi ile verilerin depolanması sonucunda özellikle veri sahiplerinin verileri işleme ve yorumlama konusunda acil ihtiyaçları oluşmuştur. Bununla birlikte verilerin işlenmesi, düzenlenmesi, sınıflandırılması, istatistiksel olarak çözümlemesi ve yorumlanması makine öğrenim algoritmalarının önemini ve gerekliliğini ortaya çıkarmıştır.

Makine öğrenimi, eğitim bilimleri, fen bilimleri, mimarlık, mühendislik, sağlık, sosyal, beşerî ve idari bilimler, ziraat ve spor gibi pek çok farklı bilimlerde kullanılmaktadır. Son yıllarda teknolojinin verdiği rahatlık ile bilimler arası alanlarda verilerin toplanması ve depolanması düşük maliyetlerde olabilmektedir. Hatta verilere erişim ve yayılım internet sistemleri sayesinde kolaylıkla yapılmaktadır. Bu da farklı alanlarda verilerin makine öğrenim algoritmaları ile incelenmesine olanak sağlamaktadır. Özellikle büyük veri seti ile çalışan birçok firma söz konusu verilerden anlamlı, değişkenler arasında ilişkileri ortaya koyan, değişkenleri karşılaştırın, bu değişkenlerle model kuran ve gerçek zamanlı tahmin yapan sonuçlar bulmayı hedeflemektedir. Firmaların temel amacı sektördeki diğer firmalarla rekabet etmek ve üstünlük sağlamak, maliyeti düşürmek, depolama ve üretim alanında daha verimli çalışma sonuçları ortaya çıkartmaktadır (Ersöz ve Çınar, 2021).

Tüm dünyada olduğu gibi Türkiye'de de üretim sektöründe oluşan bu büyük veriler tek başına bir anlam ifade etmemekte ancak veriler işlendiği zaman, belirli kurallara göre elde edilen sonuçlar özellikle veriye yönelik yöntemlerin seçilmesi ile anlam kazanmaktadır (Samoili ve diğerleri, 2020: 1). Veri bilimi içerisinde olan makine öğrenim yöntemleri ile üretim sektöründe ham madde alımları, depolama durumları, müşteri davranışları ve eğilimleri, talep tahminleri, makine ve ekipmanlara ait performans tahminleri çözümlemeye çalışılmaktadır. Elde edilen sonuçlarla özellikle şirketlerin finans durumları ve sektördeki başarıları belirlenmiş olmaktadır.

Rekabetin ve her türlü maliyetin günden güne arttığı günümüz piyasalarında özellikle firmaların maliyetlerini düşürmek için makine ve ekipmanlarının etkin kullanımı önem taşımaktadır. Bu amaçla tüm üretim firmalarının ana hedefi özellikle makine ve ekipman performanslarının artırılması şeklindedir. Bu hedefi de "Toplam Ekipman Etkinliği (TEE)" kavramını içselleştirerek gerçekleştirebilirler. TEE kavramı farklı kayıp durumlarına göre ilk kez Nakajima (1988) tarafından literatüre girmiştir. TEE; 2000 yılların sonuna kadar gerçekleştirilen üretim ile ideal üretim arasındaki oran olarak tanımlanırken, 2010 yılından sonra üretim firmaları TEE'i verimlilik ve ölçme aracı olarak kullanmışlardır (Braglia ve diğerleri, 2009; Garza-Reyes ve diğerleri, 2010; Tsarouhas, 2013; Becker ve diğerleri, 2015; Çelik, 2020). TEE'nin performans artırımında bu puan üzerindeki faktörlerin etkisi önemlidir. TEE'nin amacını oluşturan performans artırımında makinelerin verimliliğini engelleyen faktörler yok edilmeli ya da kontrol altına alınmalıdır. Bu faktörler temel düzeyde altı büyük kayıp (ekipman, montaj ve ayarlama, düşük hız, boşta çalışma ve küçük duruşlar, işlem, makine istikrarlı duruma geçme zamanı) olarak adlandırılmalıdır. Bu kayıpları engellemek için de TEE üç boyuta indirgenmiştir ($TEE = \text{kullanılabilirlik} \times \text{performans} \times \text{kalite}$). Buna göre TEE, bireysel ekipmanın veya tüm süreçlerin performans etkinliğini ölçmek için öğelerin kullanılabilirliğine, performansına ve kalitesine dayalı niceliksel bir ölçüm sağlamaktadır (Reyes, 2015). Bununla birlikte süreç iyileştirmelerini belirlemek ve uygulamak için TEE formülünü yeniden düzenleyen çalışma da bulunmaktadır (Abdelbar ve diğerleri, 2019). Literatürdeki bu çalışmaların hepsinde TEE yüzde olarak gösterilmekte ve uygulamada kabul görmüş değerlerle karşılaştırılarak makine ve ekipman etkinliği ölçüyü olarak belirtilmektedir. (Muchiri ve Pintelon, 2008; Görener, 2012; Nayak ve diğerleri, 2013; Acar ve Çakırkaya, 2018). Nakajima (1988) literatürde kabul gören ideal TEE değerini de %85 olarak göstermiş ve kullanmıştır (Görener, 2012).

TEE kavramının kullanım alanı çok genişdir. Bu kavram 1990'lardan itibaren üretim süreçlerindeki bakımada yer alırken 2000 yılların başından itibaren üretim süreçlerinde verimlilikte kullanılmıştır. 2000 yılların ikinci yarısından sonra kaynak verimliliğine odaklanan TEE, 2010 ve sonrasında tedarik zinciri verimliliği üzerine olan çalışmalarda yer almıştır (Corrales ve diğerleri, 2020). Tüm dünyada etkisini gösteren sürdürilebilir kaynaklar konusundaki çalışmalarda TEE kavramı 2015 yılından günümüze kadar özellikle kaynak kayıpları belirlemede, karayolu taşımacılığında ve Endüstri 4.0 ile ilişkilendirilmiştir (Domingo ve Aguado, 2015; Ghafforpoor Yazdi ve diğerleri, 2018; García-Arca ve diğerleri, 2018; Muñoz-Villamizar ve diğerleri, 2018). Bununla birlikte bu kavram hala üretim sektöründe popülerliğini sürdürmektedir.

Üretim sektöründe kullanılan makine öğrenim yöntemlerinde sürekli verilerin yanı sıra kategorik verilerin çözümünde de kullanılan birçok istatistiksel algoritma bulunmaktadır. Bu sektörde TEE gibi birçok ölçüt, kategorik hale getirilerek sınıflar arasındaki geçişler gösterilebilir. Özellikle firmaların sektördeki başarı ve finans durumlarında önceliklerini belirlemeleri son yıllarda büyük önem kazanmıştır. Kısıtlı süre veya bütçe durumunda bir anda gerçekleştirmeyecek ilerlemelerin ya da değişimlerin kategoriler arasında geçişleri bu sistemde daha kolay görünebilmektedir. Kategoriler arasında maliyet, insan ve ekipman talepleri farklı olabilir. Firmaların birden bu parametreleri aynı anda artırmaları mümkün değildir. Ancak firmalar için kategoriler arasında geçişlerin sağlanması ile finansal, zamansal ve olanaksal olarak daha kolay ve akıcı çözümler yaratılabilir. Böylece hammadde alımları, depolama durumları, müşteri davranış ve eğilimleri, talep tahminleri ve makine ile ekipman durumları kategorilere göre önceliklendirilebilir ya da düzenlenlenebilir.

Bu çalışmanın ana motivasyonu oransal ölçekte olan TEE verilerini sıralı ölçüye çevirerek makine öğrenim algoritmaları ile modellenmesi, yorumlanması ve model performanslarının karşılaştırılması olarak belirlenmiştir. Çalışma kapsamında ilk olarak oransal ölçekteki TEE ile birlikte makine öğrenim yöntemlerinin kullanıldığı literatür taraması verilmiştir. Daha sonra kategorik hale getirilerek sınıflar arasındaki geçiş göstergesi sıralı ölçek sisteminde üretim yapan uluslararası bir şirketin gerçek verileri baz alınarak türetilmiş TEE puanı üzerinde etkili olan değişkenlerin makine öğrenim algoritmaları (lojistik regresyon, karar ağaçları (CART, CHAID), yapay sinir ağları) ile çözümlenmesi yapılmıştır. Elde edilen bulgularda performans karşılaştırılması yapılrken test ve eğitim verilerinin kullanılması ile duyarlılık, seçicilik, kesinlik ve doğruluk gibi istatistiksel ölçütler kullanılmıştır. Son olarak sıralı ölçekteki TEE verilerinin algoritmalar sonucundaki performans yorumları literatür ile karşılaştırılarak değerlendirilmiştir.

