



KPI based performance estimation in production systems using deep learning techniques

Taha Akkurt*^{ID}, İnci Sarıççek^{ID}

Department of Industrial Engineering, Faculty of Engineering and Architecture, Eskişehir Osmangazi University, 26040, Eskişehir, Türkiye

Highlights:

- Measurement of production performance with key performance indicators
- Production performance estimation with different deep learning techniques
- Comparison of deep learning techniques in estimation

Keywords:

- Key performance indicators
- Performance estimation
- Deep learning
- Long Short Term Memory
- Light Gradient Boosting Machines

Article Info:

Research Article

Received: 08.04.2022

Accepted: 11.08.2023

DOI:

10.17341/gazimmfd.1100614

Correspondence:

Author: Taha Akkurt

e-mail:

akkurttaha@gmail.com

phone: +90 531 263 2576

Graphical/Tabular Abstract

This study focuses on the monitoring of key performance indicators to measure production system performance and the estimation of future performance of the system. In this direction, the CNC machine performances are measured by using eleven key performance indicators. On the other hand, LSTM and LightGBM models which are deep learning techniques are proposed for the estimation of performance indicators. The estimation performance of methods is compared over performance metrics. The results indicated that LightGBM outperforms LSTM for all performance metrics.

Table A. The estimation performances of LSTM and LightGBM

Metric	LSTM	LightGBM
MSE	15.731	2.958
RMSE	3.966	1.719
MAE	3.395	1.485
MAPE	3.611	1.606

Purpose:

The main objective of this study is to measure and estimate production performance. In this way, it is aimed to provide a proactive approach for the assets whose performance is monitored by the decision-makers. The proposed system makes it possible to take an early position for emergencies.

Theory and Methods:

Key Performance Indicators (KPI) are critical and vital to monitor the performance of production system. In this study, eleven KPIs are determined to measure the production performance by taking into account the factory assets. Deep learning approaches are proposed for estimation of the next KPI value. Deep learning is a machine learning method that aims to create autonomous learning structures in itself by imitating the human brain structure. In this direction, two popular deep learning methods, LSTM and LightGBM, are chosen for estimation. LSTM is referred to as an artificial neural network model, which has a structure in which both the past and future information flow is provided between the ordered neurons and this flow is repeated. LightGBM generates results by creating histogram-based decision trees. Finally, MSE, RMSE, MAE and MAPE metrics are used to compare the estimation performance of the methods.

Results:

The approximately three-month time series OEE (Overall Equipment Effectiveness) values of the sample CNC machine are used for estimation. The performance of the LSTM is compared with the performance of the LightGBM. MSE, RMSE, MAE and MAPE metrics are used to compare the estimation performance of the methods. LightGBM gives the lowest values (these values are given in Table A) for all performance metrics.

Conclusion:

In this study, the CNC machine performances are measured by using eleven key performance indicators. The proposed system aims to provide significant advantages to businesses by estimating KPI values. The performance estimation is established with LSTM and LightGBM methods. The estimation performance of methods is compared over performance metrics (MSE, MAE, etc.). The results indicated that LightGBM outperforms LSTM for all performance metrics.



Derin öğrenme teknikleri kullanılarak üretim sistemlerinde KPI tabanlı performans tahminleme

Taha Akkurt*^{ID}, İnci Sarıççek^{ID}

Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Endüstri Mühendisliği Bölümü, 26040, Eskişehir, Türkiye

ÖNEÇIKANLAR

- Anahtar performans göstergeleri ile üretim performansının ölçümü
- Farklı derin öğrenme teknikleri ile üretim performansı tahminleme
- Derin öğrenme tekniklerinin tahminleme başarılarının karşılaştırılması

Makale Bilgileri

Araştırma Makalesi
Geliş: 08.04.2022
Kabul: 11.08.2023

DOI:

10.17341/gazimmfd.1100614

Anahtar Kelimeler:

Anahtar performans göstergeleri, performans tahminleme, derin öğrenme, uzun kısa süreli bellek, hafif gradyan artırma makineleri

ÖZ

İmalat sektöründe yer alan firmaların, piyasadaki rekabet koşullarında gelişimlerini sürdürebilmeleri için performanslarını sürekli izlemeleri gerekmektedir. Bu çalışmada, fabrika varlıkları dikkate alınarak üretim performansını ölçmek için on bir adet anahtar performans göstergesi belirlenmiştir. Önerilen sistem, bir üretim sistemindeki CNC makinelerinden alınan anlık veriler ile ilgili KPI'ların elde edildiği yapıda tasarlanmıştır. Bu çalışmanın temel amacı, üretim performansını ölçmek ve bir sonraki değerlerini tahmin etmektir. Bu sayede karar vericiler tarafından performansı izlenen varlıklara proaktif bir yaklaşım sağlanması amaçlanmaktadır. Performans göstergelerinin tahmin edilmesi için derin öğrenme teknikleri olan LSTM ve LightGBM modelleri önerilmiştir. Tahminleme için örnek bir CNC makinesinin yaklaşık üç aylık zaman serisi OEE (Toplam Ekipman Etkinliği) değerleri kullanılmıştır. Yöntemlerin tahmin performansları, çeşitli metrikler (MSE, MAE vb.) üzerinden karşılaştırılmıştır. Sonuçlar, LightGBM'nin tüm performans ölçümleri için LSTM'den daha iyi performans gösterdiğini göstermiştir.

KPI based performance estimation in production systems using deep learning techniques

HIGHLIGHTS

- Measurement of production performance with key performance indicators
- Production performance estimation with different deep learning techniques
- Comparison of deep learning techniques in estimation

Article Info

Research Article
Received: 08.04.2022
Accepted: 11.08.2023

DOI:

10.17341/gazimmfd.1100614

Keywords:

Key performance indicators, performance estimation, deep learning, long short term memory, light gradient boosting machines

ABSTRACT

Firms in the manufacturing sector need to constantly monitor their performance in order to maintain their development under competitive conditions in the market. In this study, eleven KPIs are determined to measure the production performance by taking into account the factory assets. The proposed system is designed in which the relevant KPIs are obtained via the instantaneous data received from the CNC machines in a production system. The main objective of this study is to measure and estimate production performance. In this way, it is aimed to provide a proactive approach for the assets whose performance is monitored by the decision-makers. LSTM and LightGBM models which are deep learning techniques are proposed for the estimation of performance indicators. The approximately three-month time series OEE (Overall Equipment Effectiveness) values of the sample CNC machine are used for estimation. The estimation performance of methods is compared over performance metrics (MSE, MAE, etc.). The results indicated that LightGBM outperforms LSTM for all performance metrics.

