

PAPER DETAILS

TITLE: BİR OTOMOTİV İŞLETMESİNDE MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE KESİCİ TAKIM
ASINMASININ TAHMİNLENMESİ

AUTHORS: Merve Deniz, Feriştah Özçelik, Tuğba Saraç

PAGES: 21-46

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/4295721>



BİR OTOMOTİV İŞLETMESİNDE MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE KESİCİ TAKIM AŞINMASININ TAHMİNLENMESİ

Merve DENİZ¹, Feriştah ÖZÇELİK^{2*}, Tuğba SARAÇ³

¹Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Endüstri Mühendisliği, ESKİŞEHİR

ORCID No : <http://orcid.org/0009-0008-0298-3377>

²Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Endüstri Mühendisliği, ESKİŞEHİR

ORCID No : <http://orcid.org/0000-0003-0329-203X>

³Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Endüstri Mühendisliği, ESKİŞEHİR

ORCID No : <http://orcid.org/0000-0002-8115-3206>

Anahtar Kelimeler Öz

*Kestirimci bakım,
Kesici takım ömrü,
Yapay zeka,
Makine öğrenmesi.*

Kesici takım aşınmasını tahmin etmek ve önlemek için etkili bir yöntem geliştirmek işletmelerde üretim verimliliği açısından kritiktir. Bu çalışmada, bir otomotiv firmasında, makine öğrenmesi teknikleri kullanılarak CNC makinelerinden elde edilen veriler ile kesici takım aşınmasını tahminlemek amaçlanmıştır. Rastgele Orman Regresyonu, Gradyan Artırma Regresyonu, Aşırı Gradyan Artırma Regresyonu ve Uyarlamalı Artırma Regresyonu makine öğrenmesi modelleri kullanılmıştır. Bu modeller, veri setlerinin farklı kombinasyonlarından oluşan 3 farklı senaryo üzerinde değerlendirilmiştir. Veri setleri kesici takım ömrünün evrelerine bölünmüş ve farklı modellerin, kesici takımın farklı evrelerini daha iyi tahmin edebileceği öngörülerek denemeler yapılmıştır. Modeller, Hata Kareleri Ortalaması metriğine göre, farklı pencere büyüklükleri ve evreler için tüm senaryolarda değerlendirilmiştir. Senaryo 1'de elde edilen minimum MSE değeri 0,0242; Senaryo 2'de 0,0404; Senaryo

*Sorumlu yazar; e-posta : fdurmaz@ogu.edu.tr

doi : <https://doi.org/10.46465/endustrimuhendisligi.1569135>

3'te ise 0,0041 olmuştur. Kesici takım aşınmasının evrelere ayrılması, daha hassas bir şekilde tahmin edilmesini sağlamaktadır ve işletmelere daha doğru ve zamanında müdahale imkanı vermektedir.

PREDICTING CUTTING TOOL WEAR WITH MACHINE LEARNING TECHNIQUES IN AUTOMOTIVE INDUSTRY

Keywords	Abstract
<i>Predictive maintenance, Cutting tool life, Artificial intelligence, Machine learning.</i>	<i>Developing an effective method for predicting and preventing tool wear is critical for production efficiency in businesses. In this study, the aim is to predict tool wear using data obtained from CNC machines in an automotive company through the application of machine learning techniques. Machine learning models such as Random Forest Regressor, Gradient Boosting Regressor, Extreme Gradient Boosting Regressor, and Adaptive Boosting Regressor were used. These models were evaluated on three different scenarios composed of various combinations of datasets. The datasets were divided into phases of tool life, and experiments were conducted under the assumption that different models could better predict different phases of tool wear. The models were assessed using the Mean Squared Error metric across all scenarios for different window sizes and phases. The minimum MSE value obtained in Scenario 1 is 0.0242; in Scenario 2, it is 0.0404; and in Scenario 3, it is 0.0041. Dividing tool wear into phases allows for more precise predictions, providing businesses with the opportunity for more accurate and timely interventions.</i>
Araştırma Makalesi	Research Article
Başvuru Tarihi : 17.10.2024	Submission Date : 17.10.2024
Kabul Tarihi : 29.01.2025	Accepted Date : 29.01.2025

1. Giriş

Talaşlı imalat endüstrisinde, kesici takımların aşınması, üretim verimliliğini doğrudan etkileyen kritik bir faktördür. Kesici takım aşınması, yüksek maliyetli kesici takım değişimleri, iş durmaları ve iş parçalarının kalitesinde düşüş, parça kayıp maliyetleri, üretim süresinde artış, CNC makine bakım maliyetleri, iş kazası riski gibi olumsuz sonuçlara neden olabilir. Sönmez, Ertunç ve Karakuzu'ya (2000) göre, takım aşınması, işlenen parçanın doğrudan kalitesini etkilediğinden, takım aşınmasının takibi ve tahmini imalat sanayi için oldukça önemlidir.

Literatürde kesici takım aşınmasının tahmin edildiği çalışmalar Tablo 1'de sunulmuştur.

Tablo 1
Kesici Takım Aşınması Tahminlemesini İçeren Çalışmalar

Çalışma	Algoritma	PÖY	Aşınma	Veri	Özellikler	Evre
Chehrehzad, Keçibaş, Beşirova, Üresin, İrican ve Lazoğlu (2024)	YSA	MAE	300	2400	K, T, S, KP, A	✓
Wang ve Shen (2024)	Bi-GRU	-	250	800	-	✓
Li, Fu, Zhuo, Liu ve Jin (2023)	SSM2DG	HO	300	5800	K, TT	✓
Pashmforoush, Araghizad ve Budak (2024)	PIML	R ² , RMSE	300	-	KK, KH, KD	
Korkmaz, Gupta, Çelik, Ross ve Günay (2024)	MLP, LR	R ² , RMAE RMSE, RAE	160	-	K, SC	
Li, Zhao, Cao, Li ve Chen (2023)	MHDF	HO	-	180	-	
Bilgili, Keçibaş, Beşirova, Chehrehzad, Burun, Pehlivan, Üresin, Emekli ve Lazoğlu (2023)	YSA	MAPE	-	-	İMMA, DS	
Aldekoa, Olmo, Pinilla, Mouliet, Novoa ve Lacalle (2023)	RFR, KNNR, SVMR	R ² , MAE, MSE	-	-	K, Güç, A	
Huang, Shao, Guo, Li, Zhu ve Fang (2023)	SVR, LSSVR, PSO	MAE, RMSE, PCC, MAPE	360	300	K, TT	
Twardowski, Czyżyci, Czyryca, Tabaszewski ve Pikuła (2023)	CART, CHAID	HO	-	-	TTI	
Korkmaz, Gupta, Kuntoğlu, Patange, Ross, Yılmaz, Chauhan ve Vashishtha (2023)	DT, RFR, SVR	R ² , MAE, MSE, RMSE	1050	-	Takım Uzunluğu	
Tabaszewski, Twardowski, Pikuła, Znojkwicz, Czyryca ve Czyżyci (2022)	SRA, BK, YSA	HO	-	12367	KH, İMH, Besleme, KD, KS	
Sönmez, Ertunç ve Karakuzu (2000)	YSA	HO	-	480	K	
Javanjal, Mahajan, Vijay, Sudhakar ve Munde (2022)	CNN	HO, MAPE	450	-	AE, K, TT, A, Güç	
Li, Liu, İncecik, Gupta, Królczyk ve Gardoni (2022)	CNN	-	150	-	-	
Monferrer, P´erez, Santos, Migu´elez ve Cantero (2022)	LR, KNN, RFR, DT	RMSE, MAE	-	3500	Güç, Enerji	
Li, Wang, Huang ve Gao (2022)	MÖ	MAE, RMSE, MAPE	200	320	-	
Yang, Zhao ve Zhao (2022)	SSAE, BPNN	RMSE	150	-	KK	
Jin, Bao, Li ve Jin (2022)	MÖT, KM	MAPE, R ²	-	960	AFKA, KTK, ARK	
Chacón, Barrena, García, Buruaga, Badiola ve Vicente (2021)	DPA	RMSE	250	-	-	
Kalkanlı (2021)	YSA, DVM, ESA	-	80	-	Ses Sinyalleri	
Xu, Wang, Zhong, Ming ve Chen (2021)	ÖBKDM	MAE, RMSE	180	575	KK Sinyalleri, TTS, AES	
Twardowski, Tabaszewski, Pikuła ve Czyryca (2021)	DT, CART, KNN	HO	200	-	AES	
He, Shi, Xuan ve Li (2021)	SSAE-BPNN	RMSE, R ²	600	303	SC	
Hahn (2020)	KKDÖ	PR-AUC	-	11570	TT, AE, A	
Alajmi ve Almeshal (2020)	XGB-SDA	MAE, R ²	300	161	İMİH, MÇ, BH, İK, T	
Twardowski ve Pikuła (2019)	MLP, YSA	RMSE, R ²	400	-	Radyal KK, TTI, KK	
Ravikumar ve Ramachandran (2018)	DTSM	MAE, RMSE	200	-	Ses, TT	
Gündüzöz (2002)	YSA	MSE	600	-	-	

Tablo 1'in kısaltmalar dizini Ek Açıklamalarda yer almaktadır. Tablo, altı sütundan oluşmaktadır. İlk sütunda incelenen çalışma, izleyen sütunlarda ise sırasıyla çalışmada kullanılan algoritma, performans ölçüm yöntemi (*PÖY*), µm cinsinden takım aşınması miktarı (*Aşınma*), adet cinsinden çalışmada kullanılan veri miktarı (*Veri*), tahminde kullanılan özellikler ve tahminlemenin evre bazında yapılıp yapılmadığı bilgileri yer almaktadır.