2. LITERATÜR TARAMASI

Makine öğreniminde kullanılan çeşitli yöntemlerinin açıklanlığı çalışmalarında son yıllarda kullanılan denetimli ve denetimsiz algoritmaların avantaj ve dezavantajlarına yer verilmiştir. Buna göre genellikle sınıflandırma için karar ağaçları kullanılırken sınıflandırma ve modelleme için lojistik regresyon kullanılmaktadır (Reddy ve Babu, 2018). Sıralı sınıflandırmada makine öğrenim algoritmalarının yer aldığı birçok alan çalışması bulunmaktadır. Sıralı ölçeğin ele alındığı ve örneklem genişliğinin 100 ile 500 arasında değişen simülasyon verisinde yapay sinir ağları modellerinin performansları karşılaştırılmıştır (Costa ve Cardoso, 2005). Daha sonra sınıflayıcı ölçekteki girdi değişkeni için yine simülasyon verisinde CART karar ağaçları algoritması kullanılmıştır (Piccarreta, 2008). Sıralı sınıflandırmanın ele alındığı yazılım hata tahminleri verisinde makine öğrenim algoritmalarından rastgele orman, destek vektör makineleri, Naive Bayes ve k-en yakın komşu yöntemlerinden yararlanılmıştır (Kiyak Öztürk ve diğerleri, 2019).

Bunun yanı sıra üretim verilerinin incelenmesinde TEE değerinin oransal ölçekteki uygulamaları literatürde sıklıkla bulunmaktadır. Özellikle TEE değerinin hesaplanarak yapılan düzeltmeler sonucunda bu değerin nasıl değiştiği ve çeşitli yöntemlerle elde edilen TEE sonuçlarına ait çalışmaların farklı alanlardaki uygulamaları incelenmiştir. Son yıllarda küçük ve orta ölçekli firmalarda ekipman etkinliğinin iyileştirilmesi üzerine olan çalışmalarda farklı sonuçlar elde edilmektedir. Örneğin, tekstil sektöründe deri işleme makinelerinde bulunan TEE değerlerinin üretim öncesinde yapılan iyileştirmeler ile %5 oranında artırabileceği bulunmuştur (Patel ve Deshpande, 2016). İstanbul'da küçük işletmeli bir ahşap kapı üretim hattında TEE yaklaşımı ekipman iyileştirmesinde kullanılmıştır. Kritik ekipmanların belirlenmesi sayesinde iyileştirme çabalarının %64,7'den %72,4'e çıktıgı bulunmuştur (Yaşın ve Daş, 2017). Ekipman etkinliği iyileştirilmesinin yanında bir de çalışma ve duruş sürelerini dikkate alan çalışmalar işletmelerde kendini göstermektedir. Koruyucu ve önleyici bakım faaliyetleri için TEE'nin hesaplanması, makarna üretimi yapan bir üretim hattının çalışma ve duruş süreleri dikkate alınarak incelenmiştir. Yapılan bu çalışmada yükleme, performans ve kalite seviyesine bakarak TEE değeri %90,8 olarak hesaplanmış ve plansız duruşlarda iyileştirme yapılabileceği tespit edilmiştir (Acar ve Çakırkaya, 2018). Gaziantep bölgesinde faaliyet gösteren bir sentetik iplik üreticisinin yalnız üretim sürecine geçişinde büküm ve aktarma makinelerindeki arızaların giderilmesi ve duruşların azaltılması ile TEE değerinin %58,2'den %73,5'e çıktıgı tespit edilmiştir (Akçacı ve Özyurt, 2021).

Bununla birlikte farklı yöntemler kullanılarak yapılan TEE çalışmalarının sayısı ve çeşitliliği günden güne artmaktadır. TEE yöntemi ile toplam ekipmana ait maliyet kaybı farklı yönleri ile karşılaştırılmıştır (Wudhikarn, 2016). Ayıklama, düzenleme, temizleme, standartlaştırma ve disiplin aktiviteleri ile tanımlanan 5S uygulaması bir çelik üreticisi firmasında ekipman etkinliğine olan etkisi için araştırılmıştır. Araştırma sonucunda yıllık TEE değerinin yaklaşık %1,024 düzeyinde performansı artırdığı tespit edilmiştir (Çelik, 2019). Deterjan üretimi yapılan bir firmada Triz yöntemi ile TEE değerinin artırılacağı ancak bu artışın çok da büyük boyutlarda olmayacağı (%34'den %37'e) vurgulanmıştır (Özkan ve diğerleri, 2019). Makine performanslarının tercih seçim yöntemi ile değerlendirmesinde TEE'nin önemli bir araç olduğu ancak başka kriterler daha eklendiğinde performansın artabileceği modellerin geliştirilebileceği de vurgulanmıştır (Sarı, 2019). Son olarak planlı duruş süresinin önemi bir çelik firmasının üretim hattında TEE'nin yüksek çıkması ile bulunmuştur (Çelik, 2020).

TEE'nin farklı firmalardaki çeşitli uygulamalarının daha da artması ile türetilmiş verileri içeren çalışmalar önem kazanmaktadır. Aslında varolmayan ama olabilecek durumların değerlendirilmesi ya da maliyete sebep olabilecek durumların türetilmiş veri ile çözümlenmesi hem zaman hem de para kaybını önleyen çalışmalar olarak dikkate alınmaktadır. Literatürde türetilmiş veriler kullanılarak TEE tahmini çalışmaları da yapılmaktadır. Çarpıcı bir şekilde TEE yöntemi M/M/1/N kuyruk çalışmada türetilmiş verilerde tahminleme için uygulanmıştır (Paprocka, 2015).

Literatürde dünya TEE sınıflamasında bu değerinin %85 ve üstünde olması istenilen bir durumdur. Ancak firmalarda bu oranın elde edilmesi özellikle "kullanılabilirlik", "performans" ve "kalite" ölçütlerinin yüksek olarak istenilmesinden kaynaklı olarak her zaman çok mümkün değildir (Singh ve diğerleri, 2018). TEE oranını bu değerlerde tutan firmaların sayısı da çok sınırlıdır. Bu yüksek oranlar üretim firmalarında çalışılan hatların etkin olduğunu, hatta problem olmadığını veya varsa bile düzeltildiğini göstermektedir. Bir makarna üretim tesisindeki makinelerin TEE değeri %90,8 olarak belirlenerek ideal değer olan %85'in üzerinde olduğu için üretim hattının etkin çalıştığı tespit edilerek kalite değerinin daha da iyileştirilebileceği önerisi verilmiştir (Acar ve Çakırkaya, 2018). İmalat endüstrisinde klima verileri üzerine yapılan çalışmada ise TEE değerinin %81 ile %86 arasında olduğu tespit edilmiştir (Purba ve diğerleri, 2018). Plastik kalıplama makinesinin ekipman etkinliğinin artırılması üzerine yapılan çalışmada TEE yapılan düzeltmeler ile %86,95'ten %95,62'ye çıkarılmıştır (Udomraksasakul ve Udomraksasakul, 2018).

Sıralı ölçütekteki TEE için makine öğrenim algoritmaları ve performans karşılaştırma çalışmaları sınırlı iken oransal ölçütekteki TEE'nin hesaplanması birçok farklı makine öğrenim algoritmaları kullanılmaktadır. Performans karşılaştırmaları için "Ortalama Mutlak Hata, MAE", "Ortalama Mutlak Ölçekli Hata, MASE", "Ortalama Mutlak Yüzde Hatası, MAPE", "Hata Kareler Ortalaması, MSE", "Hata Oranı", "Doğruluk Yüzdesi" ve "Bileşenler Katsayıları, R²" gibi doğruluk ölçütlerinden biri kullanılabilir (Tablo 1).

Bununla birlikte sıralı ölçütekteki modellerin kurulması ve yorumlanması her zaman için sürekli ve hatta ikili olan sınıflayıcı ölçütekteki verilere göre daha zor ve karmaşıktır. Özellikle makine öğrenim yöntemlerinde sıkılıkla kullanılan lojistik regresyonda kategori sayısı artıkça kurulan ve yorumlanacak olan modellerin sayısı da artmaktadır. Aynı durum karar ağaçlarındaki katsayılar ve yapay sinir ağaçlarındaki fonksiyonlar için de geçerlidir. Literatürde sıralı ölçütekteki TEE değerinin makine öğrenim algoritmaları sonucundaki yorumlarının az ve yetersiz olması bu çalışmanın önemliliğini vurgulamıştır.