1. Giriş (Introduction)

Günümüz globalleşen dünyasında firmaların rekabet etmesi giderek zorlaşmaktadır. Piyasada yerini sağlamlaştırmak isteyen her firma kendine ait hedefler belirlemektedir. Bu hedefler işletmeyi sürekli iyileşmeye teşvik edecek nitelikte olmalıdır. En önemli husus ise işletmenin hedeflerine ne kadar ulaştığını bilmesi gerekliliğidir. Eğer bir şey ölçülebiliyorsa, geliştirilebilir. İşletmeler performans izlemek için birçok performans izleme yöntemi kullanılmaktadır. Bu çalışmanın temelini oluşturan anahtar performans göstergeleri (Key Performance Indicators-KPI) de bunlardan biridir. Organizasyonların devam etmekte olan ve gelecekteki başarılarında kritik önem taşıyan performanslarına odaklanan anahtar performans göstergeleri, performans değerlendirmede kullanılan yöntemlerden biridir.

İşletmeler ve kurumlar, amaçlarına ne ölçüde ulaştığını belirlemek için faaliyetlerini değerlendirmelidir. Bu değerlendirmeyi yapmanın olası bir yolu, kuruluşların KPI olarak bilinen performans göstergelerini ölçmektir. KPI'lar, kuruluşun mevcut ve gelecekteki başarısı için en kritik olan yönlerine odaklanan bir dizi önemi temsil eder [1]. KPI'ların kullanılması, ilerlemeyi ölçmenin yanı sıra ilerlemeyi hedeflerle karşılaştırmanın bir yolunu ifade eder. Şirketin hedefleri ile karşılaştırıldığında KPI'lar hedeflerin gerçekleşip gerçekleşmediğine dair bir fikir vermektedir [2].

Literatürde anahtar performans göstergeleri kullanarak tasarlanan birçok üretim izleme ve değerlendirme çalışması bulunmaktadır. Senkuvienė vd. [3] çalışmalarında, Litvanya'daki bir CNC imalat fabrikası için performansı artırmak üzere KPI'lar kullanarak bir üretim izleme sistemi tasarlamışlardır. Tasarlanan sistem gerçek zamanlı üretim takibi ve ekipman iş yükü izleme üzerinedir. Başka bir çalışmada [4], esnek üretim sistemleri (FMS) için dinamik makine kullanım oranı ve toplam ekipman etkinliği (OEE) gibi anahtar performans göstergeleri kullanılarak bağlama duyarlı bir optimizasyon yaklaşımı sunulmuştur. Riexinger vd. [5], çalışmalarında çevresel, operasyonel ve ekonomik yönlere odaklanan dinamik anahtar performans göstergeleri içeren bütünsel bir üretim modeli ve simülasyon sistemi tasarlamışlardır. Üretim hattından toplanan veriler KPI odaklı olarak izlenip, görselleştirilip analiz edilmektedir. Diğer bir çalışmada [6], lojistik işletmeleri için anahtar performans göstergelerine dayalı bir performans değerlendirme modeli önerilmiştir. Wohler vd. [7], çalışmalarında anahtar performans göstergeleri ile istatistiksel süreç kontrolü tekniklerini bir arada kullanmışlardır. Skylakha vd. [8], çalışmalarında Hindistan'daki bir hastane için performans yönetimine dayalı bir karar destek sistemi hazırlamışlardır. Bu doğrultuda 5 bölümde 44 gösterge belirlenmiş, yıllık 350 GB boyutunda veriyle analiz edilmiş ve sağlık izleme sisteminin kurumsal performansı ölçülmüştür. Ayrıca makine öğrenmesi algoritmalarıyla da (trend analizi vb. yöntemler) geleceğe yönelik kestirimler çıkarılmıştır. Sikora vd. [9], köprü vinç ekipmanı için canlı durum izleme sistemi tasarlanmıştır. Ayrıca tüm gösterge verileri incelenerek kestirimci bakım için analizler çıkarılmıştır.

Tahminleme çalışmaları da son yıllarda giderek artmaktadır. Bu çalışmada kullanılan LSTM veya LightGBM yöntemlerinin tahminleme için literatürde kullanıldığı görülmüştür. Ma vd. [10] çalışmalarında, uçak motorlarının kalan faydalı ömür (RUL) tahmini için LightGBM yönteminin yer aldığı bir model önerilmiştir. Başka bir çalışmada [11], imalat atölyesinde çevrim süresi tahmini için LSTM kullanılmıştır. Aniekan vd. [12], akıllı fabrika sistemi içerisinde makine hızı tahminlemesi için hibrit bir LSTM yöntemi kullanmıştır. Bir diğer çalışmada [13] inşaat projelerinde atık değer tahmini için LightGBM yöntemi denenmiştir. Üretim sistemlerinde tahminleme konusunda LSTM ve LightGBM yöntemlerinin bir arada kullanıldığı çalışmalar da literatürde mevcuttur. Xiangqian vd. [14],

çalışmalarında kömür madenlerindeki gaz konsantrasyonu tahmini için LSTM ve LightGBM yöntemleri bir arada kullanılmıştır. İlgili problem için LSTM yöntemi daha başarılı sonuç vermiştir. Başka çalışmada ise [15], bir enerji üretim tesisinde rüzgâr kuvveti tahminlemesi için LSTM ve LightGBM yöntemleriyle hibrit bir algoritma oluşturulmuş ve başarılı sonuçlar elde edilmiştir. Zhang vd. [16], çalışmalarında satış tahminleri için LightGBM ve LSTM'ye dayalı karma bir model önermiştir. Bir diğer çalışmada [17], tedarik zincirindeki satışları doğru bir şekilde tahmin edebilmek için LSTM ve LightGBM yöntemlerine dayalı bir model geliştirilmiştir.