İncelenen çalışmalarda yaygın olarak Yapay Sinir Ağı (*YSA*), Destek Vektör Regresyonu (*SVR*) ve Rastgele Orman Regresyonu (*RFR*) üzerine kurulu algoritmaların tercih edildiği gözlemlenmiştir. Performans ölçüm yöntemi olarak *RMSE (Root Mean Squared Error)*, *MAE (Mean Absolute Error)*, *MSE (Mean Squared Error)* ve R^2 (*R-squared*) en yaygın kullanılan metrikler olarak öne çıkmaktadır. Takım aşınması değeri, ortalama 300 mikrometre olarak alınmıştır. Çalışmalarda kuvvet, tork, sapma, iş mili kodlayıcı pozisyonu, akım, güç, ses, sıcaklık, iş mili motor akımı, titreşim, titreşim ivmesi, takım uzunluğu, enerji, akustik emisyon, iş mili hızı, matkap çapı, besleme hızı gibi özellikler değerlendirilmiştir. Veri sayısına ulaşılabilen çalışmalarda, en fazla 12 bin veri ile çalışıldığı görülmüştür. Bu çalışmada, literatürden farklı olarak bir işletme tarafından sağlanan gerçek verilerden oluşan toplam 5,7 milyon ham veri kullanılmaktadır. Çalışma veri sayısı yönüyle literatürdeki çalışmalardan ayrılmaktadır.

Literatürde kesici takım aşınmasını tahminlemeye yönelik çalışmalarda, genellikle sürecin tamamı evrelere ayrılmadan dikkate alınmaktadır. Ancak, her evrede takımın performansı ve işleme kalitesi farklı olduğu için sürecin tamamını tahminlemek yerine evrelere ayırarak tahminlemek, evrelere özgü özelliklerin ve değişikliklerin yakalanmasını sağlamaktadır. Bu çoklu model yaklaşımı, kesici takımın her bir evresinin daha hassas bir şekilde tahmin edilmesini sağlar ve işletmelere daha doğru ve zamanında müdahale imkanı verir. Bu çalışma, kesici takım aşınmasının evrelerini dikkate alarak tahminleme yapması açısından literatüre önemli bir katkı sağlamaktadır.

Yapılan literatür taramasında evreleri dikkate alan sadece üç çalışmaya (*Chehrehzad ve diğ. 2024*, *Wang ve Shen, 2024*, *Li ve diğ., 2023*) erişilmiştir. Bu çalışmaların üçünde de kullanılan veri sayısı 5800 ya da altındadır. Kullanılan veri sayısı tahminlemenin doğruluğu açısından kritiktir. 5,7 milyon adet verinin kullanıldığı bu çalışma, veri sayısı ile evreleri dikkate alan çalışmalar arasında öne çıkmaktadır.

Bu çalışmanın temel amacı kesici takım aşınmasını doğru bir şekilde tahminlemeye yardımcı olacak bir model geliştirilmesidir. Üretimde çalışanların, bu model sayesinde aşınma belirli bir tolerans seviyesinin ötesine geçmeden önce müdahale etmesi amaçlanmaktadır. Bu şekilde, işletmelerin üretim süreçlerini optimize etmeleri ve maliyetleri azaltmaları hedeflenmektedir. Model geliştirme aşamasında makine öğrenmesi kullanılarak uygulama yapılmıştır. Veri setleri analiz edilip ön işleme yapıldıktan sonra *RFR*, *GBR*, *XGB* ve *ABR* modelleri kullanılmıştır. Veri setlerinden 3 farklı senaryo oluşturulmuş,

model performansları hiper parametre optimizasyonu yapılarak iyileştirilmiştir. Veri setleri kesici takım ömrünün evrelerine bölünmüş ve evrelere ayırmanın sağlayacağı imkanlar incelenmiştir.

Bu çalışmanın izleyen bölümünde geliştirilen makine öğrenmesi yaklaşımı, üçüncü bölümde elde edilen deneysel sonuçlar verilmiştir. Son bölümde ise genel değerlendirme ve öneriler tartışılmıştır.

2. Geliştirilen Makine Öğrenmesi Yaklaşımı

Yapay zekanın bir alt dalı olan makine öğrenmesi, büyük veri gruplarını işleyerek doğru çıktılar elde etmede yetkindir. Makine öğrenmesi, kesici takım aşınma durumu hakkında öngörüler sağlayarak malzeme bazlı ve işleme kaynaklı problemleri ortadan kaldırabilir (Korkmaz ve diğ., 2023).

Bu çalışmada, bir otomotiv işletmesinde talaşlı imalat yapan CNC makinelerinden elde edilen veriler kullanılarak kesici takım aşınmasını tahminlemek için denetimli bir makine öğrenmesi modeli geliştirilmiştir. Bunun için Rastgele Orman Regresyonu (RFR), Gradyan Artırma Regresyonu (GBR), Aşırı Gradyan Artırma Regresyonu (XGB) ve Uyarlamalı Artırma Regresyonu (ABR) makine öğrenmesi algoritmalarından yararlanılmıştır. RFR, birden fazla karar ağacını bir arada kullanarak tahminler yapan bir öğrenme yöntemidir. Değişkenler arasındaki karmaşık ilişkileri öğrenme kapasitesi ve yüksek doğruluğu ile bilinir. Ayrıca, modelin yorumlanabilirliğini artıran özellik önem sıralaması gibi ek avantajlar sunar. GBR, tahminleme problemlerinde yüksek doğruluk sağlamak amacıyla zayıf tahminleyicilerin ardışık şekilde birleştirilmesine dayanan bir öğrenme yöntemidir. Esnekliği ve yüksek doğruluğu ile bilinir ve genellikle karmaşık veri setlerinde iyi performans gösterir. XGB, GBR algoritmasının iyileştirilmiş bir versiyonudur. Hız ve performans açısından geliştirilmiştir ve büyük ölçekli veri setleri üzerinde etkili bir şekilde çalışır. ABR, zayıf tahminleyicilerin bir topluluğunu oluşturarak güçlü bir tahminleyici elde etmeyi amaçlayan bir öğrenme yöntemidir. Basit ve etkili olması ile bilinir ve genellikle daha az karmaşık veri setlerinde iyi performans gösterir.

Modellerin başarısını değerlendirmek için MSE metriği kullanılmıştır. Bu metrik, tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasını hesaplayarak bir modelin ne kadar doğru olduğunu ölçmektedir. MSE formülü (Korkmaz ve diğ., 2023) denklem (1)'de verilmiştir.

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

n : veri kümesindeki örnek sayısı

y_i : i . örnek için gerçek değer

\hat{y}_i : i . örnek için tahmin edilen değer

Kesici takım aşınması gibi sürekli değişkenlerin tahmin edilmesi gereken durumlarda, MSE doğru bir performans ölçütü sunmaktadır. Aldekoa ve diğ. (2023), Korkmaz ve diğ. (2023) ve Gündüzöz (2002) çalışmalarında model performans karşılaştırması yaparken MSE değerini kullanmışlardır.

MSE metriğinin yanında literatür ile kıyaslanabilirliği artırmak için MAPE ve R^2 metriklerine göre de model performansları hesaplanmıştır. Bu değerler sadece en iyi sonuç grafiklerinde verilmiştir. Çalışmadaki tüm diğer model karşılaştırma ifadelerinde ve tablolarda sadece MSE değeri kullanılmıştır.