Tablo 1. Oransal ölçütekteki TEE hesaplamasında kullanılan makine öğrenme algoritmaları

Araştırmacı	Amaç	Yöntem	Tahmin/Karşılaştırma	Sonuç
Hassani ve diğerleri (2019)	Otomotiv kablo üretim endüstrisinden alınan veriler ile TEE tahmini ve performans karşılaştırılması	DVM, RO, XGBoost, DO	TEE değeri MAE ve MAPE	DO RO
Eroğlu (2019)	Dokuma endüstrisinde her bir süreç için TEE tahminleri	ÇDR	Hata Oranı (%17,31)	
Him ve diğerleri (2020)	Bakım simülasyonu verileri ile makine arızasına ait TEE tahmini	KA: CART	TEE değeri	
Engelmann ve diğerleri (2020)	Küçük ve orta ölçekli bir şirketin türetilmiş verisinde TEE tahmini ve performans karşılaştırılması	KA, LogR, NB, DVM	Doğruluk KA: % 92.8	
Acosta ve diğerleri (2020)	Üretim modellerinde TEE tahmini	DVM	Doğruluk DVM: %99,9	
Dobra ve Jósvai (2022)	Yarı otomatik montaj hattı seri üretiminin ürün değiştirme süreçlerine üzerine etkisinde TEE tahmini	KA	TEE değeri	
Yılmaz ve Kuvat (2023)	Kutu fabrikasının oluklu mukavva bölümünün TEE tahmini	ÇDR, GA, RO, MSE ve R ² RR, Lasso Reg., Elastik Net ÇDR	ÇDR	

Destek Vektör Makinesi: DVM, Lojistik Regresyon: LogR, Rassal Orman: RO, Çoklu Doğrusal Regresyon: ÇDR, Karar Ağacı: KA, Naive Bayes: NB, Genetik Algoritma: GA, Ridge Regresyon: RR; K Kümeleme: KK, Derin Öğrenme: DO

3. YÖNTEM

Çalışma kapsamındaki veriler İzmir ilinde plastik üretim sektöründen alınan 2018-2019 yılları arasındaki orjinal veriler ($n=215$) baz alınarak türetilmiştir. Çalışmada türetilmiş veriler kullanıldığından etik kurul izni gerekmemiştir. Türetilmiş veri için ilk olarak her ay ve tüm veri için sürekli olan orjinal bağımsız değişkenlerin tanımlayıcı istatistikleri Minitab 21 paket programında bulunmuş (ortalama, standart sapma, ortanca vb..) ve bu değişkenlerin TEE puanı ile olan korelasyon matrisi elde edilmiştir. Bu korelasyon matrisindeki ilişkiler dikkate alınarak her ay için sürekli bağımsız değişkenlerin parametre değerleri normal dağılım kullanılarak elde edilmiştir. Parametre değerleri için önceden bulunmuş tanımlayıcı istatistiklerden yararlanılmıştır. Makine öğrenim algoritmalarında kullanılacak olan örneklemelerde veri sayısının büyük olması performans karşılaştırması için önemlidir. Performans karşılaştırmasında örnekleminden rassal olarak elde edilen yeni örneklemelerin performans kriterleri elde edilecek ve bu kriterlere göre karşılaştırma yapılacağından veri setinde tekrarlara düşmemek adına veri setinin büyük olması önemlidir. Sonuçta eğitim ve test verilerinin daha güvenilir olması adına türetilen yeni verinin örneklem genişliği, orjinal verinin yaklaşık üç katından fazla olacak şekilde 700 örneklem biriminden ve 6 farklı bağımsız değişkenden oluşturulmuştur. Veri setinde sonuç değişkeni üretim verilerine ait 0 ile 100 arasında değişen "Toplam Ekipman Etkinliği (TEE)" puanlarıdır. TEE puanları işletmede günlük olarak kalite mühendisi tarafından her makine için kullanılabilirlik, performans ve kalite ölçütleri dikkate alınarak yüzde olarak hesaplanmıştır. Kullanılabilirlik ölçüyü içinde ekipmana ait sebepler, performans ölçütünde çalışma hızına ait planlanmış duruş ile gerçekleşen durum arasındaki farklar ve kalite ölçütü içinde de işlenen parçalardan oluşan kayıplar dikkate alınmıştır. Açıklayıcı değişkenler için firmanın çalışma zamanında öngördüğü faktörlerden "ürüm (metre)", "kayıp metre (metre)", "tecrübe (yıl)", "mevsim", "gün" ve "duruş saati (saat)" değişkenleri çalışmaya dahil edilmiştir. Bu değişkenlerden "ürüm"; günlük olarak fabrikanın üretim hattındaki makinelerden çıkan masa örtüsü metresi, "kayıp metre"; günlük olarak fabrikanın üretim hattındaki makinelerden çıkan defolu&bozuk masa örtüsü metresi, "tecrübe"; verinin elde edildiği gün çalışan personelin bu işte uzmanlaştiği yıl, "mevsim"; verinin işlendiği ay, "gün"; verinin işlendiği gün ve son olarak da "saat"; verinin işlendiği gündeki duruş süresi olarak tanımlanmıştır. TEE puanı çözümlemesinde makine öğrenim algoritmalarının performans karşılaştırması %80 eğitim ve %20 test verileri kullanarak tekrarlı ölçümler (30 farklı örneklem) ile duyarlılık, seçicilik, kesinlik ve doğruluk gibi ölçütler ile SPSS 24 paket programında %5 anlamlılık düzeyinde yapılmıştır.

TEE verisinin istatistiksel çözümlemeleri için kullanılan yöntemler büyük veri ve veri madenciliği kavramı ile açıklanmaktadır. 1990'ların başlarından beri kullanılan veri madenciliği disiplinler arası bir çalışma alanı olduğundan yapay zekâ ve istatistik çalışmalarında yer almaktadır. Özellikle istatistik ve bilgisayar kullanımının birleştiği makine öğrenmesi (ML), verileri ayırtmak, bu verileri öğrenmek ve öğrenciklerine göre bilişli kararlar vermek için algoritmalar kullanan bir sistem olarak tanımlanmaktadır (Grossfeld, 2020). Ayrıca makine öğrenmesi ile kullanılan algoritmalar sayesinde karar verme süreçleri otomatikleşerek yeni modellerin üretilmesi bir avantaja dönüştürmektedir (Şapçı ve Taşlı Pektaş, 2021).

Literatürde basitçe denetimli ve denetimsiz olarak ayrılan makine öğrenim yöntemleri çok detaylı bir şekilde incelenmektedir. Denetimli öğrenmede veri kaynağından sınıflandırma yöntemiyle seçilen eğitim (girdi) verisi ile eğitilen modelin test (çıktı) verisinde performansına bakan öğrenme algoritmaları bulunmaktadır. Denetimli öğrenmede tahmin modelleri geliştirmek için girdi verisi kategorik ise sınıflandırma (destek vektör makinesi, karar ağaçları, k-en yakın komşu, Naive Bayes, lojistik regresyon, yapay sinir ağları) yöntemleri kullanılırken girdi verisinin sürekli olduğu durumda ise regresyon (doğrusal regresyon modeli, karar ağaçları, yapay sinir ağları) yöntemleri kullanılmaktadır. Girdi verilerinin sıralayıcı ölçekte olduğu kategorik verilerde uygulanan en popüler yöntem lojistik regresyon modeli, karar ağaçları algoritmaları ve yapay sinir ağlarıdır. Lojistik regresyon çıktı (bağımsız) değişkenlerine göre girdi (bağımlı) değişkeninin beklenen değerlerinin olasılık olarak elde edildiği sınıflama ve atama işlemi yapmaya yardımcı istatistiksel bir yöntemdir. Lojistik regresyon modeli, değişkenlere ait katsayıların "en çok olabilirlik" yöntemiyle tahmin edildiği bir yöntemdir. Bu modelde katsayıların anlamlılığı için "olabilirlik oran testi" ya da "Wald testi" kullanılırken, katsayıların yorumlanması için de "odds" ve "odds oranı (OR)" ölçütlerinden yararlanılmaktadır. Odds bir olayın gerçekleşme olasılığının o olayın gerçekleşmemeye olasılığına oranı olarak tanımlanmaktadır. Odds oranı ise ilgilenilen olayın odds'unun referans kategorisindeki olayın odds'una oranı şeklindedir. Odds oranı üç farklı aralıkta hesaplanabilir. Bu oran, 0 ile 1 arasında ise bağımsız değişkenin bağımlı değişken için "koruyucu" faktörde olduğunu, 1'e eşit olduğu durumda ise değişkenler arasında bir fark olmadığını ifade etmektedir. Bununla birlikte yorumlamada esas çarpıcı durum odds oranının 1'den büyük olduğunda değişkenler arasında anlamlı bir fark olduğunu ifade etmesi ve bu farkın matematiksel olarak bir kat ile gösterilmesidir. Karar ağacında çok sayıda örneklemi olduğu veri kümlesi belirli kurallar dahilinde daha küçük ve homojen kümelere bölünerek (Gini, Twoing, Entropi, ki-kare) araştırmacılar tarafından daha anlaşıllır olması için görsel hale gelmiş algoritmalarıdır. Karar ağaçları; kök düğüm, iç düğüm, dal ve yaprak düğümlerinden oluşur. Kök düğüm, veri setindeki tüm örnekleri içerir (büyük ağaç oluşturma). Daha sonra ağaç dallanır ve yeni düğümler oluşur. Her dalda, yeni bir düğüm