Endüstri 4.0 ile dijitalleşme önem kazanmış ve işletmelerde veri analitiği konusunda önemli gelişmeler yaşanmıştır. Günümüzde veriye ulaşmak daha kolay hale gelmiştir. Sistem verilerinin anlık olarak izlenmesi, büyük verinin saklanması ve analizi performans izleme konusunda gelişmeleri de tetiklemiştir. Bu çalışmanın amacı bir talaşlı imalat işletmesinde CNC tezgâhlarından alınan anlık veriler ile üretim sisteminin anahtar performans göstergeleri kullanılarak performansının ölçülmesi ve geleceğe yönelik performans tahminlemesinin gerçekleştirilmesidir. Bu doğrultuda ilk olarak kullanılacak anahtar performans göstergeleri belirlenmiş ve gerçek bir CNC makinesi üzerinden veriler toplanarak performans değerleri elde edilmiştir. Büyük veri teknolojisiyle entegre çalışan sistemde, elde edilen tüm veriler tahminleme çalışmasında kullanılmak üzere oluşturulan veri tabanında saklanmaktadır. Ayrıca, derin öğrenme tekniklerinden LSTM ve LightGBM yöntemleri ile geçmişe yönelik performans değerleri incelenerek, gelecek dönemlerin KPI tahminleri gerçekleştirilmeye çalışılmıştır. Bu sayede, işletmelerin performansını izlediği varlıklar için proaktif yaklaşım sağlaması, acil durumlar için erken pozisyon alması ve Endüstri 4.0 kapsamında kestirimci analizler gerçekleştirmesine yardımcı olunması hedeflenmiştir.

Çalışmanın izleyen bölümlerinde ilk olarak tahminlemede kullanılan derin öğrenme yöntemleri açıklanmıştır. Üçüncü bölümde önerilen sistem, kullanılan anahtar performans göstergeleri, veri seti ve tahminleme modelleri detaylandırılmıştır. Dördüncü bölümde tahminleme sonuçları ve yöntemlerin başarı oranları belirli metrikler üzerinden değerlendirilmiştir. Son bölümde elde edilen sonuçlar tartışılmıştır.

2. Materyal ve Metot (Material and Method)

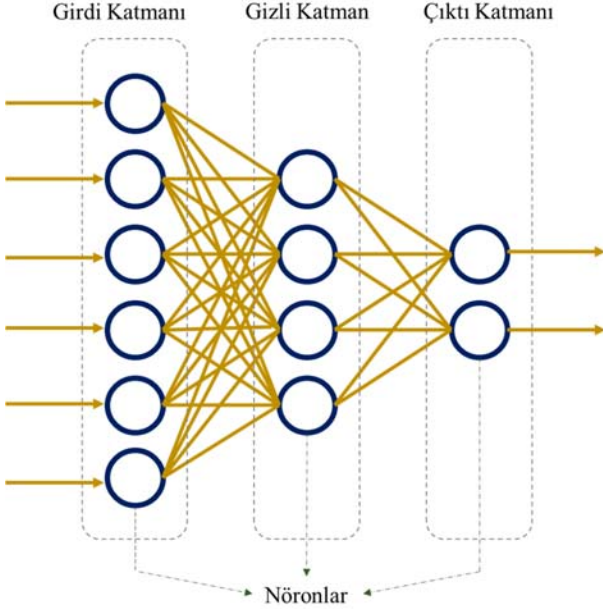
2.1. Derin Öğrenme (Deep Learning)

Derin öğrenme insan yapısını taklit ederek kendi içerisinde otonom öğrenme yapıları oluşturmayı amaçlayan bir makine öğrenmesi yöntemidir. Derin öğrenmenin yapay zekanın bir alt kümesiyken makine öğrenmesinin de bir alt kümesidir. Derin öğrenme, kendisine verilen girdi verilerinden öğrenen ve makineyi karar almaya yetenekli hale getiren derin sinir ağını kullanarak daha uyarlanabilir bir yol sağlar. Makine öğrenmesinin göreve özgü algoritmalarının aksine derin öğrenme, veri temsillerini öğrenmeye dayalı bir yöntemdir [18].

Derin öğrenme ile yapay sinir ağları kavramları çoğu kaynaklarda birlikte kullanılmaktadır. Derin öğrenme yapay sinir ağlarının ileri düzeyli bir yaklaşımıdır. Tek katmanlı yapay sinir ağlarından çok katmanlı yapay sinir ağlarına ve sonrasında derin öğrenme algoritmalarının oluşumuna doğru ilerlemiştir [19].

Yapay sinir ağları, insan beyin yapısından esinlenerek veri iletişimi ve matematiksel hesaplamaların yapılabildiği nöron yapılarına sahiptir. Katmanlar halinde sıralanmış nöronlar, karmaşık modelleri çözmeye önemli rol sahiptir. Bir sinir ağı mimarisinde, girdi katmanı (input layer), çıktı katmanı (output layer) ve ikisinin arasındaki bilgi

akışını sağlayan gizli katman (hidden layer) bulunmaktadır. Modelin sahip olduğu katman sayısı arttıkça, veriler daha karmaşık ve soyut hale gelecektir. Derin öğrenme terimi de bu tip birçok gizli katmana sahip modeller için kullanılmaktadır. Bu sayede daha çok veri işlenebilmekte ve öznelıklar doğrudan ham veriler üzerinden öğrenilebilmektedir. Şekil 1’de örnek bir yapay sinir ağı mimarisi gösterilmiştir.



Şekil 1. Bir yapay sinir ağı mimarisi
(An architecture of artificial neural network)

Literatürde Evrişimli Sinir Ağları (Convolutional Neural Networks-CNN), Yinelemeli Sinir Ağları (Recurrent Neural Networks-RNN), Kısıtlı Boltzman Makineleri (Restricted Boltzmann Machines-RBM), Derin İnanç Ağları (Deep Belief Networks-DBN) ve Derin Oto-Kodlayıcılar (Deep Autoencoders-DAE) gibi farklı türlerde derin öğrenme mimarileri yer almaktadır [20].

2.2. Uzun Kısa Süreli Bellek – LSTM (Long Short Term Memory – LSTM)

Yinelemeli sinir ağları (Recurrent Neural Networks-RNN), sıralanmış nöronlar arasında hem geçmişe hem geleceğe yönelik bilgi akışının sağlandığı ve bu akışın sürekliliği tekrarlandığı bir yapıya sahip yapay sinir ağı modeli olarak geçmektedir. Bu özelliğiyle geçmişe yönelik verilerin incelenerek gelecek tahminlemesinde kullanılmaya oldukça elverişlidir.

