

Titreşim Optimizasyonu için Akıllı Cnc Router Sistem Tasarımı

Duygu GÜRKAN^{1*}, Ahmet MAVİ¹, İhsan KORKUT¹

¹Gazi University, Faculty of Technology, Department of Manufacturing Engineering, Ankara, Turkey

Article Info

Research article
Received: 05/02/2025
Revision: 11/04/2025
Accepted: 28/04/2025

Keywords

CNC Router
Machining
Deep Learning
Chatter
Cutting Parameters

Makale Bilgisi


Araştırma makalesi
Başvuru: 05/02/2025
Düzeltilme: 11/04/2025
Kabul: 28/04/2025

Anahtar Kelimeler

CNC Router
İşleme
Derin Öğrenme
Tırlama
Kesme Parametreleri

Grafik Özet (Graphical/Tabular Abstract)

Bu çalışma, donanım değişiklikleri ve derin öğrenme algoritmalarını entegre ederek titreşim tabanlı kesme parametresi optimizasyonunu gerçekleştiren, operatör müdahalesinden bağımsız akıllı CNC router tasarımı ve montajını sunmaktadır. / This study presents the design and assembly of an intelligent CNC router capable of real-time vibration-based optimization of cutting parameters, integrating deep learning algorithms for adaptive, operator-independent manufacturing.



Şekil A: Sistem tasarım diyagramı/ Figure A: System design diagram

Önemli noktalar (Highlights)

- Kesme parametrelerinin titreşim bazlı gerçek zamanlı optimizasyonu. / Real-time vibration-based optimization of cutting parameters.
- CNN-LSTM derin öğrenme modelinin CNC kontrol sistemine entegrasyonu. / Integration of a CNN-LSTM deep learning model into the CNC control system.
- Değişken devirli fener mili, yeni kontrol kartı ve ivmeölçer sensör arayüzü gibi donanım yükseltmeleri. / Hardware upgrades: variable-speed spindle, new control board, and accelerometer sensor interface.
- C# arayüz ve TCP/IP haberleşme ile operatör müdahalesinden bağımsız uyarlanabilir karar mekanizması. / Operator-independent adaptive decision-making via C# interface and TCP/IP communication.
- Uzun süreli operasyonlarda sistem stabilitesinin ve model dayanıklılığının korunduğu kanıtlanmıştır. / System stability and model robustness were demonstrated over extended operations.

Amaç (Aim): Derin öğrenme kullanarak gerçek zamanlı titreşim ve kalite geri bildirimi temelinde kesme parametrelerini dinamik olarak optimize eden akıllı bir CNC router sistemi tasarlamak ve monte etmek/ To design and assemble a smart CNC router system that dynamically optimizes cutting parameters based on real-time vibration and quality feedback using deep learning.

Özgünlük (Originality): Çalışmanın özgünlüğü, donanım değişikliklerini operatör müdahalesi olmadan parametre optimizasyonu sağlayan CNN-LSTM modeli ile kesintisiz şekilde birleştirmesinde yatmaktadır/ The originality of this work lies in its seamless integration of hardware modifications with a CNN-LSTM model for on-the-fly parameter optimization without operator intervention.

Bulgular (Results): Elde edilen CNC router, kesme parametrelerini otonom ve gerçek zamanda ayarlayarak uyarlanabilir performans sergilemiş ve imalat verimliliği ile kalitesinde artış potansiyeli göstermiştir. / The resulting CNC router exhibited adaptive performance by adjusting cutting parameters autonomously and in real time, demonstrating the potential for increased manufacturing efficiency and quality.

Sonuç (Conclusion): Uzun süreli operasyonlarda sistem stabilitesinin ve model dayanıklılığının korunduğu kanıtlanmıştır. / This intelligent CNC router framework demonstrates a viable pathway towards fully autonomous, quality-assured manufacturing processes.