oluşur veya bölünme durumu sona ererse yaprak düğümler oluşur (budama ve optimum ağaçın belirlenmesi). En sonunda yaprak düğümlerin oluşması ile karar ağıacı sona erer. Yapay sinir ağları yönteminde ise çok sayıda girdi değişkeni ile çalışılarak ağırlıklandırmaya yapılır. Bu ağırlıklandırmalar ile yapay sinir ağına gelen net girdi toplama fonksiyonu ile bulunur ve aktivasyon fonksiyonuna gönderilir. Sonunda girdi değişkenleri kullanılarak çıktı değişkeni oluşturulur. Hem karar ağaçında hem de yapay sinir ağlarında çıktı değişkeni üzerinde en etkili girdi değişkenleri yüzde olarak gösterildiğinden araştırmacılar tarafından sıkılıkla tercih edilen yöntemlerdir.

Bu çalışmada TEE'ne ait girdi verilerinin sıralayıcı ölçükte olduğu kategorik verilerde uygulanan sıralı lojistik regresyonda sınıflama ve atama modeli oluşturulurken yorumlar odds oranından yapılmıştır. Karar ağaçında ise belirli kurallar dahilinde veri kümesi daha alt gruplara bölünerek basit istatistiksel yorumlar yüzde ile yapılmış ve görselleştirmeler elde edilmiştir. Son olarak yapay sinir ağlarında TEE'nin kategorilerinde önemli bulunan girdi değişkenlerinin önem seviyeleri yüzde ile ifade edilmiştir. Performans karşılaştırması için modellerin sonuçları tablo ve grafikler ile verilmiştir.

4. BULGULAR

TEE çözümlemesi için ilk olarak orjinal verinin ($n=215$) tanımlayıcı istatistikleri elde edilmiştir. Buna göre üretim metresi (67663 ± 24501), TEE puanı ($84,90 \pm 14,05$), saat ($2,53 \pm 2,83$) ve kayıp metre (10728 ± 13524) değişkenleri için ortalama ve standart sapma değerleri hesaplanmıştır. Aynı veri setinde çalışma günü olarak en yüksek günün perşembe (%19,5) ve en düşük günün de cumartesi (%13) olduğu, %59'unun 10 yıldan fazla bir tecrübe sahibi olduğu ve %30 ile en fazla sonbahar ayında, %19 ile de en az kiş ayında üretim gerçekleştiği bilgisi elde edilmiştir. Ayrıca medyan değerleri saat için 1,9 saat, kayıp metre için 7660 metre ve üretim için 79510 metre olarak hesaplanmıştır. Ek olarak TEE dışındaki tüm değişkenlerin birbiri ile olan çoklu bağlantısı için korelasyon katsayı değerlerine bakılmış, saat dışında tüm değişkenler birbiri ile bağıntısız olarak bulunmuştur. Saat değişkeninin de buna göre makine öğrenim yöntemlerinde modellenmesi sağlanmıştır.

Tablo 2. Tanımlayıcı istatistikler (frekans, f, %) ve ki-kare testi p-değerleri

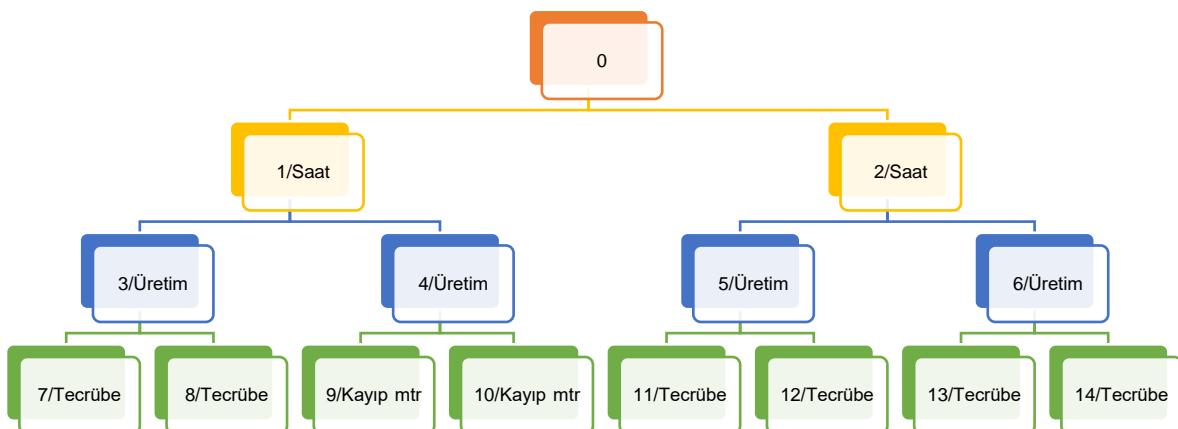
Değişken	f(%)	$\leq 83(f_1=219)$ (%31,3)Düşük	$84-91(f_2=243)$ (%34,7)Normal	$\geq 92(f_3=238)$ (%34,0)Yüksek	p-değeri
Üretim					
0 (düşük)	347(49,6)	178(81,3)	96(39,5)	73(30,7)	0,000*
1 (yüksek)	353(50,4)	41(18,7)	147(60,5)	165(69,3)	
Kayıp mtr					
0 (düşük)	484(69,1)	85(38,8)	165(67,9)	234(98,3)	0,000*
1 (yüksek)	216(30,9)	134(61,2)	78(32,1)	4(1,7)	
Tecrübe					
<10 yıl	288(41,1)	155(70,8)	49(20,2)	84(35,3)	0,000*
>10 yıl	412(58,9)	64(29,2)	194(79,8)	154(64,7)	
Mevsim					
Kış	125(17,9)	35(16,0)	43(17,7)	47(19,7)	0,000*
İlkbahar	203(29,0)	73(33,3)	60(24,7)	70(29,4)	
Yaz	157(22,4)	62(28,3)	64(26,3)	31(13,0)	
Sonbahar	215(30,7)	49(22,4)	76(31,3)	90(37,8)	
Gün					
Pazartesi	105(15,0)	56(25,6)	28(26,7)	21(20,0)	0,000*
Salı	113(16,1)	57(26,0)	29(11,9)	27(11,3)	
Çarşamba	133(19,0)	37(16,9)	36(14,8)	60(25,2)	
Perşembe	136(19,4)	28(12,8)	62(25,5)	46(19,3)	
Cuma	117(16,7)	16(7,3)	47(19,3)	54(22,7)	
Cumartesi	96(13,7)	25(11,4)	41(16,9)	30(12,6)	
Saat					
0 (düşük)	350(50,0)	56(25,6)	71(29,2)	223(93,7)	0,000*
1 (yüksek)	350(50,0)	163(74,4)	172(70,8)	15(6,3)	

Daha sonra türetilmiş veri ($n=700$) oluşturulmuş ve bu veri setini oluşturan örnekleme ait değişkenlerin istatistikleri elde edilmiştir. Sürekli veriler için normalilik testi (Shapiro Wilk) uygulanmış ve normal olmayan değişkenler kategorik hale getirilmiştir. Buna göre TEE puanı 1: düşük (≤ 83 ; %31,3), 2: normal ($84-91$; %34,7) ve 3: yüksek (≥ 92 ; %34,0) olmak üzere sıralı ölçükteki kategoriye dönüştürülmüştür. "Üretim", "kayıp metre" ve "saat" değişkenleri de medyan değerlerine göre ikili kategorik değişken haline (medyan değerinden düşük ya da yüksek olmasına göre) getirilmiştir. Mevsim (4 kategori) ve gün (6 kategori)

değişkenleri de kategorilere ayrılmıştır (Pazar hariç). TEE puanı ile değişkenler arasında istatistiksel ilişki %95 güvenle ki-kare ile tespit edilmiştir ($p=0,00<0,05$) (Tablo 2).