RNN için hafıza açısından çok geriye gitmek mümkün değildir. Bu aşamada RNN’lerin çok yaygın kullanılan bir türü olan Uzun Kısa Süreli Bellek (Long Short Term Memory-LSTM) ortaya çıkmaktadır. LSTM, veri sırasını ezberlemek için ek özelliklere sahip özel bir RNN türüdür. Her LSTM, veri akışlarının yakalandığı ve depolandığı bir dizi hücre veya sistem modülünden oluşur [21]. Şekil 2’de LSTM yapısı gösterilmiştir.


LSTM hücre yapısında giriş kapısı, unutmaya kapısı, çıkış kapısı ve hafıza hücresi vardır. Unutmaya kapısı bilginin ne kadarının geçirileceğine karar verir. 0 ile 1 arasında değer alır ve 1 verinin olduğu gibi geçmesini 0 ise bilginin hiçbir şekilde geçmemesini sağlar. Giriş kapısında ise hangi verilerin güncellenmesi gerektiği “tanh” fonksiyonu kullanılarak belirlenir. Son çıkış kapısında ise ilk iki kapıdan geçen veri -1 ile 1 arasına getirilecek şekilde “tanh” fonksiyonu ile çarpılarak sonuç elde edilir [23].

2.3. Hafif Gradyan Arttırma Makineleri-LightGBM (Light Gradient Boosting Machines- LightGBM)

LightGBM, Microsoft tarafından 2017’de önerilen GBDT’ye (Gradient Boosting Decision Tree – Gradyan Arttırıcı Karar Ağaçları) dayalı bir veri modelidir. Gradyan artırma, regresyon ve sınıflandırma problemlerinde kullanılan bir makine öğrenmesi tekniğidir. Zayıf tahmin modelleri bir araya getirilerek karar ağaçlarının oluşturduğu bir model oluşturulmaktadır. Bununla birlikte, GBDT algoritmasında kullanılan karar ağacı sadece bir regresyon ağacı olabilir, çünkü algoritmanın her ağacı, önceki tüm ağaçların sonuçlarını ve kalıntılarını öğrenir. GBDT, birçok makine öğrenimi görevinde iyi öğrenme sonuçları elde etmesine rağmen, son yıllarda veri hacminin geometrik büyümesiyle çözüm süresi açısından tartışılmaktadır. LightGBM algoritması ise tahmin doğruluğunu azaltmadan tahmin hızını büyük ölçüde hızlandırması ve bellek kullanımını azaltması özelliğiyle öne sürülmüştür [24].

Çoğu karar ağacı algoritması Derinlik Öncelikli Arama (Depth-First Search) ya da seviye odaklı (level-wise) arama stratejisi kullanırken, LightGBM En iyi Öncelikli Arama (Best-First Search) ya da yaprak odaklı (leaf-wise) arama stratejisini kullanmaktadır. Şekil 3’te ilgili arama stratejilerinin görselleri verilmiştir.

LightGBM, yaprak odaklı ağaç oluşturma stratejisi ve histogram tabanlı algoritma kullanarak diğer modellere göre daha hızlı sonuçlar elde edebilmektedir. Ayrıca LightGBM tarafından kullanılan EFB algoritması, gereksiz özelliklerin hesaplanmasını önlemek için büyük boyutta verinin birçok özelliğini seyrek bir özellik alanında bir araya getirmektedir. Böylece bilgisayarlar için işlem hacmi de önemli ölçüde azalmaktadır. Birden fazla veri kümesi üzerinde yapılan deneyler, LightGBM modelinin geleneksel GBDT algoritmasının eğitim sürecini 20 kata kadar hızlandırırken neredeyse aynı doğruluğu elde ettiğini göstermiştir [25].



Şekil 2. LSTM yapısı (Structure of LSTM) [22]

3. Deneysel Çalışmalar (Experimental Studies)

Önerilen sistem kapsamında üç temel çalışma gerçekleştirilmiştir. İlk olarak literatür dikkate alınarak sistem kapsamına alınacak anahtar performans göstergeleri belirlenmiştir. Ardından uygulamanın yapılabilmesi için bir veri tabanı oluşturulmuştur. İlgili veri tabanı kullanılarak LSTM ve LightGBM yöntemleri ile performans göstergelerinin tahminlemesi gerçekleştirilmiştir. Elde edilen sonuçlar analiz edilerek birbirleriyle karşılaştırılmıştır. Şekil 4'te önerilen sistemin mimarisi görselleştirilmiştir.

Gerçek bir CNC makinesinden toplanan üretim verileri ilgili hesaplamalar yapılarak anahtar performans göstergelerine dönüştürülmüştür. Gün bazında hesaplanan ve PostgreSQL veri tabanında saklanan veriler kullanılarak iki farklı yöntem ile gelecek tahminlemesi gerçekleştirilmiştir. İzleyen başlıklarda bu çalışmaların detayları verilmiştir.

3.1. Veri Seti (Dataset)

Gerçekleştirilen literatür araştırmasıyla birlikte, üretim performansını her yönüyle ölçebilmek için işletme şartları da göz önünde bulundurularak 11 KPI belirlenmiştir. Göstergeler belirlenirken çeşitli kaynaklar baz alınmış ancak çoğu kaynağın temelini 2007 yılında İngiliz Standartlar Enstitüsü (BSI) tarafından yayımlanan "EN 15341 Bakım Anahtar Performans Göstergeleri" standartlarına dayandığı görülmüştür.

Göstergeler hesaplanırken aynı parçaya, makineye ve zaman dilimine (yıl, çeyrek, ay, vb.) ait veriler kullanılır. Çoğu gösterge, tesis üretiminin, bir üretim hattının veya belirli bir ekipmanın performansını ölçmek için farklı seviyelerde kullanılabilir. Bu göstergelerin ölçümü ve analizi, yönetime aşağıdaki konularda yardımcı olabilir [26]:

- Güncel durumu ölçmek
- Performansı değerlendirmek
- Performansı karşılaştırmak
- Güçlü ve zayıf yönleri belirlemek
- Kontrol ilerlemesini ve zaman içindeki değişiklikleri kontrol etmek

ISO 22400 standartlarına göre, kullanılan göstergelerin adı, tanımı ve formülü Tablo 1'de yer almaktadır.