Titreşim Optimizasyonu için Akıllı Cnc Router Sistem Tasarımı

Duygu GÜRKAN^{1*}, Ahmet MAVİ¹, İhsan KORKUT¹

¹Gazi University, Faculty of Technology, Department of Manufacturing Engineering, Ankara, Turkey

Makale Bilgisi

Araştırma makalesi
Başvuru: 05/02/2025
Düzeltilme: 11/04/2025
Kabul: 28/04/2025

Anahtar Kelimeler

CNC Router
İşleme
Derin Öğrenme
Tırlama
Kesme Parametreleri

Öz

Dünyada dijital teknolojiler ile ivmelenen Endüstri 4.0, geleneksel üretim sistemlerine entegre edilerek, üretim sektörünü önemli boyutta dönüştürmekte ve mevcut endüstriyel süreçlerin dijitalleştirilmesini amaçlamaktadır. Bu dijitalleştirme, insan hatası faktörüne bağlı olmayan, akıllı ve kendisini uyarlayan, kalitesi ve verimi daha yüksek, daha hızlı bir imalat sanayinin en büyük adımı olmaktadır. Bu çalışmada, olması gereken titreşim seviyesi ve istenilen kaliteye göre kesme parametrelerini optimize edebilen akıllı bir CNC Router tasarımı ve montajı yapılmıştır. CNC Router'ın kesme parametrelerini tahmin etmesi ve gerçek zamanlı olarak güncellemesi için Stepcraft CNC Router'a ait makine kontrol kartı, sürücüler, fener mili, güç kaynağı değiştirilmiştir. Ayrıca veri toplama ve kesme parametrelerine müdahale edebilmek için ara yüz tasarımı gerçekleştirilmiştir. Sonuç olarak, kesme parametrelerini olması gereken titreşim seviyesi ve beklenen kaliteye göre tahmin edebilen, operatör müdahalesi olmadan gerçek zamanlı olarak operasyon sürecine karar verebilen ve kendini uyarlayan özgün bir CNC Router elde edilmiştir.

Smart Cnc Router System Design for Vibration Optimization

Article Info

Research article
Received: 05/02/2025
Revision: 11/04/2025
Accepted: 28/04/2025

Keywords

CNC Router
Machining
Deep Learning
Chatter
Cutting Parameters

Abstract

Accelerating with digital technologies in the world, Industry 4.0 is integrating into traditional production systems, transforming the production sector to a significant extent and aims to digitalize existing industrial processes. This digitalization is the biggest step of a manufacturing industry that is not dependent on human error, is smart and adaptable, has higher quality and efficiency, and is faster. In this study, a smart CNC Router that can optimize cutting parameters according to the required vibration level and quality was designed and assembled. In order for the CNC Router to estimate the cutting parameters and update them in real time, the machine control card, drivers, spindle, and power supply belonging to Stepcraft were changed. In addition, an interface design was carried out. As a result, an original CNC Router that can estimate the cutting parameters according to the required vibration level and expected quality, decide on the operation process in real time without operator intervention and adapt itself was obtained.

1. GİRİŞ (INTRODUCTION)

Endüstri 4.0, değer yaratma ekonomisini ve imalat endüstrisini geliştirmekte; üretim süreçleri, daha yüksek üretim verimliliği, daha iyi ürün kalitesi ve daha fazla müşteri memnuniyeti gerektirmektedir. İmalat sektöründe beklentiler artmışken, sürecin genel kalitesini korumak ve iyileştirmek de hayati önem taşımaktadır. Yazılım paketlerinin, gelişmiş istatistiksel süreç kontrolü ve büyük veri analitiği ile entegrasyonu bu iyileştirmeyi sağlamaktadır. Dijitalleşmedeki hızlı ilerleme, Nesnelerin İnterneti (IoT), yapay zeka (AI) ve daha pek çok yenilik ile Endüstri 4.0; tüm üretim sistemini etkilemiş ve imalatla “akıllı üretim” terimini ortaya çıkarmıştır. Akıllı üretim sistemi (AÜS), sensörler, bilgi işlem

platformları, iletişim teknolojileri, simülasyon ve tahmine dayalı, gerçek zamanlı olarak yanıt veren, mühendislik ile entegre olan yeni bir üretim şeklidir [1-4]. Günümüzün imalat makineleri giderek daha karmaşık, daha hızlı ve özel hale gelmektedir, bu da daha yüksek maliyetlere ve enerji tüketimine yol açmaktadır [5]. Talaşlı imalat sektörü toplam enerjinin %30'undan, takım tezgahları ise imalat sanayisinde tüketilen enerjinin %74,7'sinden sorumludur [6]. İmalat endüstrisinin rekabet gücünü arttıran takım tezgahlarından olan Bilgisayarlı Sayısal Kontrol (CNC) otomotiv, havacılık ve savunma sanayi gibi çeşitli imalat endüstrilerinde yaygın olarak kullanılmaktadır [7]. CNC ile üretilen parçaların yüzey pürüzlülüğü ve boyutsal toleransı,