TEE puanı ve ilişkili değişkenler için makine öğrenim yöntemleri kullanılarak modeller kurulmuştur. Buna göre CART ve CHAID algoritmaları sonucunda kurulan karar ağaçlarında “üretim”, “kayıp metre”, “tecrübe” ve “saat” değişkenleri gözlemlenmiştir. Her iki karar ağacın algoritmalarında ilk dallanma duruş zamanlarını dikkate alan “saat” değişkeni üzerinden gerçekleşmiş olup iki algoritmda da 12. düğüme kadar olan dallanma ve düğümlere ait yüzdelerin aynı olduğu gözlemlenmiştir (Tablo 3). CHAID algoritmasında ise CART algoritmasından farklı olarak 13. ve 14. düğüm oluşmuştur (Şekil 1). Bununla birlikte CART karar ağacı için 8 (7., 8., 9., 10., 11., 12., 13. ve 14.), CHAID için ise 7 (6., 7., 8., 9., 10., 11. ve 12.) terminal düğüm bulunmuştur.

CART ve CHAID karar ağaçlarında değişkenlerinin TEE puanı üzerindeki pozitif ve negatif yönde ilişkileri gösterilmiştir. İlk olarak saat değişkeninin 2. düğümündeki “düşük” kategorisinde verilerin %63,7’lik oranı ile “yüksek” TEE kategorisinde yer aldığından bu değişkeninin TEE puanı üzerindeki etkisinin negatif yönlü olduğu tespit edilmiştir. Sırasıyla sonraki dallanmalar “üretim” ve “kayıp metre” değişkenleri üzerinden gerçekleşmiştir. 9. ve 10. düğümler dikkate alındığında “kayıp metre” değişkeni yüksekse TEE’nin “yüksek” kategorisinde gözlemin olmaması ve “kayıp metre” değişkeni düşükse TEE’nin “düşük” kategorisinde gözlemin olmaması bu değişkeninin TEE puanı üzerindeki etkisinin negatif yönde olduğunu göstermiştir. Üretim değişkeninin yönü ise 5. ve 6. düğümler ile bulunmuştur. Üretim değişkeninin “yüksek” kategorisine göre dallanma olduğunda (6. düğümde) %88,8’lik gibi büyük bir oranla TEE’nin “yüksek” kategorisine düşüğü tespit edilmiştir. Bu da “üretim” değişkenin TEE puanı üzerindeki etkisinin pozitif yönde olduğunu göstermiştir (Tablo 3). CHAID karar ağacında CART karar ağacından farklı olarak, 6. düğümün “tecrübe” değişkeni üzerinden dallanma gerçekleştirerek bu değişkenin TEE puanı üzerindeki etkisinin pozitif yönde olduğunu göstermiştir (Şekil 1, Tablo 3).



Şekil 1. CART ve CHAID için karar ağaçları modeli

Sonuç olarak “saat” ve “kayıp metre” değişkenlerinin TEE puanı üzerindeki etkisi negatif yönde bulunurken “üretim” ve “tecrübe” değişkenlerinin bu puan üzerindeki etkisinin pozitif yönde olduğu CART ve CHAID karar ağaçları ile tespit edilmiştir.

TEE puanı için kurulan sıralı lojistik regresyon modellerinde bu puan üç (düşük, normal, yüksek) farklı kategoride olduğundan iki farklı lojistik regresyon modeli kurulmalıdır. İlk kurulan sıralı lojistik regresyon modelinde (Tablo 4) TEE’nin düşük kategorisi (≤ 83) referans olarak alınırken diğer sıralı lojistik regresyon modelinde (Tablo 5) TEE’nin yüksek kategorisi (≥ 92) referans olarak alınmıştır. Modelde referans alınan kategori, diğer kategorilerle karşılaştırılarak model içerisinde bölgeler oluşmaktadır. Buna göre TEE’nin düşük kategorisinin referans olduğu birinci lojistik regresyon modelinde TEE’nin normal ve yüksek kategorisi için “üretim”, “kayıp metre” ve “tecrübe” değişkenlerinden oluşan iki ayrı yorumlanabilir bölüm vardır. Aynı şekilde TEE’nin yüksek kategorisinin referans olduğu ikinci lojistik regresyon modelinde de TEE’nin bu sefer düşük ve normal kategorisi için “üretim”, “kayıp metre” ve “tecrübe” değişkenlerinden oluşan iki ayrı bölüm bulunmaktadır.

Tablo 3. Karar ağaçları (CART ve CHAID) için istatistikler (frekans, f, %)

Düğüm No	Düğüm Değişkeni	Düşük	Normal	Yüksek	Toplam f(%)
0		219(31,3)	243(34,7)	238(34,0)	700(100)
1	Saat yüksek	163(46,6)	172(49,1)	15(4,3)	350(50,0)
2	Saat düşük	56(16,0)	71(20,3)	223(63,7)	350(50,0)
3	Üretim düşük	127(76,5)	39(23,5)	0(0,0)	166(23,7)
4	Üretim yüksek	36(19,6)	133(72,3)	15(8,2)	184(26,3)
5	Üretim düşük	51(28,2)	57(31,5)	73(40,3)	181(25,9)
6	Üretim yüksek	5(3,0)	14(8,3)	150(88,8)	169(24,1)
7	Tecrübe <10 yıl	88(95,7)	4(4,3)	0(0,0)	92(13,1)
8	Tecrübe >10 yıl	39(52,7)	35(47,3)	0(0,0)	74(10,6)
9	Kayıp mtr yüksek	36(39,6)	55(60,4)	0(0,0)	91(13,0)
10	Kayıp mtr düşük	0(0,0)	78(83,9)	15(16,1)	93(13,3)
11	Tecrübe <10 yıl	42(58,3)	14(19,4)	16(22,2)	72(10,3)
12	Tecrübe >10 yıl	9(8,3)	43(39,4)	57(52,3)	109(15,6)
13	Tecrübe <10 yıl	3(4,1)	3(4,1)	68(91,9)	74(10,6)
14	Tecrübe >10 yıl	2(2,1)	11(11,6)	82(86,3)	95(13,6)

Sıralı lojistik regresyonde bağımsız değişkenlerin bağımlı değişken üzerindeki yorumu için odds oranından (OR) yararlanılmaktadır. Buna göre TEE'nin düşük kategorili sıralı lojistik regresyon modelinde üretimi yüksek olanların üretimi düşük olanlara göre yaklaşık $(1/0,080)=12,5$ kat daha "normal TEE" puanı alma şansı ile yaklaşık $(1/0,042)=23,8$ kat daha "yüksek TEE" puanı alma şansı olduğu bulunmuştur. Kayıp metresi düşük olanların kayıp metresi yüksek olanlara göre yaklaşık 5,8 kat daha "normal TEE" puanı alma şansı ile yaklaşık 186,5 kat daha "yüksek TEE" puanı alma şansı olduğu da tespit edilmiştir. Son olarak tecrübe yüksek olanların tecrübesi düşük olanlara göre yaklaşık $(1/0,086)=11,6$ kat daha "normal TEE" puanı alma şansı ile yaklaşık $(1/0,191)=5,2$ kat daha "yüksek TEE" puanı alma şansı olduğu odds oranı ile bulunmuştur (Tablo 4).

Tablo 4. Sıralı lojistik regresyon modeli (TEE: referans: düşük-1)

	B	Sd	Wald	p değeri	OR %95 GA
TEE: normal-2					
Üretim					
0 (düşük)	-2,531	0,288	77,047	0,000	0,080(0,045-0,140)
Kayıp metre					
0 (düşük)	1,759	0,273	41,635	0,000	5,808(3,404-9,912)
Tecrübe					
0 (düşük)	-2,458	0,256	91,999	0,000	0,086(0,052-0,141)
TEE: yüksek-3					
Üretim					
0 (düşük)	-3,162	0,313	101,899	0,000	0,042(0,023-0,078)
Kayıp metre					
0 (düşük)	5,228	0,562	86,670	0,000	186,5(62,02-560,55)
Tecrübe					
0 (düşük)	-1,658	0,275	36,366	0,000	0,191(0,111-0,327)

TEE referans değeri: düşük-1; Referanslar: üretim (yüksek), kayıp metre (yüksek), tecrübe (yüksek)

TEE'nin yüksek kategorili sıralı lojistik regresyon modelinde ise, düşük üretimde olanların yüksek üretimde olanlara göre 23,6 kat daha "düşük TEE" puanı alma şansı ile yaklaşık 1,9 kat daha "normal TEE" puanı alma şansı olduğu tespit edilmiştir. Kayıp metresi yüksek olanların kayıp metresi düşük olanlara göre de yaklaşık $(1/0,005)=200$ kat gibi çok yüksek bir oranda daha "düşük TEE" puanı alma şansı varken yine yaklaşık $(1/0,031)=31,3$ kat ile daha "normal TEE" puanı alma şansının olduğu bulunmuştur. Ayrıca düşük tecrübe bililerin yüksek tecrübe bililere göre 5,2 kat daha "düşük TEE" puanı ile $(1/0,449)=2,2$ kat daha "normal TEE" puanı alma şansı olduğu hesaplanmıştır (Tablo 5).