MAPE, ortalama mutlak yüzde hata değerlerini belirten bir metriktir. MAPE, farklı ölçeklerde olan değişkenler için kullanılabilmesi ve mutlak hatalara odaklandığı için tahminlerin gerçek değerlerden ne kadar uzak olduğunu ölçmesi yönleriyle faydalıdır. Bu çalışmada MAPE değeri 100 ile çarpılarak elde edilen % MAPE değeri kullanılmıştır. MAPE formülü (Huang ve diğ., 2023) denklem (2)'de verilmiştir.

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

R^2 , tahmin edilen değerlerin gerçek değerlere ne kadar iyi uyduğunu gösteren bir istatistiktir. R^2 , 0 ile 1 arasında değişen bir değerdir ve bu nedenle, farklı modellerin performanslarının karşılaştırılabilmesini sağlar, doğrusal olmayan modeller için de kullanılabilir. R^2 formülü (Jin ve diğ., 2022) denklem (3)'de verilmiştir.

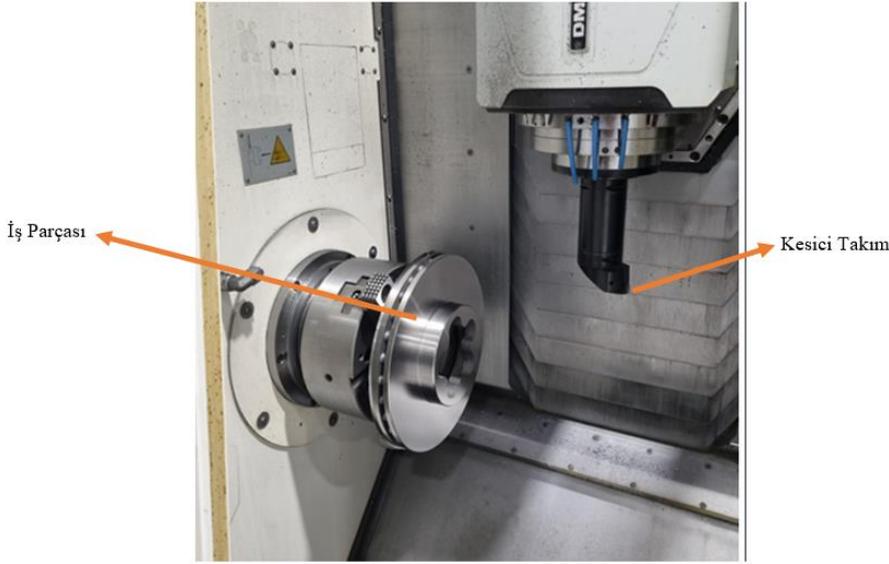
$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

\bar{y} : y_i 'lerin ortalaması

3. Deneysel Sonuçlar

Çalışmada, bir otomotiv imalat işletmesinin deney merkezinde talaşlı imalat yapan CNC makinelerinden elde edilen veriler kullanılmıştır. Tornalama işlemine odaklanılmıştır. Şekil 1'de CNC torna tezgahı üzerinde bir iş parçası ve kesici takım görülebilir. Veri toplama süreci bu çalışma öncesinde işletme tarafından gerçekleştirilmiştir.

Bu çalışmada araştırma ve yayın etiğine uyulmuştur.



Şekil 1. CNC Torna Tezgahı Üzerinde İş Parçası ve Kesici Takım

Veri toplama sürecinde kesici takımlar sıfırdan başlayıp 300 mikrometre aşınmaya ulaşana kadar kullanılmıştır. 5 farklı kesici takıma ait toplam 5,7 milyon satır ham veri mevcuttur. Veri setleri “kaba işleme” ve “ince işleme” işlem adımlarından oluşmaktadır. “İnce işleme” iş parçasını nihai haline getiren işlem olması sebebiyle kesici takım aşınması, üretim kalitesini doğrudan etkilemektedir. Çalışma için, en geniş yüzeye sahip olan 5 numaralı yüzeyin “ince işleme” verileri kullanılarak makine öğrenmesi modeli eğitilmiştir. En geniş yüzey seçilerek daha fazla veri ile kapsayıcılığı artırmak amaçlanmıştır. Veri setlerinde: akımın kontrol ölçüm hatası, akım, enkoder pozisyonu, iş mili motoru ilerlemesi, motorun tükettiği güç, motorun torku, iş mili motoru hızı özellikleri yer almaktadır. Her bir özelliğin 5 farklı eksenindeki değerleri mevcuttur.

Kesici takım aşınması tahminlemesi için daha geniş bir perspektif sunmak amacıyla 5 adet kesici takımın verisi, farklı kombinasyonlarda kullanılarak 3 senaryo oluşturulmuştur. Modeller tüm senaryolar için test edilmiştir.

- *Senaryo 1* ; 1., 2., 4. ve 5. takımlara ait verilerin alt alta sırası değiştirilmeden birleştirilmesiyle oluşan veri çerçevesi kullanılarak 3. takıma ait aşınma tahminlenmiştir.
- *Senaryo 2* ; 4. ve 5. takımlara ait verilerin alt alta sırası değiştirilmeden birleştirilmesiyle oluşan veri çerçevesi kullanılarak 3. takıma ait aşınma tahminlenmiştir.

- *Senaryo 3* ; 2. takıma ait veriler ile yine aynı takımın aşınması tahminlenmiştir.

3.1. Veri Ön İşleme

Veri ön işleme aşamasında boş ve ilgisiz veri içeren sütun ve satırlar çıkarılmış, tahminleme yapılacak yüzeyin (5 numaralı yüzey) verisi ayıklanmış, *Senaryo 1* ve *Senaryo 2* için veri birleştirme işlemi yapılmıştır.

Veri setinde yer alan özelliklerin, kesici takımın aşınma sürecini tahminleme yeteneğine etkisi göz önüne alınarak, analizler yapılmıştır. Özellikle yüksek korelasyona sahip olan ve tahminleme performansını artırabilecek özellikler belirlenmiştir.

Senaryo 1, 2 ve *3* için özellik korelasyonlarının ve seçiminin verildiği Tablo 2, 3 ve 4'te, P, pozitif korelasyonu, N, negatif korelasyonu, X korelasyon olmadığını göstermektedir. F1, F2, F3, F4 ve F5, 5 farklı kesici takımın verisini temsil etmektedir. Bu sütunlardaki değerler ilgili özelliğin takım aşınması ile korelasyon durumunu göstermektedir. Eğitim veri seti sütunu, senaryoda seçilen kesici takımların verisinin birleştirilmesi ile oluşan veri setindeki ilgili özelliğin, yine bu veri setindeki kesici takım aşınması ile korelasyon durumunu göstermektedir. Korelasyon sütununda eğitim veri setinin korelasyon değeri yer almaktadır. *Senaryo 1* ve *Senaryo 2* eğitim verisinde farklı kesici takımları içerdiği için korelasyon değerleri *Senaryo 3*'e göre düşük seyretmektedir. *Senaryo 3* de ise aynı takımın verisi ile eğitildiğinden, özelliklerin kesici takım ile korelasyonları yüksektir. Korelasyonun mutlak değeri *Senaryo 1* ve *Senaryo 2* için 0,25'ten, *Senaryo 3* için 0,60'tan büyük olan özellikler seçilmiştir. Modelde kullanılmasına karar verilen özelliklerin satırları koyu ve italik olarak işaretlenmiştir.