parça ömürleri ve çalışma veriminde önemli etkiye sahiptir [8]. Deneme-yanılma yöntemiyle en iyi parametrelerin bir kombinasyonunu elde etmek oldukça maliyetlidir ve daha fazla malzeme tüketilmesine neden olmaktadır [9]. Operatör deneyimleri yerine daha önceden elde edilen verileri kullanan akıllı üretim, endüstriyi daha verimli, karlı ve sürdürülebilir hale getirmektedir. Ayrıca CNC'lerde makine durumunun izlenmesi için çok yönlü, uyarlanabilir ve uygun maliyetli tekniklere ihtiyaç duyulmaktadır [10]. Akıllı üretim ve makine öğrenmesi, bu karmaşıklıkların önüne geçmek, üretim sürecini önceden tasarlamak, geliştirmek, optimize etmek ve üretim verimliliğini arttırmak için dijital olanaklar sağlamaktadır [11]. Söz konusu yeni sistem ve teknikler, kapsamlı bir enerji bilincine sahip ürün tasarımı yapılmasına, makine verimliliğinin iyileştirilmesine ve üretimin arttırılmasına yardımcı olacaktır [11-12]. Makine öğrenmesi yolu ile takım tezgahlarında yapılan iyileştirmeler, endüstrinin sürdürülebilir kalkınmayı gerçekleştirmesi için önemli bir enerji tasarrufu potansiyeline sahiptir [13-14]. Akıllı üretim, üretimin gelecekteki durumunu ifade etmekte, enerji ve malzeme kullanımını en aza indirerek operasyonların tüm yönlerinde dikkate değer iyileştirmeler sağlamaktadır [10].

Akıllı üretimin büyük bir parçası olan makine öğrenimi, bilgisayarlara deneyimlere dayalı modelleme ve gelecekteki olayları doğru bir şekilde tahmin etme konusunda yardımcı olan önemli bir yapay zeka araştırma alanıdır [15]. Makine öğrenimi yöntemlerinin ortaya çıkmasıyla birlikte üretim sistemleri gerçek zamanlı iletişim ve işbirliği yoluyla fiziksel süreçleri izleyebilmektedir. Makine öğrenmesi, imalat endüstrisinde ekipman arıza süresinin azaltılmasına, üretim hatalarının tespit edilmesine, tedarik zincirinin iyileştirilmesine ve tasarım sürelerinin kısaltılmasına olanak tanımaktadır [16]. Son birkaç yılda şirketlerdeki dijitalleşme, üretimden elde edilen veri miktarında artış sağlamıştır. Modern ve hızlı veri toplama sistemleri, yeni verilerin daha yüksek boyutlarda alınmasına yardımcı olmaktadır. Kaydedilen veriler, süreç analizi, üretkenliği artırmak ve ürün kalitesini tahmin etmek için kullanılabilecek yüksek düzeyde bilgi içermektedir. Yüksek bilgi işlem gücü, gerçek dünya uygulama senaryolarını uygun şekilde temsil etmek için daha büyük hacimli verilere sahip karmaşık modellerin verimli bir şekilde eğitilmesini sağlamaktadır. Özellikle takım tezgahlarına, Makine Öğrenimi yöntemlerinin uygulanması için gereken büyük miktarda veriyi sağlamak üzere birçok donanım eklenmektedir. Makine öğrenmesi CNC işleme teknolojisi ile hızlı bir şekilde entegre olmakta ve imalatta makine

öğrenmesi tabanlı birçok çalışma rapor edilmektedir [17-20].