Tablo 5. Sıralı lojistik regresyon modeli (TEE: referans: yüksek-3)

	B	Sd	Wald	p değeri	OR %95 GA
TEE: düşük-1					
Üretim					
0 (düşük)	3,162	0,313	101,899	0,000	23,61(12,78-43,63)
Kayıp metre	-5,228	0,562	86,670	0,000	0,005(0,002-0,016)
Tecrübe					
0 (düşük)	1,658	0,275	36,366	0,000	5,247(3,06-8,99)
TEE: normal-2					
Üretim					
0 (düşük)	0,631	0,206	9,344	0,002	1,879(1,25-2,81)
Kayıp metre	-3,469	0,527	43,275	0,000	0,031(0,01-0,09)
Tecrübe					
0 (düşük)	-0,800	0,228	12,340	0,000	0,449(0,29-0,70)

TEE referans değeri: yüksek-3; Referanslar: üretim (yüksek), kayıp metre (yüksek), tecrübe (yüksek)

Son olarak sıralı ölçekteki TEE puanı için makine öğrenimi yöntemlerinden çok katmanlı yapay sinir ağları (YSA) algoritması kullanılmıştır. Çok katmanlı yapay sinir ağında her bir bağımsız değişkene karşılık gelen giriş katmanı, doğrusal olmayan ilişkileri çözen gizli katmanlar ve tahmin edilen sınıflandırmayı içeren çıkış katmanı bulunmaktadır. Çok katmanlı yapay sinir ağ ile hata en aza indirgenmektedir. Giriş hücresindeki bilgiler ara katmanlara ağırlıklı toplam fonksiyona göre aktarılır ve çıkış katmanına aktivasyon fonksiyonu ile geçirilir. Buna göre TEE puanı içeri oluşturulan YSA modelinde aktivasyon fonksiyonu ara katmandaki hyperbolic tangent, çıktı katmanında ise softmax olarak belirlenmiştir. TEE'nin puanları üzerinde değişkenlerin önemlilikleri incelendiğinde 7 birimden oluşan tek katmanlı YSA modelinde yaklaşık %32 ile "ürütim", %27 ile "kayıp metre", %21 ile "tecrübe" ve %20 ile "saat" değişkenlerinin olduğu saptanmıştır. Ayrıca 7 ve 5 birimden oluşan iki katmanlı YSA modelinde ise değişkenlerin önemlilikleri tek katmanlı ile benzer olup yaklaşık olarak %34 ile "ürütim", %30 ile "kayıp metre", %20 ile "tecrübe" ve %16 ile "saat" değişkenlerinin olduğu bulunmuştur.

Sıralı ölçekteki TEE puanı için kurulan makine öğrenim algoritmalarına ait performansların karşılaştırılmasında istatistiksel ölçütler kullanılmıştır. Buna göre, kesinliği en yüksek olan kategori, lojistik regresyon algoritmasında 0,779 ile TEE'nin "normal" kategorisi olarak bulunmuştur. TEE'nin "normal" kategorisinde lojistik regresyondan sonra en yüksek başarı YSA tarafından elde edilmiştir. Bununla birlikte lojistik regresyonda TEE'nin "düşük" ve "yüksek" kategorisinde aynı başarı yüzdesi bulunamamıştır. Bunu CHAID algoritması ile TEE'nin "yüksek" kategorisi 0,752 ile takip etmiştir. Duyarlılıkta ise TEE'nin "normal" kategorisi tüm algoritmalar da en düşük değer olarak gözlemlenmiştir. Sadece TEE'nin "yüksek" kategorisinde iki katmanlı YSA 0,886 değerini ve lojistik regresyon ise 0,877 değerini elde edilmiştir. Seçicilikte en yüksek olan kategori lojistik regresyon algoritmasında 0,920 ile TEE'nin "normal" kategorisi olarak bulunmuştur. Doğrulukları karşılaştırdığımızda ise en yüksek "doğruluk" 0,732 ile lojistik regresyon algoritmasında tespit edilmiştir. Bunu sırasıyla CHAID, CART ve YSA algoritmaları takip etmiştir (Tablo 6).

Tablo 6. CART, CHAID, lojisik regresyon ve YSA algoritmalarının performans değerleri

Performans	CART	CHAID	Lojistik Regresyon	YSA/Tek Katman	YSA/İki Katman
Kesinlik					
Düşük-1	0,698	0,718	0,695	0,668	0,648
Normal-2	0,716	0,716	0,779	0,738	0,750
Yüksek-3	0,741	0,752	0,734	0,713	0,750
Duyarlılık					
Düşük-1	0,756	0,762	0,822	0,761	0,745
Normal-2	0,537	0,563	0,510	0,517	0,559
Yüksek-3	0,876	0,868	0,877	0,863	0,886
Seçicilik					
Düşük-1	0,853	0,863	0,834	0,808	0,815
Normal-2	0,882	0,880	0,920	0,889	0,879
Yüksek-3	0,843	0,851	0,845	0,832	0,877
Doğruluk	0,718	0,730	0,732	0,703	0,713

Sonuç olarak sıralı ölçekteki TEE puanı için kullanılan makine öğrenim yöntemlerinde tüm performanslar dikkate alındığında lojisik regresyon modelinin çeşitli istatistiksel ölçütlere göre en iyi sonucu verdiği tespit edilmiştir.

5. SONUÇ ve DEĞERLENDİRME

Günümüzde firmalar, müşteri, maliyet ve rakabet bileşenlerinin sebep olduğu zorlu koşullar altında faaliyetlerini devam ettirmektedirler. Özellikle müşteri beklenileri ve yatırım harcamaları firma maliyetlerini artırmaktadır. Bu da firmaları makine ve ekipmanlarını daha etkin bir şekilde kullanmaya önem vermek zorunda bırakmaktadır. Firmaların TEE puanı için verdikleri bu performans göstergelerini her yıl belirlemeleri ve bu puanı artırıcı çalışmalarda bulunmaları diğer firmalarla rekabet edebilmeleri açısından önemlidir. Bugüne kadar yapılmış üretim sektöründeki uygulamalarda TEE puanı sürekli olarak hesaplanmış, klasik yöntemler veya belli başlı makine öğrenim algoritmaları ile çözümlenmiştir.

Bu çalışmanın amacı üretim sektöründe sürekli olarak modellenen TEE puanını kategorik hale getirerek toplam ekipman etkinliğinin sınıfları arasındaki farkın firmalardaki yerini makine öğrenim algoritmaları ile nasıl yorumlanacağını göstermektedir. Çalışmada makine öğrenim algoritmalarından sınıflandırma, karar ağaçları ve yapay sinir ağları kullanılmıştır.

Üretim sektörlerine bağlı olarak farklı makine öğrenim algoritmaları kullanılabilir. Bunun için sektörlerde bağlı makine öğrenme algoritmaları birebir bulunmamasına karşın bazı üretim sektörlerinde kategorik bağımlı değişkenin olması ile özellikle sınıflandırma algoritmalarının kullanımı öne geçmektedir. Bununla birlikte sadece bağımlı değişkenin (çıkıtı) değil bağımsız değişkenlerinde (giriş) ölçek durumu ve sayısından dolayı daha kolay yorumlanabilmesi açısından karar ağaçları tercih edilebilir. Bağımlı değişkenin kategorik olduğu ve girdi değişkenlerinin çıktı değişkeni üzerindeki etkilerini oransal (odds oranı) olarak görmek için de sınıflandırma algoritmalarından lojistik regresyon modeli kullanılması kaçınılmazdır.

Maden üretim sektörü gibi pahalı sektörlerde TEE puanını artırmak için bir anda yenileme, geliştirme ve iyileştirme yapılamayacağından TEE puanının yavaş yavaş artırılmasıyla özellikle mali sonuçları görmek faydalı olabilir. Bu amaçla TEE puanı kategori olarak belirlenip bir sonraki kategoriye geçmek için özellikle hangi değişkenlerin nasıl bir boyutta değiştirileceğini görmek adına makine öğrenim yöntemlerinden lojistik ya da karar ağaçlarını kullanmak avantaja dönüşebilir. Bu çalışma ile bunun yapılabileceği gösterilmiştir. Ayrıca tekstil sektörü gibi bileşenleri çok fazla olan üretim sektörlerinde makine öğrenim algoritmaları ile TEE puanının kategorisinin belirlenerek en önemli değişkenin hangisi olduğu ve bu değişkenler üzerinde ilk olarak hangisine dikkat edilmesi gerekliliği karar ağaçları ya da yapay sinir ağları ile karar verilebilir.