Tablo 2
Senaryo 1 için Özellik Korelasyon Bilgileri ve Seçimi

<i>Senaryo 1</i>								
Özellik	F1	F2	F3	F4	F5	Eğitim Veri Seti	Korelasyon	Sonuç
Özellik1	<i>N</i>	<i>N</i>	<i>P</i>	<i>P</i>	<i>P</i>	<i>P</i>	0,25	<i>P</i>
Özellik2	X	X	X	X	X	X	X	X
Özellik3	N	N	P	P	P	P	0,16	X
Özellik4	X	X	X	X	X	X	X	X
Özellik5	X	X	X	X	N	N	0,16	X
Özellik6	X	N	X	P	P	P	0,17	X
Özellik7	P	P	N	N	N	N	0,13	X
Özellik8	P	P	X	N	N	N	0,24	X
Özellik9	<i>N</i>	<i>N</i>	<i>P</i>	<i>P</i>	<i>P</i>	<i>P</i>	0,34	<i>P</i>
Özellik10	X	X	X	X	X	X	X	X
Özellik11	<i>N</i>	<i>N</i>	<i>P</i>	<i>P</i>	<i>P</i>	<i>P</i>	0,34	<i>P</i>
Özellik12	X	X	X	X	X	X	X	X
Özellik13	N	N	N	N	N	N	0,15	X
Özellik14	X	X	X	X	N	N	0,16	X
Özellik15	N	N	X	P	P	P	0,17	X
Özellik16	P	P	N	N	N	N	0,13	X
Özellik17	P	P	X	N	N	N	0,24	X
Özellik18	<i>N</i>	<i>N</i>	<i>P</i>	<i>P</i>	<i>P</i>	<i>P</i>	0,25	<i>P</i>
Özellik19	X	X	X	X	X	X	X	X
Özellik20	<i>N</i>	<i>N</i>	<i>P</i>	<i>P</i>	<i>P</i>	<i>P</i>	0,25	<i>P</i>

Tablo 3
Senaryo 2 için Özellik Korelasyon Bilgileri ve Seçimi

<i>Senaryo 2</i>						
Özellik	F3	F4	F5	Eğitim Veri Seti	Korelasyon	Sonuç
Özellik1	P	P	P	P	0,31	P
Özellik2	X	X	X	X	X	X
Özellik3	P	P	P	P	0,20	X
Özellik4	X	X	X	X	X	X
Özellik5	X	X	N	N	0,19	X
Özellik6	X	P	P	P	0,23	X
Özellik7	N	N	N	N	0,18	X
Özellik8	X	N	N	N	0,31	X
Özellik9	P	P	P	P	0,42	P
Özellik10	X	X	X	X	X	X
Özellik11	P	P	P	P	0,42	P
Özellik12	X	X	X	X	X	X
Özellik13	N	N	N	N	0,17	X
Özellik14	X	X	N	N	0,19	X
Özellik15	X	P	P	P	0,23	X
Özellik16	N	N	N	N	0,18	X
Özellik17	X	N	N	N	0,31	X
Özellik18	P	P	P	P	0,31	P
Özellik19	X	X	X	X	X	X
Özellik20	P	P	P	P	0,31	P

Tablo 4
Senaryo 3 için Özellik Korelasyon Bilgileri ve Seçimi

<i>Senaryo 3</i>		
Özellik	Korelasyon	Sonuç
Özellik1	-0,70	N
Özellik2	0,10	X
Özellik3	-0,77	N
Özellik4	0,02	X
Özellik5	-0,01	X
Özellik6	-0,55	X
Özellik7	0,65	P
Özellik8	0,50	X
Özellik9	-0,79	N
Özellik10	-0,11	X
Özellik11	-0,68	N
Özellik12	-0,02	X
Özellik13	-0,34	X
Özellik14	-0,01	X
Özellik15	-0,55	X
Özellik16	0,65	P
Özellik17	0,50	X
Özellik18	-0,79	N
Özellik19	-0,02	X
Özellik20	-0,79	N

Z-score yöntemi kullanılarak aykırı verilerin tespit edilmesi için bir analiz yapılmıştır. Z-score mutlak değeri 3 ten büyük olan aykırı verilerin çıkarılması ile birlikte, önceki MSE değerine göre model performansının %80 kötüleştiği gözlemlenmiştir. Aykırı verilerin, kesici takımın farklı aşamalarının tahminlenmesinde önemli bilgiler içerebileceği düşüncesi ile aykırı veriler çıkarılmadan çalışmaya devam edilmiştir. Çalışmada kullanılan veri miktarı, literatürdeki pek çok çalışmaya kıyasla oldukça fazladır. Bu nedenle aykırı değerlerin, tahmin başarısını düşürmek yerine veri setindeki değişkenliği temsil ederek daha doğru ve güvenilir tahminler yapılmasına olanak tanıdığı gözlemlenmiştir.

Veri normalizasyonu için makine öğrenmesi modellerinde sıklıkla kullanılan Min-Maks ölçeklendirme yöntemi seçilmiştir. Bu yöntem, veri setindeki özellik değerlerini belirli bir aralığa ölçeklendirerek veri setinin daha istikrarlı ve etkili

bir şekilde işlenmesini sağlamaktadır. Min-Maks değerleri [1, 3] olarak tercih edilmiştir. Senaryo 3'te RFR modeli, 50 pencere büyüklüğünde yapılan denemede Min-Maks değeri [1,5] olarak alındığında MSE değeri 0,0164 olarak elde edilmiştir. [1, 3] olarak denemede elde edilen MSE değeri (0,0041) %75 daha iyi sonuç verdiği için [1, 3] aralığı seçilmiştir. Uygulamada denetimsiz öğrenme yapılacağı için test veri seti ölçeklendirme yapılırken eğitim veri setine ait minimum ve maksimum değerler kullanılmıştır. Ölçeklendirme için kullanılan formül denklem (4)'te verilmiştir.

$$X_{ölçek} = S_{min} + \frac{(X - X_{min}) * (S_{maks} - S_{min})}{(X_{maks} - X_{min})} \quad (4)$$

$X_{ölçek}$: Özelliğin ölçeklendirilmiş değeri

X : Özelliğin orijinal değeri

X_{min} : Özelliğin minimum değeri (test veri seti için eğitim veri setinin değeri)

X_{maks} : Özelliğin maksimum değeri (test veri seti için eğitim veri setinin değeri)

S_{min} : İlgili özellik için alt sınır değeri

S_{maks} : İlgili özellik için üst sınır değeri

Bu çalışmada, kesici takım aşınmasını tahminlemek için kullanılan veri seti pencerelere bölünmüştür. Veri pencerelere bölme işlemi, verinin belirli sayıda örnek içeren segmentlere ayrılması sürecidir. Pencerelerin kendi içinde karakteristiği korunurken, veri tutarsızlığından kaynaklı olabilecek hatalar engellenmiş olur. Verilerin pencerelere bölünmesi adımında, verilerin sırası bozulmadan, belirlenen pencere büyüklüğünde özelliklerin ortalama değerini, takım aşınmasının ise maksimum değerini içerecek şekilde pencereler oluşturulmuştur. Tablo 5'te Senaryo 3 için her modelin en iyi sonucu veren pencere büyüklüklerinin MSE değerleri koyu italik olarak işaretlenmiştir. Senaryo 3'ün tüm denemeleri 50 pencere büyüklüğünde gerçekleştirilmiştir. Veri büyüklüklerine göre modellerin yanıt verme süresi dikkate alındığında Senaryo 1 ve Senaryo 2 için pencere büyüklüğü 200 olarak kullanılmıştır.

Tablo 5

Senaryo 3 için Pencere Büyüklüğü MSE Performans Sonuçları

Model	Pencere 200	Pencere 150	Pencere 100	Pencere 50
RFR	0,0061	0,0059	0,0050	0,0041
GBR	0,0149	0,0079	0,0070	0,0071
XGB	0,0203	0,0090	0,0216	0,0072
ABR	0,0047	0,0045	0,0051	0,0052

3.2. Modellerin Çalıştırılması

Model seçimi için LR, LASSO, EN, HR, MLP, GBR ve RFR gibi farklı makine öğrenmesi modelleri değerlendirilmiştir. Yapılan denemelerde en iyi sonuçları GBR ve RFR vermiştir. Araştırma sonucunda XGB ve ABR modelleri de çalışmaya dahil edilmiştir. Her bir model, eğitim veri seti üzerinde eğitilmiş ve hiper parametre optimizasyonu yapılmıştır. Modellerin başarı metriği olarak MSE değeri kullanılmıştır. Test veri seti, doğrulama olarak da değerlendirilmiştir. Eğitim veri seti ve test veri seti büyüklükleri aşağıdaki gibi belirlenmiştir.

- Senaryo 1 ve Senaryo 2 için; birleştirilmiş veri çerçevesi, eğitim veri seti olarak, 3. takıma ait verilerin ise tamamı test veri seti olarak kullanılmıştır.
- Senaryo 3 için; 2. takıma ait verilerin sırası değiştirilmeden ilk %90'ı eğitim veri seti olarak, son %10'luk kısım ise test veri seti olarak kullanılmıştır.