Çalışmalar talaşlı imalat ve CNC'de genellikle arıza tespiti [12,21-23], kestirimci bakım [8,24], enerji tüketim tahmini [25-27] ve takım aşınması tahmini [11, 28-32] üzerine odaklanmıştır. Takım aşınması genellikle titreşim [33-34] ve kesme parametreleri [35] ile ilişkilendirilmiştir. Ragai ve arkadaşları, frezeleme operasyonunda kesme parametrelerinin takım titreşimi, akustik sinyaller ve güç tüketimi ile ilişkisini araştırmak için tam faktöriyel deney tasarımı yapmışlardır. Ortalama güç tüketiminin iki kesme parametresi ile de orantılı olarak değiştiği gözlemlenirken, ilerleme hızındaki değişimin güç ortalama değeri üzerinde daha yüksek bir etkisinin bulunduğu belirlenmiştir [36]. Guo ve arkadaşları, frezeleme operasyonunda kesme kuvveti ve titreşimi esas alarak MPAN algoritması ile takım aşınmasını tahmin etmeye çalışmışlardır. Yöntemin etkinliği ve uygulanabilirliği, yüksek hızlı frezeleme deneyleri ile doğrulanmıştır [37].


Literatür incelendiğinde, Endüstri 4.0'da sensör tabanlı veri toplamanın artmasına ve algoritmalar ile tahmin modellerinin geliştirilmesine rağmen, bu tahmin modellerinin makine öğrenmesi ile talaşlı imalat operasyonlarına gerçek zamanlı olarak entegre edilmesi henüz kısıtlıdır. Bu çalışmada, frezeleme operasyonunda kesme parametrelerinin titreşime, yüzey pürüzlülüğüne ve boyutsal doğruluğa olan etkisinin makine öğrenmesi algoritmaları ile "gerçek zamanlı" optimizasyonunu gerçekleştirebilecek özgün bir CNC Router tasarımı ve montajı gerçekleştirilmiştir. Ayrıca, titreşim verilerini toplamak, makineye gerçek zamanlı olarak müdahale edebilmek için bir ara yüz tasarımı yapılmıştır. CNC Routerın eş zamanlı olarak titreşim tabanlı veri alıp göndermesi, kullanıcı müdahalesi olmadan makine öğrenimi destekli dinamik kesme parametresi optimizasyonu ve güncellemesi çalışmanın özgün yönünü oluşturmaktadır. Çalışma, Endüstri 4.0'ın temel bileşenlerini, yani gerçek zamanlı veri toplama, otomatik karar verme, ve kendini uyarlayabilme yeteneklerini bir araya getirmektedir. CNC Router'da yapılan donanımsal değişiklikler ve eklenen haberleşme sistemi, Endüstri 4.0'ın akıllı üretim hedeflerine uygun şekilde, geleneksel CNC Router'lara bir yenilik olarak kazandırılmıştır. Bu özellikler, CNC Router'da daha verimli ve kaliteli üretim yapılmasını sağlamaktadır. Söz konusu yönleriyle makale, CNC Router'lar için ileri seviye makine öğrenimi tabanlı bir optimizasyon sistemi sunarak literatüre özgün bir katkı sunmaktadır.

2. TASARIM VE MONTAJ (DESIGN AND ASSEMBLY)


CNC Router'ın veri toplaması ve titreşim seviyesine göre gerçek zamanlı olarak kesme parametrelerini optimize edebilmesi için Router üzerindeki cihaz ve bağlantılar tekrar düzenlenmiştir.

CNC Routerda üretici firmaya ait makine kontrol kartı bulunmaktadır. Ayrıca fener mili tek devirde dönmektedir. Deneylerin yapılabilmesi için kart, karta ait yazılım ve farklı devirlerde dönebilen fener miline ihtiyaç bulunmaktadır. Bu nedenle fener mili ve kontrol kartı değiştirilmiştir.

Sonraki aşamalarda farklı kesme şartlarında 600 deney yapılacaktır. Deneyler sırasında tezgaha montajı yapılan ivme ölçer ile tırlama verileri alınacak ve kaydedilecektir. Deney numunelerinin yüzey pürüzlülük ölçüm cihazı ile yüzey kalitesi, CMM ile de boyutsal ve geometrik doğrulukları belirlenecektir. Ölçüm sonuçları tırlama verileri ile beraber tahmin modelini oluşturmak üzere kullanılacaktır. Veri seti kesme parametreleri, titreşim, yüzey pürüzlülük ve boyutsal doğruluk verilerinden oluşacaktır. Şekil 1'de sisteme ait şematik diyagram, Şekil 2'de deney düzeneği için yapılan değişiklikler görülmektedir.