Buna benzer şekilde literatürde çelik üretiminde planlı duruş süresinin hesaplanması TEE'ne yeni bir yaklaşımın kullanılabilirlik'teki düzeltme ile klasik yöntemlerle yapıldığı gösterilmiştir (Çelik, 2020). Ancak bu çalışmada gibi TEE kategorisi belirlenerek duruş süresi üzerinde hangi boyutta değişim gösterilerek yoğunlaşılacağı yüzdelerle veya oranlarla belirlenip alternatifler sunulabilir. Otomotiv üretim verisinde de rassal orman yöntemi kullanılarak TEE değeri ve performansı hesaplanmıştır (Hassani ve diğerleri, 2019: 2). Yine bu çalışmada olduğu gibi TEE kategorisi yüzdelerle belirlenerek hangi kategorisinin daha yüksek olduğu performans değerlerine bağlı olarak açıklanabilir. Bu çalışma için de sıralı ölçekte olan TEE puanı için üretim sektöründe olan bu firmaya sıralı lojistik regresyon modeli için yapılan yorumlar sunulabilir. Bu yorumlar firmanın normal TEE kategorisinde olan değerden yüksek TEE kategorisinde olan değere geçebilmesi için özellikle kayıp metresini azaltması ve makineyi işleyen çalışanların tecrübesini artırması şeklinde basitçe ifade edilebilir.

Sonuç olarak firmalar TEE kategorisini bildiği durumda veri setine ve amacına uygun makine öğrenim algoritmaları ile o kategoriden yükselme ya da aynı kalma durumu için yapabileceklerini TEE puanı üzerinde etkili olan değişkenleri kontrol altına tutarak gerçekleştirebilir. Ayrıca etkili olan değişkenlerin etki güçlerine bakılarak karar verme süreçlerinde daha hızlı, çarpıcı ve etkili kararlar alınabilir. Ortaya çıkan bu sonuçlar doğrultusunda araştırmacılar için sektör ve şirket bazında çalışmanın devamında çeşitli öneriler verilebilir. TEE, sanayi&imalat sektörünün birçok alt dalında kullanılmaktadır. Bu çalışmada kimya endüstrisinin üretim sektöründe kullanılmasına karşın piyasada yer alan tekstil ve konfeksiyon, gıda, metal eşya ve makine, seramik, cam ve taş ürünleri, kağıt ve kağıt ürünleri, ağaç ve mobilya ürünleri ve son olarak metal sanayi gibi farklı sektörler seçilerek çeşitli makine öğrenim algoritmalarının kullanılması ve o sektörde ait algoritma veya analizin belirlenmesi veya şirketlerin bir yıllık verisinden daha fazla verisinin toplanarak mevsimselliği, zamanı, trendi vb durumları dikkate alan zaman serisi bileşenlerinin olduğu modellerin kurulması da önerilmektedir. Ayrıca TEE'nin kategorik olarak belirlenmesi ile özellikle TEE'ni iyileştirme durumunda olan şirketlerin parametrelerini daha kolay yorumlayabilecekleri görselliği yüksek daha farklı karar ağaçları modellerinin kullanılması gelecek çalışmalar için planlanabilir. Bununla birlikte kategorik olarak modellenen TEE'nin kendi sektöründeki diğer şirketler ile olan karşılaştırılması ve kategori atlaması için yapması gereken iyileştirmeleri için en uygun makine öğrenme yöntemlerinden biri olan lojistik regresyon modeline ait çalışmalar yapılabilir. Son olarak veri setinin örneklem büyülüğu ve parametrelerinin artırılmasıyla akan (güçlendirilen) veride şirket yöneticilerinin TEElarındaki kararlarına yön veren algoritmaların ve modellerin bilgisayar destekli olarak programlarının yazılması büyük verinin çözümlenmesi açısından gelecek çalışmalarla önerilmektedir.

Yazar Katkıları / Author Contributions

Özgül Vupa Çilengiroğlu: Literatür Taraması, Kavramsallaştırma, Metodoloji, Analiz, Makale Yazımı-inceleme ve düzenleme İlke Genç: Literatür Taraması, Modelleme, Analiz, Makale Yazımı-orijinal taslak
Özgül Vupa Çilengiroğlu: *Literature Review, Conceptualization, Methodology, Analysis, Writing-review and editing* İlke Genç: *Literature Review, Modelling, Analysis, Writing-original draft*

Çalışma Beyanı / Conflict of Interest

Yazarlar tarafından herhangi bir potansiyel çıkar çatışması beyan edilmemiştir.

No potential conflict of interest was declared by the authors.

Fon Desteği / Funding

Bu çalışmada herhangi bir resmi, ticari ya da kâr amacı gütmeyen organizasyondan fon desteği alınmamıştır.

Any specific grant has not been received from funding agencies in the public, commercial, or not-for-profit sectors.

Etik Standartlara Uygunluk / Compliance with Ethical Standards

Yazarlar tarafından, çalışmada kullanılan araç ve yöntemlerin Etik Kurul izni gerektirmediği beyan edilmiştir.

It was declared by the authors that the tools and methods used in the study do not require the permission of the Ethics Committee.

Etik Beyanı / Ethical Statement

Yazarlar tarafından bu çalışmada bilimsel ve etik ilkelere uyulduğu ve yararlanılan tüm çalışmaların kaynakçada belirtildiği beyan edilmiştir.

It was declared by the authors that scientific and ethical principles have been followed in this study and all the sources used have been properly cited.



Yazarlar, Verimlilik Dergisi’nde yayımlanan çalışmalarının telif hakkına sahiptirler ve çalışmaları CC BY-NC 4.0 lisansı altında yayımlanmaktadır.

The authors own the copyright of their works published in Journal of Productivity and their works are published under the CC BY-NC 4.0 license.