3.3. Hiper Parametre Optimizasyonu

Kesici takım aşınmasının tahmin edilmesi için kullanılan makine öğrenmesi modellerinin performansını artırmak amacıyla hiper parametrelerin değerleri belirlenmiştir. Hiper parametre ayarlaması, modellerin güçlü olmasında önemli bir rol oynamaktadır (Korkmaz ve diğ., 2023). Çalışma kapsamında kullanılan modellerin hiper parametre isimleri, bunların varsayılan değerleri, hiper parametrelerin alabileceği değerler için bir arama kümesi ve senaryolarda seçilen en iyi parametre değerleri Tablo 6'da verilmiştir. İyileştirme öncesinde varsayılan parametre değerleri ile modeller çalıştırılmış ve MSE değerleri kaydedilmiştir. Sonrasında, grid arama yöntemi ile en iyi parametre değerleri belirlenmiştir. Grid arama yöntemi, arama kümesindeki tüm seçenekleri ziyaret ederek en iyi parametre değerleri kombinasyonunu araştırmaktadır. Örneğin Tablo 6'dan görülebileceği gibi, Senaryo 1 için RFR modelinin tahminci sayısı, en

küçük örnek bölme sayısı ve en küçük yaprak örnek sayısı parametrelerinin değerleri sırasıyla 100, 2 ve 1 olarak belirlenmiştir.

Tablo 6
Hiper Parametre Bilgileri

Model	Hiper Parametre	Varsayılan	Arama Kümesi	Senaryo 1	Senaryo 2	Senaryo 3
RFR	Tahminci Sayısı	100	[50, 100, 200]	100	50	100
RFR	Min. Örnek Bölme Sayısı	2	[2, 5, 10]	2	2	5
RFR	Min. Yaprak Örnek Sayısı	1	[1, 2, 3]	1	1	1
GBR	Tahminci Sayısı	100	[50, 100, 200]	200	100	200
GBR	Öğrenme Hızı	0.1	[0.01, 0.1, 1]	0.01	0.01	0.1
GBR	Maks. Derinlik	3	[3, 5, 7]	7	7	7
XGB	Tahminci Sayısı	100	[50, 100, 200]	200	50	50
XGB	Öğrenme Hızı	0.3	[0.01, 0.3, 1]	0.01	0.01	0.3
XGB	Maks. Derinlik	6	[3, 6, 7]	7	3	6
ABR	Tahminci Sayısı	50	[10, 15, 50]	50	10	50
ABR	Öğrenme Hızı	1.0	[0.001, 0.01, 0.1]	0.1	0.001	0.001
ABR	Kayıp Fonksiyonu	doğrusal	[doğrusal, kare, üstel]	kare	doğrusal	doğrusal

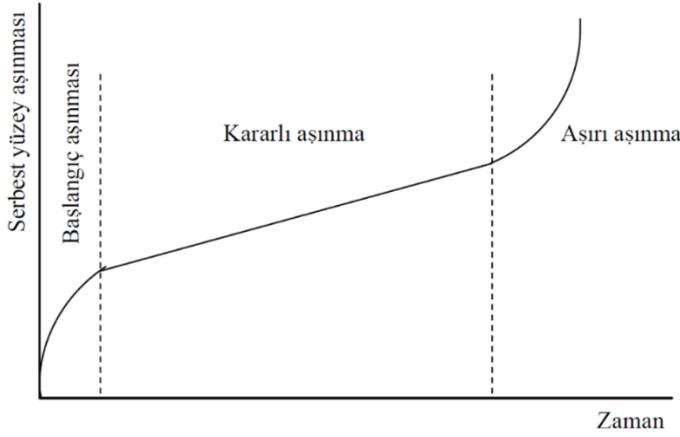
En iyi parametre değerleri ile modeller tekrar çalıştırılmış ve iyileştirme sonrası elde edilen MSE değerleri Tablo 7'de verilmiştir.

Tablo 7
Senaryolar için Model İyileşme Özvetleri

Model	Senaryo 1 Pencere 200			Senaryo 2 Pencere 200			Senaryo 3 Pencere 50		
	Varsayılan Parametre MSE	İyileştirme Sonrası MSE	İyileşme	Varsayılan Parametre MSE	İyileştirme Sonrası MSE	İyileşme	Varsayılan Parametre MSE	İyileştirme Sonrası MSE	İyileşme
RFR	0,0627	0,0627	0%	0,1124	0,1032	8%	0,0041	<i>0,0041</i>	0%
GBR	0,0733	0,0614	16%	0,1116	0,0908	19%	0,0154	0,0071	54%
XGB	0,2539	0,0669	74%	0,7763	0,1030	87%	0,0108	<i>0,0072</i>	33%
ABR	0,0926	0,0684	26%	0,1551	0,1409	9%	0,0058	0,0052	11%

3.4. Kesici Takım Aşınmasının Evrelere Bölünmesi

Kesici takım aşınması, çeşitli evrelerden geçen bir süreçtir ve her evrede takımın performansı ve işleme kalitesi farklıdır. Dolayısıyla, her aşama için tek bir modelin kullanılması, bu evrelere özgü özellikleri ve değişiklikleri yeterince yakalayamayabilir. Çoklu model yaklaşımı, kesici takımın her bir evresinin daha hassas bir şekilde tahmin edilmesini sağlar ve işletmelere daha doğru ve zamanında müdahale imkanı verir. Chehrehzad ve diğ. (2024); Wang ve Shen (2024); Li ve diğ. (2023) çalışmalarında kesici takımın evrelere ayrılmasına yer vermişlerdir. Serbest yüzey aşınmasının zamana bağlı olarak gelişimi ve örnek evreler Şekil 2’de verilmiştir.



Şekil 2. Kesici Takım Aşınma Evrelerine Örnek: Serbest Yüzey Aşınmasının Zamana Bağlı Olarak Gelişimi (Özdemir ve Erten, 2003)

Senaryo 1 ve Senaryo 2 için kesici takım aşınması evrelere bölünerek her evre için en iyi model seçilmiştir. Takım aşınmasının ölçeklendirilmiş değeri Senaryo 1 için; [1-1,7) aralığı Evre 1, [1,7-2) aralığı Evre 2, [2-3] aralığı Evre 3, Senaryo 2 için; [1-1,75) aralığı Evre 1, [1,75-2,13) aralığı Evre 2, [2,13-3] aralığı Evre 3 olarak belirlenmiştir. Senaryo 3’te bir takımın ömrünün son %10 luk kısmı tahminlenmektedir. Bu nedenle bu senaryo için evre çalışması yapılamamıştır.

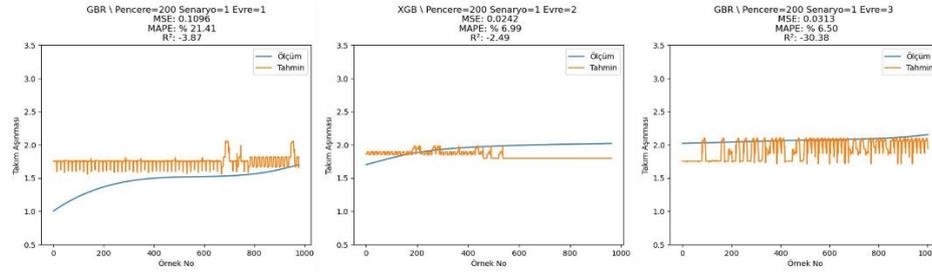
Senaryolarda kullanılan modellerin farklı evrelerde verdikleri MSE değerleri Tablo 10 ve Tablo 11’de özetlenmiştir. Her evre için en iyi sonuçlar koyu italik işaretlenmiştir. En iyi sonuçlara ait grafikler Şekil 3 ve Şekil 4’te verilmiştir. Grafikler ölçeklenmiş veriler ile oluşmuştur ve dikey ekseninde takım aşınması, yatay ekseninde örnek numaraları yer almaktadır. Örnek numaraları çalışmanın tamamında sırası bozulmadan kullanılmıştır. Grafiklerde, gerçekleşen ölçüm değerleri ve modelin tahminlediği değerler yer almaktadır. Grafiklerin

başlığında kullanılan model, pencere, senaryo ve evre bilgileri ve MSE değeri yer almaktadır.