Şekil 1. Sistem genel tasarımı (System design)




Şekil 2. Deney düzeneği için yapılan değişiklikler a. Router'a ait önceki fener mili b. Değişken devirli fener mili c. Yeni tasarlanan pano ve değişen ekipmanlar (Changes made for the experimental setup a. Previous spindle of the router b. Variable speed spindle c. Newly designed panel and changed equipment)

Deneylerde titreşim verilerini almak amacı bağlantısı geliştirme kartı ile gerçekleştirilmiştir. kullanılacak 3 eksen ivmeölçerin bilgisayara Geliştirme kartları dijital verilerin toplanması,


hesap kodlarının ve ara kodların işlenmesi vb. ön işlemleri yapmak için kullanılmaktadır. Ayrıca ana bilgisayarın çalışma performansını da arttırmakta, bilgisayar ile sensörün bağlantısını donanımsal olarak kolaylaştırmaktadır. İvmeölçer ve geliştirme kartı arasındaki haberleşme, SPI haberleşme protokolü ile sağlanmaktadır. CNC Router ve geliştirme kartının bilgisayara bağlantısında ise TCP/IP protokolleri kullanılmaktadır. Geliştirme kartındaki veri, kartın USB-Seri dönüştürücüsü aracılığıyla bilgisayara USB bağlantısı üzerinden iletilmektedir. Bilgisayar tarafında uygun bir seri iletişim yazılımı, USB-Seri dönüştürücü aracılığıyla gelen verileri almakta ve geliştirme kartına veri göndermek için gerekli komutları iletmektedir. Bu şekilde, geliştirme kartı üzerindeki sensör verileri bilgisayara USB bağlantısı aracılığıyla aktarılmakta ve uygun yazılım kullanılarak bu veriler gözlemlenmekte ve işlenebilmektedir. Şekil 3'te sistem tasarımı diyagramı gösterilmiştir.

3. VERİ TOPLAMA VE GERÇEK ZAMANLI MÜDAHALE İÇİN ARA YÜZ TASARIMI (INTERFACE DESIGN FOR DATA COLLECTION AND REAL-TIME INTERVENTION)

Makine Öğrenimi deneylerinde kullanılmak üzere gerçek zamanlı müdahale için ara yüz tasarlanmıştır. Tasarım C# Form ortamında gerçekleştirilmiştir. Aynı zamanda veriler bu ara yüz ile kaydedilmekte, X, Y,Z koordinatları, ilerleme, kesme hızı gibi parametreler bu ara yüz yardımıyla kontrol edilmektedir. İlk olarak haberleşme için seri port com 5 seçilir ve baudrate belirlenir. "COM5", bilgisayardaki belirli bir seri portun adını, baudrate bir saniyede iletilen sembol veya sinyal değişikliklerinin sayısını belirtir. 'Başla' operasyonu başlatmak, 'durdur' operasyonu durdurmak, 'programı durdur' operasyonu durdurmadan takımı durdurmak için kullanılır. Tasarlanan ara yüz ile birlikte doğru veri alış verişi sağlanabilmektedir. (Şekil 4)



Şekil 3. Kesme parametrelerini gerçek zamanlı olarak tahmin ve optimize edebilen haberleşme sistemi tasarımı (Communication system design that can estimate and optimize cutting parameters in real time)



Şekil 4. Ara yüz tasarımı (Interface design)

Gerekli modernizasyonu tamamlanmış CNC Router, C# Form uygulamasında yazılmış ara yüz üzerinden kontrol edilebilmekte, konum ve G-kod satır bilgilerini çekebilmektedir. Ara yüz, Mach3