Belirlenen KPI'ların değerleri, Eskişehir OSB'de faaliyet gösteren bir fabrikadaki CNC makinesinden alınan veriler doğrultusunda elde edilerek veri seti oluşturulmuştur. Şekil 5'te veri setinin belirli bir kısmının örnek ekran görüntüsü yer almaktadır.

Yaklaşık 3 aylık, 95 satırdan oluşan ve zaman serisi formatında olan veriler günlük olarak toplanmıştır. Ardından bu performans değerleri kullanılarak tahminleme çalışmaları gerçekleştirilmiştir.

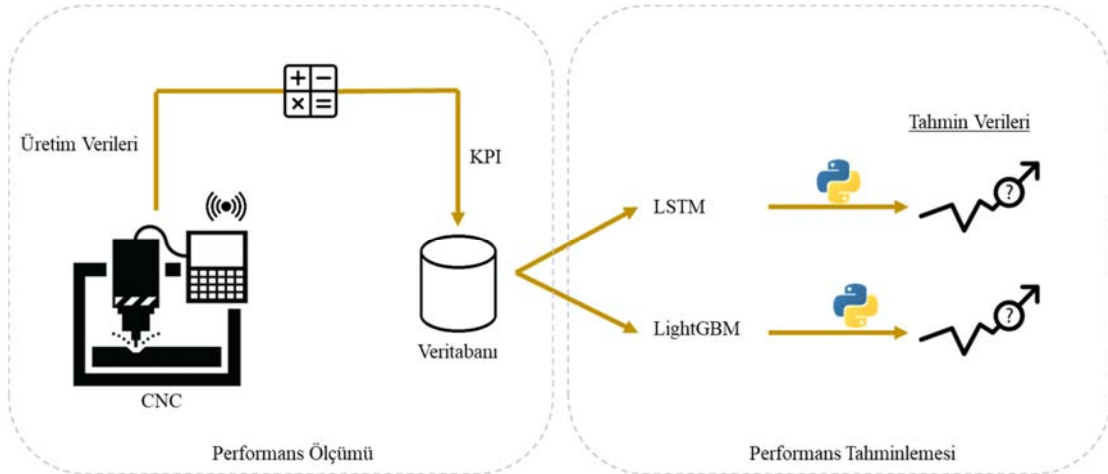
3.2. Tahminleme Modelleri (Estimation Models)

Kodlama çalışmaları Python programlama dili ile Google Colab üzerinde gerçekleştirilmiştir. Tek bir KPI tahminlemek için tarih verisi ve diğer KPI değerleri kullanarak çok değişkenli (multivariate) tahminleme gerçekleştirilmiştir. Veri setindeki son 15 günlük değerler test verisi olarak ayrılmıştır. Daha başarılı sonuçlar elde etmek için min-max normalizasyon işlemi gerçekleştirilmiştir. Ardından iki farklı yöntem için model parametreleri belirlenmiştir.

LSTM Modeli: LSTM uygulaması, açık kaynak kodlu Keras kütüphanesi kullanılarak gerçekleştirilmiştir. Model parametreleri için çeşitli optimizasyon çalışmaları yapılmış olup nihai LSTM modeli şu şekilde kurulmuştur:



Şekil 3. Ağaç oluşturma stratejileri (The generation strategies of tree)



Şekil 4. Önerilen sistem mimarisi (An architecture of the proposed system)

Tablo 1. Önerilen sistemdeki anahtar performans göstergeleri (Key performance indicators in the proposed system)

KPI (İng.)	Tanım	Formül
Asset utilization	Varlık kullanımı	(Toplam çalışma süresi / Toplam çalışılabilecek süre) * 100
Availability	Varlıkların kullanılabilirliği	[(Planlanan süre – Duruş süresi) / Planlanan süre] * 100
Capacity utilization	Kapasite kullanımı	(Gerçekleşen çıktı / Hedeflenen çıktı) * 100
Downtime	Duruş süresi oranı	(Duruş süresi / Planlanan süre) * 100
Mean time between failure (MTBF)	Arızalar arası ortalama süre	Toplam çalışma süresi / Toplam arıza sayısı
Mean time to repair	Ortalama onarım süresi	Toplam tamir süresi / Toplam arıza sayısı
Defect rate	Kusurlu oranı	(Toplam kusurlu ürün adedi / Toplam ürün adedi) * 100
Completion ratio	Zamanında tamamlanan iş oranı	(Gerçekleşen iş emri sayısı / Toplam iş emri sayısı) * 100
Performance rate	Bir sürecin aktif olarak çalıştığı periyotta üretim için geçen sürenin etkin süreye oranı	[(Standart süre / Adet) * Üretilen adet] / (Planlanan süre – Duruş süresi) * 100
Quality rate	Toplam üretim miktarındaki kusurlu ürün sayısı oranı	[(Toplam ürün adedi – Kusurlu ürün adedi) / Toplam ürün adedi] * 100
OEE (Overall Equipment Efficiency) rate	Toplam ekipman etkinliği	Kullanılabilirlik * Performans * Kalite

Tarih	Varlık Kullanımı	Performans Oranı	Kusurlu Oranı	Tamamlanma Oranı	Toplam Duruş Adedi	Kullanılabilirlik	OEE Oranı	Kalite oranı	Kapasite Kullanımı	Toplam Duruş Süresi	Toplam Üretim Adedi
0 2020-10-05	100	91	0	100	5	100	91	100	97	22	129
1 2020-10-03	100	90	0	100	13	100	90	100	94	183	312
2 2020-10-02	100	91	1	100	15	100	91	99	92	95	406
3 2020-10-01	100	90	0	100	21	100	90	100	92	86	822
4 2020-09-30	100	95	0	100	24	100	95	100	95	104	798

Şekil 5. Veri setinin kısmi ekran görüntüsü (Screenshot from a part of dataset)