Tablo 10

Senaryo 1 için Modellerin Evre Performansları

Model	Pencere 200		
	Evre 1 MSE	Evre 2 MSE	Evre 3 MSE
RFR	0,1147	0,0323	0,0412
GBR	0,1096	0,0437	0,0313
XGB	0,1433	0,0242	0,0332
ABR	0,1409	0,0273	0,0372

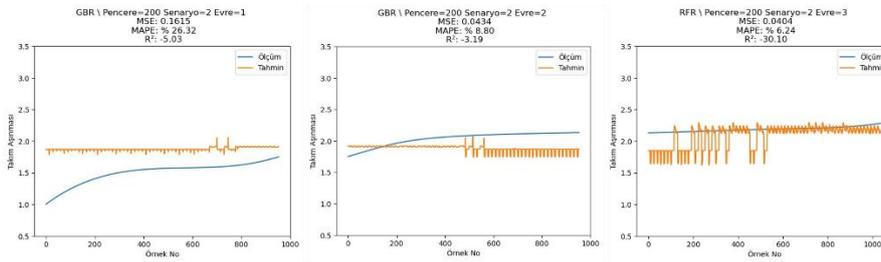


Şekil 3. Senaryo 1 için Evrelerin En İyi Sonuç Grafikleri

Tablo 11

Senaryo 2 için Modellerin Evre Performansları

Senaryo 2			
Pencere 200			
Model	Evre 1 MSE	Evre 2 MSE	Evre 3 MSE
RFR	0,1945	0,0800	0,0404
GBR	0,1615	0,0434	0,0692
XGB	0,1689	0,0515	0,0898
ABR	0,2676	0,1180	0,0456



Şekil 4. Senaryo 2 için Evrelerin En İyi Sonuç Grafikleri

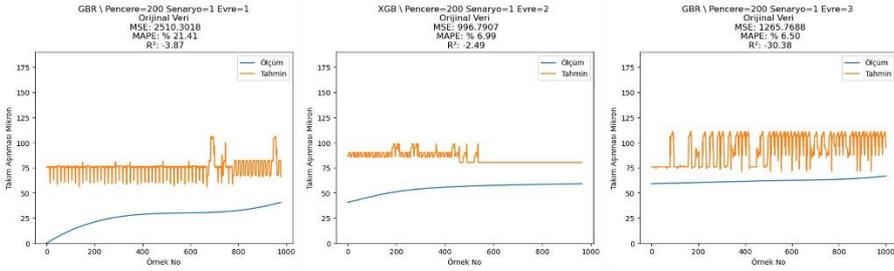
Her evrenin karakteristiği farklı olduğundan dolayı evreleri en iyi tahminleyen modellerin farklı olabileceği kanıtlanmıştır. Sonuç grafiklerine bakıldığında ilk evrenin başında modellerin başarısının düşük olduğu görülmektedir. Bu durum, özelliklerin korelasyon değerlerinin düşük olmasından kaynaklanmaktadır. Kesici takım aşınmasının tahminlenmesi probleminde en kritik nokta aşınmanın en sonda geleceği değerlerin doğru tahminlenmesidir. Grafiklerde de görüldüğü üzere modellerin son aşamalarda gerçekleşen ölçüme yakın tahmin vermesi, modellerin başarılı olduğunu göstermektedir.

3.5. Verinin Orijinal Hale Döndürülmesi

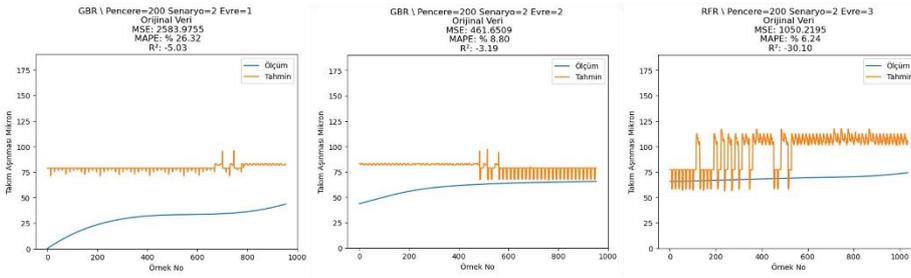
Tüm senaryoların sonunda optimum çözümü içeren sonuçlar için ölçeklendirilmiş veri, denklem (5)'te verilen formül kullanılarak orijinal veriye geri döndürülmüştür.

$$X = X_{min} + \frac{(X_{ölçek} - S_{min})(X_{maks} - X_{min})}{(S_{maks} - S_{min})} \quad (5)$$

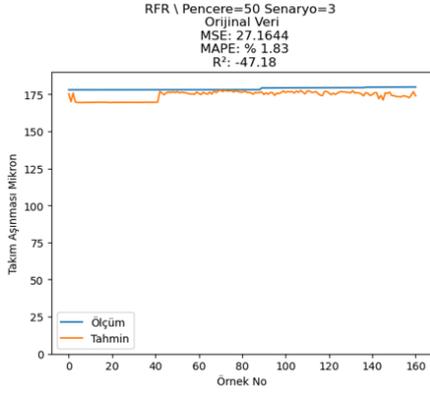
Her senaryo için gerçek değerleri içeren grafikler Şekil 5, Şekil 6 ve Şekil 7'de verilmiştir. Grafikler orijinal veriler ile oluşmuştur ve dikey eksende takım aşınması, yatay eksende örnek numaraları yer almaktadır. Gerçekleşen ölçüm değerlerinin ve modelin tahminlediği değerlerin grafiklerinden oluşmaktadır.



Şekil 5. Senaryo 1 için Gerçek Değerler ile En İyi Sonuç Grafikleri



Şekil 6. Senaryo 2 için Gerçek Değerler ile En İyi Sonuç Grafikleri



Şekil 7. Senaryo 3 için Gerçek Değerler ile En İyi Sonuç Grafiği

4. Sonuç ve Öneriler

Bu çalışmada, otomotiv sektöründe talaşlı imalat yapan CNC makinelerinde kesici takım aşınmasının tahmin edilmesi için makine öğrenmesi modelleri kullanılmıştır. RFR, GBR, XGB, ABR algoritmaları değerlendirilmiş ve hiper parametre optimizasyonu yapılmıştır. Özelliklerin kesici takım aşınması ile korelasyonu analiz edilmiş ve uygun olanlar modellerde kullanılmıştır. Z-score yöntemi ile aykırı veriler tespit edilmiş, ancak aykırı verilerin çıkarılması model performansını olumsuz etkilediği için aykırı veriler çıkarılmadan devam edilmiştir. Min-Maks ölçekleme yöntemi ile tüm özellik değerleri ölçeklendirilmiştir. Verilerin sırası bozulmadan, belirlenen pencere büyüklüğünde özelliklerin ortalama değerini, takım aşınmasının ise maksimum değerini içeren pencereleme yöntemi kullanılmıştır. Modellerin performansı, MSE metriği ile değerlendirilmiştir. Kesici takım aşınmasının farklı evreleri dikkate alınarak modellerin performansı incelenmiştir. Kesici takım aşınmasının evrelere ayrılarak tahmin edilmesi, evrelere özgü özelliklerin ve değişikliklerin yakalanarak her bir evrenin daha hassas bir şekilde tahmin edilmesini sağlamaktadır ve işletmeye daha doğru ve zamanında müdahale imkanı vermektedir. Her evrenin karakteristiği farklı olduğundan evreleri en iyi tahminleyen modellerin farklı olabileceği kanıtlanmıştır.

Tüm senaryolar için en başarılı MSE değerleri Tablo 12’de verilmiştir. Senaryo 1’de elde edilen minimum MSE değeri 0,0242, Senaryo 2’de 0,0404, Senaryo 3’te ise 0,0041 olmuştur. Senaryo 3’te model başarısının en yüksek olmasının sebebi, aynı takımın verisinin eğitim ve test olarak bölünmesi sebebiyle özelliklerin takım aşınması ile korelasyonun yüksek olması olarak belirtilebilir. Senaryo 2’de Senaryo 1’e göre sonucun daha iyi olacağı düşüncesi ile daha benzer özellikteki takımlar seçilmiştir. Buna rağmen sonuç daha kötü gerçekleşmiştir. Bu durumun sebebi ise daha büyük ve daha kapsayıcı bir veriyle öğrenen modelin farklı

değişkenleri de öğrenmesi ve test verisinde karşılaştığı farklılıkları daha iyi tahminlemesidir.

Tablo 12

Tüm Senaryolar İçin En Başarılı MSE Değerleri Özet

Optimum	Senaryo 1			Senaryo 2			Senaryo 3
	Evre 1	Evre 2	Evre 3	Evre 1	Evre 2	Evre 3	-
Model	GBR	XGB	GBR	GBR	GBR	RFR	RFR
MSE	0,1096	0,0242	0,0313	0,1615	0,0434	0,0404	0,0041

Çalışma kapsamında modellerin yanıt verme sürelerine odaklanılmamasına rağmen modeller çalıştırılırken XGB'nin önemli oranda hızlı sonuç verdiği gözlemlenmiştir. Senaryo 1'de RFR modeli 15 saniyede yanıt vererek en uzun sürede yanıt veren model olurken, aynı veri ile XGB 1 saniyeden daha az sürede yanıt vermektedir.