CNC kontrol kartına OEM kodları ile bağlanarak CNC Router'ın kontrolünü sağlamaktadır (Şekil 4). Ara yüz ve kontrol yazılımındaki Veri Toplama Modu, verileri işleyip deneylerden önce manuel olarak veri seti oluşturulmasını sağlar. Ayrıca ara yüz üzerinde “Başla” butonuna basılır basılmaz arka planda ön işleme ve veri oluşturma prosesi otomatik olarak başlatılmaktadır. Tahmin modu ise seçili iken arka planda Python uygulaması açılmakta ve tahmin sonuçlarını belirlenen bir klasöre kaydetmektedir. Elde edilen tahmin sonuçlarına göre operatörden bağımsız olarak parametrelere müdahale edebilmektedir. Arayüz Kontrol yazılımı her 10ms de bir bu klasördeki güncel tarihli sonuçları çekmektedir. Ayna Fener mili devir ve ilerleme hızı parametrelerini bu


tahmine göre değiştirmektedir. Ara yüz yazılımı, fener mili devir sayısı ve ilerleme hızını anlık olarak ara yüz üzerinde göstermekte ve değiştirebilmektedir. Kalibrasyon ve filtre kodları (Şekil 5) geliştirme kartı içine kodlanmış ivme ölçer sensöründen anlık gelen veriler ile Mach3 CNC kontrol kartından gelen kesme hızı ve ilerleme verileri zamana bağlı olarak .CSV formatında bilgisayarda belirlenen bir klasöre kaydedilir. (Şekil 6a ve Şekil 6b). Aynı zamanda değişen kesme parametreleri ile üretilen numunelerin yüzey pürüzlülük ölçüm cihazı ile yüzey kalitesi, CMM ile de boyutsal ve geometrik doğrulukları sınıflandırılarak yazılım tarafından oluşturulan .CSV formatındaki dosyalara eklenmektedir.

```

XYZaccelino
1  #include <Adafruit MPU6050.h>
2  #include <Adafruit_Sensor.h>
3  #include <Wire.h>
4
5  Adafruit MPU6050 mpu;
6  float accelX_offset = 0.4355;
7  float accelY_offset = -0.2765;
8  float accelZ_offset = 0.3735;
9
10 void setup() {
11   Serial.begin(115200);
12
13   if (!mpu.begin()) {
14     Serial.println("MPU6050 sensörü bulunamadı!");
15     while (1);
16   }
17   mpu.setAccelerometerRange(MPU6050_RANGE_16_G);
18   // Kalibrasyon adımı
19 }
20
21 void loop() {
22   sensors_event_t accelEvent, gyroEvent, tempEvent;
23   mpu.getEvent(&accelEvent, &gyroEvent, &tempEvent);
24
25   float accelX_g = ((accelEvent.acceleration.x - accelX_offset) / 9.81);
26   float accelY_g = ((accelEvent.acceleration.y - accelY_offset) / 9.81);
27   float accelZ_g = ((accelEvent.acceleration.z - accelZ_offset) / 9.81);
28
29   // Değerleri filtrele
30   if (accelX_g >= 0.97 && accelX_g <= 1.03) {
31     accelX_g = 1.0;
32   }
33   if (accelY_g >= -0.05 && accelY_g <= 0.05) {
34     accelY_g = 0.0;
35   }
36   if (accelZ_g >= -0.05 && accelZ_g <= 0.05) {
37     accelZ_g = 0.0;
38   }
39 }

```

Şekil 5. İvmeölçer kalibrasyon ve filtreleme kodları (Accelerometer calibration and filtering codes)




Şekil 6a. Ön Proses verileri, b.ön proses ara yüzü (Pre-Process data, b.pre-process interface)

Parça işleme esnasında sekans veriler sayılmakta ve her 1000 veride bir ön işleme tabi tutulmaktadır. Ön

proses verileri, bilgisayar içerisinde istenilen bir klasöre 64x64 piksel görüntü formatı ile sırası ile

kaydedilmektedir. Bu özgün yöntem ile yüksek boyutlu verilerin boyutu küçültülerek anlık veri işlemede hız ihtiyacının karşılanması sağlanmış ve verilerin optimizasyonunda kullanılacak olan CNN-LSTM mimarisi (Şekil 7) içerisinde işlenebilmesi hedeflenmiştir. Kaydedilen 64x64 piksel veri setleri

arka planda tahmin mimari içerisinde işletilmektedir. Alınan titreşim verileri model eğitimi öncesi filtrelenecek ve gürültü azaltılacaktır. Verilerin %70'i eğitim, %15'i doğrulama, %15'i test için kullanılacaktır.