- Lookback: 5 (Bir sonraki zaman adımını tahmin etmek için geriye dönük kaç tane önceki zaman adımı kullanıldığını tanımlar.)
- Katman Sayısı: 256
- Aktivasyon Fonksiyonu: ReLU
- Optimizasyon Fonksiyonu: Adam
- Hata Fonksiyonu: Mean Squared Logarithmic Error
- Epochs: 50

LightGBM Modeli: LightGBM uygulaması, açık kaynak kodlu Lightgbm kütüphanesi kullanılarak gerçekleştirilmiştir. Model parametreleri için çeşitli parametre optimizasyon çalışmaları yapılmış olup nihai model şu şekilde kurulmuştur:

- Boosting Type: GBDT (Karar ağaçları temelli gradyan artırma)
- Objective: Regresyon (Çözülecek problem tipini gösterir.)
- Yaprak Sayısı: 31
- Öğrenme Oranı: 0,05

Tahminleme çalışmaları OEE (Overall Equipment Effectiveness-Toplam Ekipman Etkinliği) göstergesi üzerinde gerçekleştirilmiştir. OEE, CNC makinesinin zamanının ne kadar etkin kullanıldığını gösteren ve işletmeler için oldukça önemli bir göstergedir. Sonuçlar bir sonraki başlıkta tartışılmıştır.

4. Sonuçlar ve Tartışmalar (Results and Discussions)

Üretim performansı ölçmek ve tahminlemek amacıyla önerilen sistemde ilk olarak anahtar performans göstergeleri belirlenmiş ardından gerçek CNC veriyle bir veri seti oluşturulmuştur. İki farklı tahminleme yöntemi için modellerin kurulmasının ardından algoritmalar çalıştırılmış ve sonuçlar elde edilmiştir. Yöntemlerin tahminleme başarısını ölçmek için çeşitli performans göstergelerinden yararlanılmıştır.

Hata Kareleri Ortalaması (Mean Squared Error – MSE): Tahmin hatalarının karesinin toplamının ortalaması olarak hesaplanır (en iyi değeri = 0) [27]. Formülü Eş. 1’de verilmiştir.

$$MSE = \frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2 \quad (1)$$

Hata Kareleri Ortalamasının Karekökü (Root Mean Squared Error – RMSE): MSE’nin karekökü, hataların standart sapması olarak adlandırılır (en iyi değeri = 0) [27]. Formülü Eş. 2’de verilmiştir.

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2} \quad (2)$$

Mutlak Hata Ortalaması (Mean Absolute Error – MAE): İki değişken arasındaki mutlak farkın ortalaması olarak hesaplanır (en iyi değeri = 0) [27]. Formülü Eş. 3'te verilmiştir.

$$MAE = \frac{1}{m} \sum_{i=1}^m |X_i - Y_i| \quad (3)$$

Mutlak Yüzde Hata Ortalaması (Mean Absolute Percentage Error – MAPE): Mutlak varyasyonlardan ziyade göreceli varyasyonlara duyarlı olmanın daha önemli olduğu durumlarda kullanılabilir (en iyi değeri = 0) [28]. Formülü Eş. 4'te verilmiştir.

$$MAPE = \frac{1}{m} \sum_{i=1}^m \left| \frac{Y_i - X_i}{Y_i} \right| \quad (4)$$

İlk olarak elde edilen tahmin verileri ile gerçekleşmesi beklenen 15 günlük test verileri karşılaştırılmıştır. Beklenen ve gerçekleşen değerler arasındaki yüzde fark hesaplanmıştır. LSTM yöntemiyle elde edilen tahmin değerleri gerçekleşmesi beklenen değerlerden %3,61 farklı iken, bu oran LightGBM'de %1,61'dir. Tablo 2'de ilgili yöntemlerin tahminleme başarılarının karşılaştırması verilmiştir.

Karşılaştırmanın daha anlaşılır olması için sonuçlar grafik üzerinde gösterilmiştir. Grafikteki mavi çizgi eğitim, sarı çizgi test verisi ve yeşil çizgi ilgili yöntemle elde edilen tahmin değerini göstermektedir. Şekil 6a'da LSTM, Şekil 6b'de ise LightGBM yöntemleriyle elde

edilen tahmin değerlerinin grafiği yer almaktadır. LightGBM yöntemi ile test verilerine daha yakın ve daha başarılı sonuçlar üretildiği görülmektedir.

Son olarak, kullanılan iki yöntemin tahminleme başarısı yukarıda tanımları verilen performans metrikleri temelinde değerlendirilmiştir. Sonuçlar Tablo 3'te özetlenmiştir.