Tablo 13

Senaryo 1 için RFR ve XGB Modellerinin Yanıt Verme Süresi Karşılaştırması

Model	Senaryo 1
RFR	15 saniye
XGB	1 saniye

Geliştirilen modellerin ilerleyen aşamada işletmede üretim hattında uygulanması planlanmaktadır. Tahminlerin sağladığı zamanında müdahale imkanı sayesinde, kesici takım değişim maliyetlerinde, iş parçalarının kalitesinde ve üretim süresinde %15-25 oranında iyileşme olacağı öngörülmektedir. Ayrıca, takım kullanımının optimize edilmesi ile atık miktarının %10-15 oranında azalması da beklenmektedir. Bu sayede karbon ayak izi ve çevresel etkinin azalması sağlanacaktır.

Gelecek çalışmalar için öneriler:

- Gerçek zamanlı veri toplama ve analiz sistemlerinin entegrasyonu, kesici takım aşınmasının daha dinamik ve anlık olarak tahmin edilmesine olanak sağlayabilir.

- Makine öğrenmesi alanında sürekli gelişen yeni algoritmalar ve teknikler, kesici takım aşınmasının tahmininde daha yüksek doğruluk sağlayabilir. Bu nedenle, yeni algoritmaların ve derin öğrenme yaklaşımlarının da denenmesi önerilmektedir.
- Ek veri kaynaklarının ve sensörlerin kullanımı, daha fazla değişkenin modellenmesine olanak tanıyabilir. Bu, tahmin doğruluğunu artırabilir ve kesici takım aşınmasının daha kapsamlı bir şekilde analiz edilmesini sağlayabilir. Örneğin bu çalışmada özellik olarak motor tork değeri yer almaktadır. İlave bir dinamometre cihazı ile kesme torku verisi alınırsa tahminler iyileştirilebilir.
- Senaryo 1 ve Senaryo 2 için farklı pencere büyüklükleri bilgisayar kapasitesi nedeniyle modellerin yanıt verme süresi uzadığı için denenmemiştir. Daha güçlü işlemci, yüksek bellek kapasitesi ve grafik işlem birimi (GPU) gibi daha iyi donanım özelliklerine sahip bir bilgisayar veya bir sunucu altyapısı kullanılması durumunda model sonuçları iyileştirilebilir.

Bu çalışma, kesici takım aşınmasının tahmini konusunda önemli bulgular sağlamış ve makine öğrenmesi modellerinin bu alandaki potansiyelini göstermiştir. Gelecekte yapılacak araştırmalar, bu bulguları daha da ileriye taşıyarak endüstriyel uygulamalarda daha geniş kapsamlı çözümler sunabilir.

Teşekkür

Verilerin ve süreçle ilgili bilgilerin sağlanması konusundaki desteği için Sayın Gamze KEÇİBAŞ VİT'e teşekkürlerimizi sunarız.

Araştırmacıların Katkısı

Merve DENİZ, bilimsel yayın araştırması, istatistiki analizler, çözüm yönteminin tasarımı, bilgisayar ortamına aktarılması, uygulanması, makalenin oluşturulması; Feriştah ÖZÇELİK, makale fikrinin oluşturulması, çözüm yönteminin tasarımı, makalenin yazımı; Tuğba SARAÇ, makale fikrinin oluşturulması, çözüm yönteminin tasarımı, makalenin yazımı konularında katkı sağlamışlardır.

Çıkar Çatışması

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

Kaynakça

- Alajmi, M. ve Almeshal, A. M. (2020). Predicting the tool wear of a drilling process using novel machine learning XGBoost-SDA. *Materials*, 13, 4952. Doi: <https://www.mdpi.com/1996-1944/13/21/4952>
- Aldekoa, I., Olmo, A., Pinilla, L., Mouliet, S., Novoa, U. ve Lacalle, L. N. (2023). Early detection of tool wear in electromechanical broaching machines by monitoring main stroke servomotors. *Mechanical Systems and Signal Processing*, 204, 110773. Doi: <https://doi.org/10.1016/j.ymsp.2023.110773>
- Bilgili, D., Keçibaş, G., Beşirova, G., Chehrehzad, M. R., Burun, G., Pehlivan, T., Üresin, U., Emekli, E. ve Lazoğlu, İ. (2023). Tool flank wear prediction using high-frequency machine data from industrial edge device. *Procedia CIRP*, 118, 483–488. Doi: <https://doi.org/10.1016/j.procir.2023.06.083>
- Chacón, J.L., Barrena, T. F., García, A., Buruaga, M. S., Badiola, X. ve Vicente, J. (2021). A novel machine learning-based methodology for tool wear prediction using acoustic emission signals. *Sensors*, 21, 5984. Doi: <https://doi.org/10.3390/s21175984>
- Chehrehzad, M. R., Keçibaş, G., Beşirova, G., Üresin, U., İrican, M. ve Lazoğlu, İ. (2024). Tool wear prediction through AI-assisted digital shadow using industrial edge device. *Journal of Manufacturing Processes*, 113, 117–130. Doi: <https://doi.org/10.1016/j.jmapro.2024.01.052>
- Gündüzöz, U. (2002). *Yapay sinir ağı kullanılarak tornalamada kesici takım aşınması tahmini* (Yüksek Lisans Tezi). Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Hahn, T. (2020). *End-to-end deep learning in tool wear monitoring* (M.Sc. Thesis). Queen's University. Erişim adresi: <http://dx.doi.org/10.1007/s00170-024-13909-w>
- He, Z., Shi, T., Xuan, J. ve Li, T. (2021). Research on tool wear prediction based on temperature signals and deep learning. *Wear*, 478-479, 203902. Doi: <https://doi.org/10.1016/j.wear.2021.203902>
- Huang, Z., Shao, J., Guo, W., Li, W., Zhu, J. ve Fang, D. (2023). Hybrid machine learning-enabled multi-information fusion for indirect measurement of tool flank wear in milling. *Measurement*, 206, 112255. Doi: <https://doi.org/10.1016/j.measurement.2022.112255>
- Javanjal, V.K., Mahajan, K. A., Vijay, R., Sudhakar, G. P. ve Munde, K. H. (2022). Tool wear prediction system using machine learning approach. *NeuroQuantology*, 20(10), 12922-12928. Doi: [10.14704/nq.2022.20.10.NQ551252](https://doi.org/10.14704/nq.2022.20.10.NQ551252)
- Jin, F., Bao, Y., Li, B. ve Jin, X. (2022). Tool wear prediction in edge trimming of carbon fiber reinforced polymer using machine learning with instantaneous

- parameters. *Journal of Manufacturing Processes*, 82, 277–295. Doi: <https://doi.org/10.1016/j.jmapro.2022.08.006>
- Kalkanlı, E. (2021). *Ses sinyalleri kullanılarak talaşlı imalat prosesinde takım durumunun izlenmesi* (Yüksek Lisans Tezi). Bursa Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Bursa.
- Korkmaz, M. E., Gupta, M. K., Çelik, E., Ross, N. S. ve Günay, M. (2024). Tool wear and its mechanism in turning aluminum alloys with image processing and machine learning methods. *Tribology International*, 191, 109207. Doi: <https://doi.org/10.1016/j.triboint.2023.109207>
- Korkmaz, M. E., Gupta, M. K., Kuntoğlu, M., Patange, A. D., Ross, N. S., Yılmaz, H., Chauhan, S. ve Vashishtha, G. (2023). Prediction and classification of tool wear and its state in sustainable machining of boehler steel with different machine learning models. *Measurement*, 223, 113825. Doi: <https://doi.org/10.1016/j.measurement.2023.113825>
- Li, C., Zhao, X., Cao, H., Li, L. ve Chen, X. (2023). A data and knowledge-driven cutting parameter adaptive optimization method considering dynamic tool wear. *Robotics and Computer-Integrated Manufacturing*, 81, 102491. Doi: <https://doi.org/10.1016/j.rcim.2022.102491>
- Li, W., Fu, H., Zhuo, Y., Liu, C. ve Jin, H. (2023). Semi-supervised multi-source meta-domain generalization method for tool wear state prediction under varying cutting conditions. *Journal of Manufacturing Systems*, 71, 323–341. Doi: <https://doi.org/10.1016/j.jmsy.2023.09.011>
- Li, Y., Wang, J., Huang, Z. ve Gao, R. X. (2022). Physics-informed meta learning for machining tool wear prediction. *Journal of Manufacturing Systems*, 62, 17–27. Doi: <https://doi.org/10.1016/j.jmsy.2021.10.013>
- Li, Z., Liu, X., İncecik, A., Gupta, M. K., Królczyk, G. M. ve Gardoni, P. (2022). A novel ensemble deep learning model for cutting tool wear monitoring using audio sensors. *Journal of Manufacturing Processes*, 79, 233–249. Doi: <https://doi.org/10.1016/j.jmapro.2022.04.066>
- Monferrer, C. D., Pérez, J., Santos, R., Miguélez, M. H. ve Cantero, J. L. (2022). Machine learning approach in non-intrusive monitoring of tool wear evolution in massive cfrp automatic drilling processes in the aircraft industry. *Journal of Manufacturing Systems*, 65, 622–639. Doi: <https://doi.org/10.1016/j.jmsy.2022.10.018>
- Özdemir, U. ve Erten, M. (2003). Talaşlı imalat sırasında kesici takımında meydana gelen hasar mekanizmaları ve takım hasarını azaltma yöntemleri. *Havacılık ve Uzay Teknolojileri Dergisi*, 1(1), 37-50. Erişim adresi: https://www.researchgate.net/publication/237362821_TALASLI_IMALAT_SIRASINDA_KESICI_TAKIMDA_MEYDANA_GELEN_HASAR_MEKANIZMALARI_VE_TAKIM_HASARINI_AZALTMA_YONTEMLERİ