Şekil 7. Tahmin modelinde kullanılan CNN-LSTM yapısı (CNN-LSTM structure used in the prediction model)

İvmeölçer gibi zamana dayalı sinyal verileri üreten sensörlere dayalı tahmin modellerinde genellikle CNN-LSTM, CNN-RNN ve CNN-GRU hibrit mimarileri kullanılmaktadır [38-42]. Modelin girişine 64x64 piksel boyutlarında bir dizi görüntü verilir. Bu görüntüler, belirli bir süreçten veya ardışık görüntülerden oluşabilir. Giriş verileri, modelin daha verimli öğrenmesi için çeşitli ön işleme adımlarından geçebilir. Bu aşama genellikle gürültü azaltma, normalizasyon gibi adımları içermektedir. 2B CNN + ReLU aşamasında, 2 boyutlu bir Convolutional Neural Network (CNN) katmanı kullanılarak görüntülerdeki temel özellikler çıkarılır. CNN katmanı, görüntüdeki kenarlar, dokular ve diğer düşük seviyeli özellikleri öğrenir. ReLU (Rectified Linear Unit) aktivasyon fonksiyonu ise nonlineerlik ekler ve modelin daha karmaşık özellikleri öğrenmesine olanak tanır. Bu fonksiyon, negatif değerlerin sıfırlanmasını sağlar ve modelin daha hızlı öğrenmesini destekler. Bu örnekte 128 filtre kullanılmıştır. CNN katmanından sonra, boyutları küçültmek ve modelin hesaplama yükünü azaltmak için Maksimum Havuzlama uygulanır. Bu katman, her bir özellik haritasının belirli bir bölgesindeki maksimum değeri alır, böylece boyut küçültülürken önemli özellikler korunur. Düzleştirme aşamasında 2D özellik haritalarını tek boyutlu bir dizi haline getirerek LSTM katmanına hazırlık yapılır. Aşırı öğrenmeyi (overfitting) azaltmak için, bazı nöronların rastgele devre dışı bırakılır. LSTM katmanı, ardışık görüntüler arasındaki zamansal ilişkileri öğrenir. LSTM katmanı, uzun süreli bağımlılıkları öğrenebildiği için ardışık görüntülerdeki zamansal

bilgiyi analiz eder ve çıkarır. LSTM katmanından gelen veriler, son katmanlar olan Yoğunluk katmanlarına aktarılır. Bu katmanlar, modelin çıktı sınıflarını veya tahmin edilen değerleri üretmesi için son hesaplamaları yapar. Son olarak, model belirli bir çıktıyı üretmektedir.

CNN-LSTM hibrit mimarisi, görüntüler arasındaki zamansal bilgiyi birlikte analiz ederek daha doğru tahminlerde bulunabilmek için geliştirilmiştir. CNN, görsel özellikleri çıkarırken, LSTM bu özelliklerin ardışıklığındaki zamansal bağımlılıkları öğrenmektedir.

Uzun vadede daha iyi öğrenme, daha az gradyan kaybı, daha esnek bellek yönetimi gibi avantajları nedeni ile LSTM (Long-Short Term Memory) tercih edilmiştir. Donanımsal ve yazılımsal olarak veri toplama ve anlık müdahaleye uygun hale getirilen CNC Router üzerinde farklı kesme parametreleri ile cep boşaltma operasyonu yapılacaktır. Kesme parametrelerinin titreşim, geometrik tolerans ve yüzey pürüzlülüğüne olan etkisi CNN-LSTM hibrit mimarisi ile modellenerek CNC Router'a entegre edilecektir.

4. SONUÇ (CONCLUSION)

Bu çalışmada, kesme parametrelerini titreşim seviyesine ve hedef kaliteye göre optimize eden bir akıllı sistem tasarımı ve montajı yapılmıştır. Bu doğrultuda Stepcraft'a ait bir CNC Router'ın donanımında değişiklikler yapılmış ve kesme parametrelerinin tahmin edilmesi, güncellenmesi için geliştirme kartları ve sensörler eklenmiştir.