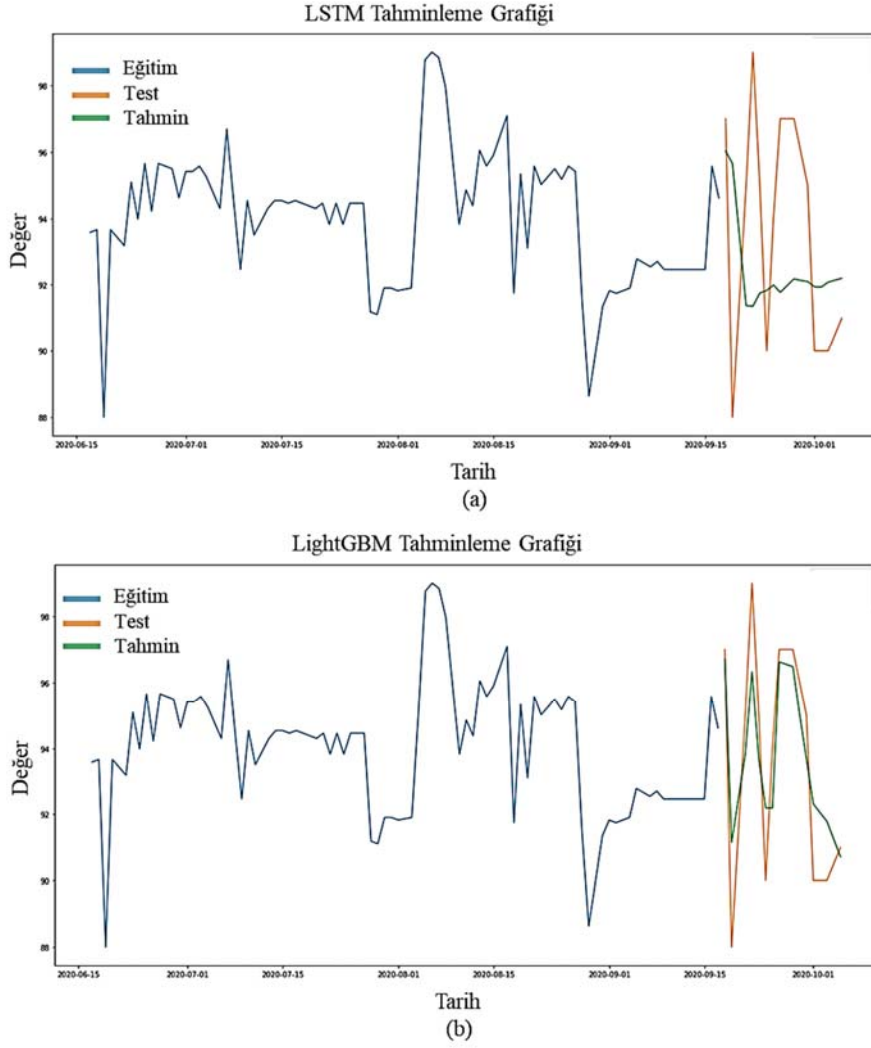
Elde edilen sonuçlara göre iki yöntemin de üretim sistemlerinde performans tahminlemesi için kullanılabilirliği gösterilmiştir. Çözüm süresi bakımından iki yöntem de kabul edilebilir sürede tahminler üretmiştir. Ancak Tablo 3'teki metriklerin sonucuna bakıldığında LightGBM yönteminin tahminleme başarısının daha yüksek olduğu sonucuna varılmıştır. Bu sonuçlarda veri seti boyutunun, normalizasyon ve aykırı değer tespiti gibi veri analiz işlemlerinin ve model parametrelerinin önemli etkileri bulunmaktadır. LSTM yöntemi için başarı oranı veri boyutuyla doğru orantılıdır. Dolayısıyla bu çalışmada kullanılan 95 satırlık veri seti için sonuçlar pek başarılı olmamıştır. Veri seti boyutu artırılarak modelin öğrenme performansı iyileştirilebilir. LightGBM yöntemine bakıldığında, yaprak odaklı ağaç oluşturma stratejisi sonuca hızlı ulaşsa da küçük veri setleri için aşırı öğrenme (overfitting) sorunu yaşayabilmektedir. Bu veri setinde LightGBM ile başarılı sonuçlar elde edilse de büyük veri setleri üzerinde denemeler yapılarak daha kapsamlı bir karşılaştırma yapılabilir.

Tablo 2. Test veri setinde beklenen ve gerçekleşen değerler (Expected and estimated values in test dataset)

Test Verileri		LSTM		LightGBM	
No	Beklenen	Gerçekleşen	Fark (%)	Gerçekleşen	Fark (%)
1	91,00	92,19	1,31	90,71	0,32
2	90,00	92,08	2,31	91,78	1,98
3	90,00	91,93	2,14	92,04	2,27
4	90,00	91,94	2,16	92,31	2,57
5	95,00	92,1	3,05	93,67	1,40
6	96,00	92,13	4,03	95,02	1,02
7	97,00	92,18	4,97	96,47	0,55
8	97,00	91,77	5,39	96,62	0,39
9	94,00	91,99	2,14	92,19	1,93
10	90,00	91,83	2,03	92,19	2,43
11	95,00	91,75	3,42	93,66	1,41
12	99,00	91,36	7,72	96,32	2,71
13	95,00	91,37	3,82	93,8	1,26
14	88,00	95,64	8,68	91,14	3,57
15	97,00	96,03	1,00	96,7	0,31
Ortalama Fark (%)			3,61	1,61	

Tablo 3. LSTM ve LightGBM tahminleme performansları (Estimation performances of LSTM and LightGBM)

Metrik	LSTM	LightGBM
MSE	15,731	2,958
RMSE	3,966	1,719
MAE	3,395	1,485
MAPE	3,611	1,606



Şekil 6. LSTM ve LightGBM tahminleme grafikleri (Estimation plots of LSTM and LightGBM)

5. Sonuçlar (Conclusions)

Endüstri 4.0 ile birlikte, üretim sistemlerinde yapay zekâ kullanımı giderek yaygın hale gelmektedir. Özellikle derin öğrenme ile tahminleme konusu, işletmelerin proaktif bir yaklaşım sergilemeleri için oldukça önemlidir. Bu çalışmada üretim performansını ölçmek için anahtar performans göstergelerinin izlenmesi ve geleceğe yönelik performans tahminlemesi yapılmıştır. Belirlenen 11 anahtar performans göstergesiyle örnek bir CNC makinesinin 3 aylık performans değerleri izlenmiş, ardından bu veriler tahminleme çalışması için kullanılmıştır. LSTM ve LightGBM olmak üzere iki farklı derin öğrenme yöntemiyle tahminleme çalışmaları gerçekleştirilmiştir. Yöntemlerin tahminlemedeki başarıları farklı performans göstergeleri (MSE, MAE vb.) üzerinden değerlendirilmiş ve sonuçlar LightGBM yönteminin LSTM yöntemine göre daha başarılı tahminler ürettiğini göstermiştir. Bu çalışmada sunulan sonuçlar, tahminleme problemlerinde model seçimi için yol gösterici bir referans sağlamaktadır.

İşletmeler için üretimin sürekliliği açısından makine ve iş gücü performansının periyodik olarak izlenmesi ve olağan dışı istenmeyen durumların önceden fark edilebilmesi önem arz etmektedir. Bu sebeple yapay zekâdaki gelişmelerin sağladığı imkânları da içeren

sistemlerin geliştirilmesi mümkün hale gelmiştir. Bu çalışmada anahtar performans göstergeleri ile performansın izlenmesinin yanında, derin öğrenme yöntemleriyle ilgili göstergelerin izleyen dönemlerde alacağı değerlerin önceden fark edilebileceği bir sistem tasarlanarak karar vericilerin erken önlem alabilmeleri sağlanmıştır. Gelecekteki çalışmalarda, ilgili tahminleme modelleri için farklı boyutlardaki veri setleri kullanılarak çalışmalar yapılabilir. Ayrıca bu çalışmada kullanılan modellerin yanı sıra diğer tahminleme yöntemleriyle de kestirimci analizler gerçekleştirilebilir ve sonuçlar karşılaştırılabilir.