KAYNAKÇA

- Abdelbar, K.M., Bouami, D., Elfezazi, S. (2019). "New Approach towards Formulation of the Overall Equipment Effectiveness", *Journal of Quality in Maintenance Engineering*, 25(1), 90-127. DOI: 10.1108/JQME-07-2017-0046
- Acar, Ö. ve Çakırkaya, M. (2018). "Bir Üretim Hattında Toplam Ekipman Etkinliğinin Ölçülmesi ve Geliştirilmesi Üzerine Bir Uygulama", *Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü Elektronik Dergisi*, 9(24), 217-230.
- Acosta, C.P., Terán, H.C., Arteaga, O. ve Terán, M.B. (2020). "Machine Learning in Intelligent Manufacturing System for Optimization of Production Costs and Overall Effectiveness of Equipment in Fabrication Models", *Journal of Physics: Conference Series*, 1432. DOI: 10.1088/1742-6596/1432/1/012085
- Akçacı, T. ve Özürt, S. (2021). "Yalın Üretime Geçiş: İplik Sektöründe Bir Uygulama", *İşletme ve İktisat Çalışmaları Dergisi*, 9(2), 85-103.
- Becker, J.M., Borst, J. ve Veen, A. (2015). "Improving the Overall Equipment Effectiveness in High-Mix-Low-Volume Manufacturing Environments", *CIRP Annals*, 64(1), 419-422.
- Braglia, M., Frosolini, M. ve Zammori, F. (2009). "Overall Equipment Effectiveness of a Manufacturing Line (OEEML): An Integrated Approach to Assess Systems Performance", *Journal of Manufacturing Technology Management*, 20(1), 8-29. DOI: 10.1108/17410380910925389
- Corrales, L.C., Lambán, M.P., Hernandez Korner, M.E., Royo, J. (2020). "Overall Equipment Effectiveness: Systematic Literature Review and Overview of Different Approaches", *Applied Science*, 10, 6469. DOI: 10.3390/app10186469
- Costa, J. ve Cardoso, J. (2005). "Classification of Ordinal Data Using Neural Networks", *16th European Conference on Machine Learning*, Porto, Portugal, October 3-7, 2005 Proceedings, 690-697. ISBN-13 978-3-540-29243-2 Springer Berlin Heidelberg New York. DOI: 10.1007/11564096_70
- Çelik, H. (2019). "5S Uygulamalarının Ayar Süreleri ve Toplam Ekipman Etkinliğine Etkisi", *Yorum Yönetim Uluslararası Yönetim Ekonomi ve Felsefe Dergisi*, 7(2), 95-110.
- Çelik, H. (2020). "Ekipman Etkinliğine Farklı Bir Yaklaşım: Genel Operasyon Etkinliği", *Verimlilik Dergisi*, 4, 25-40. DOI: 10.51551/verimlilik.560600
- Dobra, P. ve Jósvai, J. (2022). "Predicting the impact of type changes on Overall Equipment Effectiveness (OEE) through machine learning", 2022 IEEE 1st International Conference on Internet of Digital Reality, 23-24 June. DOI: 10.1109/IOD55468.2022.9986645
- Domingo, R. ve Aguado, S. (2015). "Overall Environmental Equipment Effectiveness as a Metric of a Lean and Green Manufacturing System", *Sustainability*, 7, 9031–9047. DOI: 10.3390/su7079031
- Engelmann, B., Schmitt, S., Miller, E., Bräutigam, V. ve Schmitt, J. (2020). "Advances in Machine Learning Detecting Changeover Processes in Cyber Physical Production Systems", *J. of Manufacturing and Materials Processing*, 4(108). DOI: 10.3390/jmmp4040108
- Ersöz, F. ve Çınar, Y. (2021). "Veri Madenciliği ve Makine Öğrenimi Yaklaşımlarının Karşılaştırılması: Tekstil Sektöründe bir Uygulama", *Avrupa Bilim ve Teknoloji Dergisi*, 29, 397-414. DOI: 10.31590/ejosat.1035124
- Eroğlu, D.Y. (2019). "Systematization, Implementation and Analysis of the Overall Throughput Effectiveness Calculation for the Finishing Processes After Weaving". *Tekstil ve Konfeksiyon*, 29(2), 121-132.
- García-Arca, J., Prado-Prado J.C. ve Fernández-González, A.J. (2018). Integrating KPIs for Improving Efficiency in Road Transport. *International Journal of Physical Distribution & Logistics Management*, 48(9), 931-951. DOI: 10.1108/IJPDLM-05-2017-0199
- Garza-Reyes, J.A., Eldridge, S., Barber, K.D. ve Soriano Meier, H. (2010). "Overall Equipment Effectiveness (OEE) and Process Capability (PC) Measures: A Relationship Analysis", *International Journal of Quality and Reliability Management*, 27(1), 48-62. DOI: 10.1108/02656711011009308
- Ghafoorpoor Yazdi, P., Azizi, A., Hashemipour, M. (2018). "An Empirical Investigation of the Relationship between Overall Equipment Efficiency (OEE) and Manufacturing Sustainability in Industry 4.0 with Time Study Approach", *Sustainability*, 10, 3031. DOI: 10.3390/su10093031
- Görener, A. (2012). "Toplam Verimli Bakım ve Ekipman Etkinliği: Bir İmalat İşletmesinde Uygulama", *Electronic Journal of Vocational Colleges*, 2(1), 15-20.
- Grossfeld, B. (2020). "Deep Learning vs Machine Learning". Zendesk Blog. January, 2023. <https://www.zendesk.com/blog/machine-learning-and-deep-learning/> (Erişim Tarihi: 12.03.2024).
- Hassani, I., Mazgualdi, C. ve Masrour, T. (2019). "Artificial Intelligence and Machine Learning to Predict and Improve Efficiency in Manufacturing Industry", arXiv: 1901.02256, 2019.
- Him, L.C., Poh, Y.Y. ve Pheng, L.W. (2020). "Improvement of Overall Equipment Effectiveness from Predictive Maintenance", International Conference on Digital Transformation and Applications (ICDXA).

- Kiyak Öztürk, E., Birant, K.U. ve Birant, D. (2019). "An Ordinal Classification Approach for Software Bug Prediction". *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 21(62), 533-544. DOI: 10.21205/deufmd.2019216218
- Muchiri, P. ve Pintelón, L. (2008). "Performance Measurement Using Overall Equipment Effectiveness (OEE): Literature Review and Practical Application Discussion", *International Journal of Production Research*, 46(13), 3517-3535. DOI: 10.1080/00207540601142645
- Muñoz-Villamizar, A., Santos, J., Montoya-Torres, J., Jaca, C. (2018). "Using OEE to Evaluate the Effectiveness of Urban Freight Transportation Systems: A Case Study. *International Journal of Production Economics*, 197, 232–242. DOI: 10.1016/j.ijpe.2018.01.011
- Nakajima, S. (1988). "Introduction to TPM: Total Productive Maintenance". 11th Ed. New York, USA, Productivity Press.
- Nayak, D.M., Kumar, V.M.M., Naidu, G.S. ve Sharkar, V. (2013). "Evaluation of OEE in a Continuous Process Industry on an Insulation Line in a Cable Manufacturing Unit", *International Journal of Innovative Research in Science, Engineering and Technology*, 2(5), 1629-1634.
- Özkan, N.F., Ada, E.C. ve Genlik, S. (2019). "Toplam Ekipman Etkinliğinin İyileştirilmesinde Triz Kullanımı: Bir Uygulama", *Verimlilik Dergisi*, 2, 169-184.
- Paprocka, I., Kempa, W.M., Kalinowski, K., Grabowik, C. (2015). "Estimation of Overall Equipment Effectiveness Using Simulation Programme", *IOP Conference Series: Materials Science and Engineering*, 95 (1), 1-6.
- Patel, C. ve Deshpande, V. (2016). "A Review on Improvement in Overall Equipment Effectiveness." *International Journal for Research in Applied Science & Engineering Technology*, 4, 642-650.
- Piccarreta, R. (2008). "Classification Trees for Ordinal Variables", *Computational Statistics*, 23, 407-427. DOI: 10.1007/s00180-007-0077-5
- Reyes, J.A.G. (2015). "From Measuring Overall Equipment Effectiveness (OEE) to Overall Resource Effectiveness (ORE)", *Journal of Quality in Maintenance Engineering*, 21(4), 506-527. DOI: 10.1108/JQME-03-2014-0014
- Purba, H.H., Wijayanto, E. ve Aristiara, N. (2018). "Analysis of Overall Equipment Effectiveness (OEE) with Total Productive Maintenance Method on Jig Cutting : A Case Study in Manufacturing Industry", *Journal of Scientific and Engineering Research*, 5(7), 397-406.
- Reddy, R.V.K. ve Babu, U.R. (2018). "A Review on Classification Techniques in Machine Learning", *International Journal of Advance Research in Science and Engineering*, 7(30), 40-47.
- Samoili, S., López Cobo, M., Gómez, E., De Prato, G., Martínez-Plumed, F. ve Delipetrev B. (2020). "Defining Artificial Intelligence. Towards an Operational Definition and Taxonomy of Artificial Intelligence". Luxembourg Publications Office of the European Union. ISBN 978-92-76-17045-7. DOI: 10.2760/382730
- Sarı, B.E., (2019). "Measuring The Performances of the Machines Via Preference Selection Index (PSI) Method and Comparing Them with Values of Overall Equipment Efficiency (OEE)", *İzmir İktisat Dergisi*, 34(4), 573-581.
- Singh, R.K., Clements, E.J. ve Sonwaney, V. (2018). "Measurement of Overall Equipment Effectiveness to Improve Operational Efficiency", *Int. J. Process Management and Benchmarking*, 8(2), 246-261.
- Şapçı, B. ve Taşlı Pektaş, Ş. (2021). "Makine Öğrenmesi Aracılığı ile Kullanıcı Deneyimi Bilgilerinin Erken Mimari Tasarım Süreçleriyle Bütünleştirilmesi", *Journal of Computational Design*, 2(1), 67-94.
- Tsarouhas, P.H. (2013). "Evaluation Of Overall Equipment Effectiveness in The Beverage Industry: A Case Study", *International Journal of Production Research*, 51(2), 251-253. DOI: 10.1080/00207543.2011.653014
- Udomraksasakul, C. ve Udomraksasakul, C. (2018). "Increase Improvement of Overall Equipment Effectiveness of Plastic Molding Machine", *International Journal of Mechanical Engineering and Technology*, 9(10), 1107-1113.
- Wudhikarn, R. (2016). "Implementation of the Overall Equipment Cost Loss (OECL) Methodology for Comparison with Overall Equipment Effectiveness (OEE)", *Journal of Quality in Maintenance Engineering*, 22(1), 81-93.
- Yaşın, M., Daş, G. (2017). "KOBİ'lerde Ekipman Etkinliğinin İyileştirilmesinde TEE Tabanlı Yeni Bir Yaklaşım: Bir Ahşap İşleme Kuruluşunda Uygulama", *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 32(1), 45-52.
- Yılmaz, Ü. ve Kuvat, Ö. (2023). "Investigating the Effect of Feature Selection Methods on the Success of Overall Equipment Effectiveness Prediction", *Uludağ University Journal of the Faculty of Engineering*, 28(2). DOI: 10.17482/uumfd.1296479