- Pashmforoush, F., Araghizad, A.E. ve Budak, E. (2024) Physics-informed tool wear prediction in turning process: A thermo-mechanical wear-included force model integrated with machine learning. *Journal of Manufacturing Systems*, 77, 266–283. Doi: <https://doi.org/10.1016/j.jmsy.2024.09.008>
- Ravikumar, S. ve Ramachandrana, K. I. (2018). Tool wear monitoring of multipoint cutting tool using sound signal features signals with machine learning techniques. *Materials Today: Proceedings*, 5, 25720–25729. Doi: <https://doi.org/10.1016/j.matpr.2018.11.014>
- Sönmez, M., Ertunç, H. M. ve Karakuzu, C. (2000). Kesici takım aşınma durumunun yapay sinir ağı kullanılarak belirlenmesi. Erişim adresi: <https://www.academia.edu/12210520>
- Tabaszewski, M., Twardowski, P., Pikuła, M., Znojkiwicz, N., Czyryca, A. ve Czyżycy, J. (2022). Machine learning approaches for monitoring of toolwear during grey cast-iron turning. *Materials*, 15, 4359. Doi: <https://doi.org/10.3390/ma15124359>
- Twardowski, P., Czyżycy, J., Czyryca, A., Tabaszewski, M. ve Pikuła, M. (2023). Monitoring and forecasting of tool wear based on measurements of vibration accelerations during cast iron milling. *Journal of Manufacturing Processes*, 95, 342–350. Doi: <https://doi.org/10.1016/j.jmapro.2023.04.036>
- Twardowski, P. ve Pikuła, M. (2019). Prediction of tool wear using artificial neural networks during turning of hardened steel. *Materials*, 12(19), 3091. Doi: <https://doi.org/10.3390/ma12193091>
- Twardowski, P., Tabaszewski, M., Pikuła, M. ve Czyryca, A. (2021). Identification of tool wear using acoustic emission signal and machine learning methods. *Precision Engineering*, 72, 738–744. Doi: <https://doi.org/10.1016/j.precisioneng.2021.07.019>
- Wang, C. ve Shen, B. (2024). Auxiliary input-enhanced siamese neural network: a robust tool wear prediction framework with improved feature extraction and generalization ability. *Mechanical Systems and Signal Processing*, 211, 111243. Doi: <https://doi.org/10.1016/j.ymssp.2024.111243>
- Xu, X., Wang, J., Zhong, B., Ming, W. ve Chen, M. (2021). Deep learning-based tool wear prediction and its application for machining process using multi-scale feature fusion and channel attention mechanism. *Measurement*, 177, 109254. Doi: <https://doi.org/10.1016/j.measurement.2021.109254>
- Yang, Y., Zhao, X. ve Zhao, L. (2022). Research on asymmetrical edge tool wear prediction in milling tc4 titanium alloy using deep learning. *Measurement*, 203, 111814. Doi: <https://doi.org/10.1016/j.measurement.2022.111814>

Ek Açıklamalar

Tablo 1 kısaltmalar dizini

A: Akım
ABR: Uyarlamalı Artırma Regresyonu
AE: Akustik Emisyon
AE: Akustik Emisyon
AES: Akustik Emisyon Sinyalleri
AFKA: Anlık Fiber Kesme Açısı
AI: Yapay Zeka
AISNN: Yardımcı Girdi İyileştirmeli Siyam Sinir Ağı
ARK: Anlık Radyal Kuvveti
BH: Besleme Hızı
Bi-GRU: Çift Yönlü Geçit Tekrarlayan Birim
BK: Bulanık Kurallar
BPNN: Geri Yayılım Sinir Ağı
CART: Sınıflandırma ve Regresyon Ağaçları
CHAID: Ki-Kare Otomatik Etkileşim Tespiti
CNN: Evrimsel Sinir Ağları
DPA: Dalgacık Paket Ayrışımı
DS: Dinamometre Sinyalleri
DT: Karar Ağacı
DTSM: Karar Ağacı Sınıflandırma Modeli
DVM: Karar Vektör Makinesi
EN: Elastik Ağ
ESA: Evrimsel Sürü Algoritması
GBR: Gradyan Artırma Regresyonu
GBR: Gradyan Artırma Regresyonu
HO: Hata Oranı
HR: Huber Regresyonu
İK: İtme Kuvveti
İMİH: İş Mili Hızı
İMMA: İş Mili Motor Akımı
K: Kuvvet
KD: Kesme Derinliği
KH: Kesme Hızı
KK: Kesme Kuvveti
KKDÖ: Ayrıştırılmış-Değişken Otomatik Kodlayıcı ile Kendi Kendini Denetleyen Öğrenme
KM: Kinematik Model
KNNR: K-En Yakın Komşu Regresörü
KP: İş Mili Kodlayıcı Pozisyonu
KS: Kesme Süresi
KTK: Kesilmemiş Talaş Kalınlığı
LASSO: En Küçük Mutlak Daraltma ve Seçim Operatörü

LR: Doğrusal Regresyon
LSSVR: En Küçük Kareler Destek Vektör Regresyonu
LSTM: Uzun-Kısa Süreli Bellek
MAE: Ortalama Mutlak Hata
MAPE: Ortalama Mutlak Yüzde Hatası
MÇ: Matkap Çapı
MHDF: Çok Kaynaklı Heterojen Veri Füzyonuna Dayalı Markov Karar Süreci
ML: Makine Öğrenmesi
MLP: Çok Katmanlı Algılama Regresyonu
MÖ: Meta-Öğrenme
MÖT: Makine Öğrenme Tekniği
MSE: Hata Kareleri Ortalaması
ÖBKDM: Çok Ölçekli Özellik Birleştirme ve Kanal Dikkat Mekanizması
PCC: Pearson Korelasyon Katsayı
PD: Performans Değeri
PIML: Physics-informed machine learning
PÖY: Performans Ölçüm Yöntemi
PR-AUC: Doğruluk-Kurtarma Eğrisi Altındaki Alan
PSO: Parçacık Sürü Optimizasyonu
RAE : Göreceli Mutlak Hata
RMAE: Kök Göreceli Mutlak Hata
RFR: Rastgele Orman Regresyonu
RMSE: Kök Hata Kareleri Ortalaması
S:Sapma
SC: Sıcaklık
SDA: Spiral Dinamik Algoritması
SRA: Sınıflandırma ve Regresyon Ağacı
SSAE: Yığılmış Seyrek Otomatik Kodlayıcı
SSM2DG:Yarı Denetimli Çok Kaynaklı Meta-Alan Genellemesi
SVMR: Destek Vektör Makinesi Regresörü
SVR: Destek Vektör Regresyonu
T:Tork
TT: Titreşim
TTİ: Titreşim İvmesi
TTS: Titreşim Sinyalleri
XGB: Aşırı Gradyan Artırma Regresyonu
YSA: Yapay Sinir Ağı