Teşekkür (Acknowledgement)

Bu çalışmada kullanılan veriler, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'nun (TÜBİTAK) 1170452 no'lu "Otomotiv Endüstrisi için Akıllı Üretim Yönetim Sistemi-IOTOPRO" proje çerçevesinde elde edilmiştir.

Kaynaklar (References)

1. Domínguez, E., Pérez, B., Rubio, Á.L., Zapata, M.A., A taxonomy for key performance indicators management, *Computer Standards & Interfaces*, 64, 24-40, 2019.

2. Samir, K., Khabbazi, M.R., Maffei, A., Onori, M.A., Key performance indicators in cyber-physical production systems, *Procedia CIRP*, 72, 498-502, 2018.
3. Senkuvienė, I., Jankauskas, K., Kvietkauskas, H., Using manufacturing measurement visualization to improve performance, *Mechanics*, 20 (1), 99-107, 2014.
4. Uddin, M.K., Puttonen, J., Martinez Lastra, J.L., Context-sensitive optimisation of the key performance indicators for FMS, *International Journal of Computer Integrated Manufacturing*, 28 (9), 958-971, 2015.
5. Rixinger, G., Holtewert, P., Bruns, A., Wahren, S., Tran, K., Bauernhansl, T., KPI-focused simulation and management system for eco-efficient design of energy-intensive production systems, *Procedia CIRP*, 29, 68-73, 2015.
6. Küçükaltan, B., Irani, Z., Aktas, E., A decision support model for identification and prioritization of key performance indicators in the logistics industry, *Computers in Human Behavior*, 65, 346-358, 2016.
7. Wohlers, B., Dziwok, S., Schmelter, D., Lorenz, W., Improving quality control of mechatronic systems using KPI-based statistical process control, *International Conference on Applied Human Factors and Ergonomics*, 398-410, 2018.
8. Skylakha, S., Sakthivel, P., Arunselvan, K. S., Empirical study on application of machine learning techniques for resource allocation in health care using KPI, *The Journal of Supercomputing*, 76 (4), 2266-2274, 2020.
9. Sikora, M., Szczyrba, K., Wróbel, Ł., Michalak, M., Monitoring and maintenance of a gantry based on a wireless system for measurement and analysis of the vibration level, *Eksplotacja i Niezawodność*, 21 (2), 341-350, 2019.
10. Ma, Z., Zeng, H., Guo, J., Gu, T., Mao, S., Yang, T., The application of CNN-LightGBM algorithm in remaining useful life prediction, In *2020 7th International Conference on Information Science and Control Engineering (ICISCE)*, 1411-1418, 2020.
11. Wang, J., Zhang, J., Wang, X., Bilateral LSTM: A two-dimensional long short-term memory model with multiply memory units for short-term cycle time forecasting in re-entrant manufacturing systems, *IEEE Transactions on Industrial Informatics*, 14 (2), 748-758, 2017.
12. Essien, A., Giannetti, C., A deep learning model for smart manufacturing using convolutional LSTM neural network autoencoders, *IEEE Transactions on Industrial Informatics*, 16 (9), 6069-6078, 2020.
13. Shehadeh, A., Alshboul, O., Al Mamlook, R. E., Hamedat, O., Machine learning models for predicting the residual value of heavy construction equipment: An evaluation of modified decision tree, LightGBM, and XGBoost regression, *Automation in Construction*, 129, 103827, 2021.
14. Wang, X., Xu, N., Meng, X., Chang, H., Prediction of gas concentration based on LSTM-LightGBM variable weight combination model, *Energies*, 15 (3), 827, 2022.
15. Cao, Y., Gui, L., Multi-step wind power forecasting model using LSTM networks, similar time series and LightGBM, In *2018 5th International Conference on Systems and Informatics (ICSAD)*, 192-197, 2018.
16. He, Z., Yu, S., Application of LightGBM and LSTM combined model in vegetable sales forecast, In *Journal of Physics: Conference Series*, 1693 (1), 012110, 2020.
17. Weng, T., Liu, W., Xiao, J., Supply chain sales forecasting based on lightGBM and LSTM combination model, *Industrial Management & Data Systems*, 265-279, 2019.
18. Ganatra, N., Patel, A., A comprehensive study of deep learning architectures, applications and tools, *International Journal of Computer Sciences and Engineering*, 6 (12), 701-705, 2018.
19. Doğan, F., Türkoğlu, İ., Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması, *Sakarya University Journal of Computer and Information Sciences*, 1 (1), 10-21, 2018.
20. Şeker, A., Diri, B., Balık, H. H., Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme, *Gazi Mühendislik Bilimleri Dergisi*, 3 (3), 47-64, 2017.
21. Siami-Namini, S., Namin, A.S., Forecasting economics and financial time series: ARIMA vs. LSTM, *arXiv preprint arXiv:1803.06386*, 2018.
22. Burcu, C., LSTM ağları ile Türkçe kök bulma, *Bilişim Teknolojileri Dergisi* 12 (3), 183-193, 2019.
23. Altun, S., Alkan, A., LSTM-based deep learning application in brain tumor detection using MR spectroscopy, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38 (2), 1193-1202, 2022.
24. Ju, Y., Sun, G., Chen, Q., Zhang, M., Zhu, H., Rehman, M.U., A model combining convolutional neural network and LightGBM algorithm for ultra-short-term wind power forecasting, *Ieee Access*, 7, 28309-28318, 2019.
25. Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Liu, T.Y., Lightgbm: A highly efficient gradient boosting decision tree, *Advances In Neural Information Processing Systems*, 30, 2017.
26. The European Standard EN 15341:2007, Maintenance key performance indicators, *British Standards Institution*, 2007.
27. Klimberg, R.K., Sillup, G.P., Boyle, K. J., Tavva, V., Forecasting performance measures—what are their practical meaning?, In *Advances In Business And Management Forecasting*, 7, 137-147, 2010.
28. Chicco, D., Warrens, M. J., Jurman, G., The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation, *PeerJ Computer Science*, 7, 623, 2021.