CNC Router üzerinde yapılan fener mili ve kontrol kartı değişiklikleri, makinenin farklı devirlerde çalışabilmesini ve kesme hızını optimize edebilmesini sağlamıştır. Ayrıca, 3 eksenli ivmeölçer ve geliştirme kartı eklenerek, CNC Router'ın titreşim verilerini toplama yeteneği artırılmıştır. Bu eklemeler, sistemin titreşim seviyelerini gerçek zamanlı olarak izleyebilmesini ve kesme işlemi sırasında parametrelerin otomatik olarak optimize edilmesini mümkün kılmıştır. TCP/IP protokolü ile kurulan haberleşme altyapısı ise sistemin veri aktarım hızını artırarak gerçek zamanlı işlem kabiliyetini güçlendirmiştir. Ayrıca, C# tabanlı bir arayüz oluşturulmuş, bu arayüz CNC Router'ın gerçek zamanlı kontrolünü sağlamaktadır. Bu ara yüz, CNC Router'ın hem kullanıcıdan bağımsız olarak çalışmasını hem de elde edilen verileri işleyerek kendini optimize edebilmesini sağlamıştır. Arayüz yazılımı, aynı zamanda verileri belirli bir klasöre kaydetmekte, kullanıcıya geçmiş verileri analiz etme ve süreç performansını gözlemlene imkanı tanımaktadır.

Donanımsal ve yazılımsal olarak yapılan bu iyileştirmeler, CNC Router'ın performansını artırarak üretim sürecinin verimliliğini ve ürün kalitesini önemli ölçüde yükseltecektir. Sonraki çalışmalarda, deneyler ve ölçümler gerçekleştirilecektir. Frezeleme operasyonu sonrası elden edilen ürünlerin istenilen kalitede olması ve kalitede sürekliliğinin sağlanması için veriler üzerinden makine öğrenimi algoritmaları kullanılarak bir tahmin modeli geliştirilecektir. Oluşturulan model, CNC Router tezgahına entegre edilecek ve dinamik müdahale sistemi tamamlanacaktır.

TEŞEKKÜR (ACKNOWLEDGMENTS)

Gazi Üniversitesi Bilimsel Araştırma Projeleri Birimi'ne FGA-2023-8959 numaralı projemize verdikleri destekten dolayı teşekkür ederiz. / We would like to thank Gazi University Scientific Research Projects Unit for their support to our FGA-2023-8959 project.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

The author of this article declares that the materials and methods they use in their work do not require ethical committee approval and/or legal-specific permission.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Duygu GÜRKAN: Tasarımı ve montajı yapmış, makinenin yazım işlemini gerçekleştirmiştir.

She designed and assembled and performed the writing process.

Ahmet MAVİ: Tasarım ve montajı yapmış, sonuçlarını analiz etmiştir.

He designed, assembled and analyzed the results

İhsan KORKUT: Sonuçlarını analiz etmiştir.

He analyzed the results.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

There is no conflict of interest in this study.

KAYNAKLAR (REFERENCES)

- [1] A. G. Frank, L. S. Dalenogare, N. F. Ayala, Industry 4.0 technologies: Implementation patterns in manufacturing companies. International Journal of Production Economics, 210 (2019) 15-26.
- [2] X. Zhang, X. Ming, Z. Liu, D. Yin, Z. Chen, Y. Chang A reference framework and overall planning of industrial artificial intelligence (I-AI) for new application scenarios", The International Journal of Advanced Manufacturing Technology, 101(9), (2019) 2367-2389.
- [3] M. Ammar, A. Haleem, M. Javaid, S. Bahl, A. S. Verma, Implementing Industry 4.0 technologies in self-healing materials and digitally managing the quality of manufacturing. Materials Today: Proceedings, 52 (2022) 2285-2294.
- [4] Y. Cui, S. Kara, K. C. Chan, Manufacturing big data ecosystem: A systematic literature review. Robotics and computer-integrated Manufacturing, 62 (2020) 101861.
- [5] S. Yağmur, AISI 1050 çeliğinin tormalanmasında minimum miktarda yağlamanın (MMY) kesme kuvvetleri ve yüzey pürüzlüğü üzerindeki etkisinin araştırılması. Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım Ve Teknoloji, 11(4) (2023) 1024-1034.
- [6] A. Giampieri, J. Ling-Chin, Z. Ma, A. Smallbone, Roskilly, A. P.. A review of the current automotive manufacturing practice from an energy perspective, Applied Energy, 261 (2020) 114074.

- [7] Z. You, H. Gao, L. Guo, Y. Liu, J. Li, C. Li., "Machine vision based adaptive online condition monitoring for milling cutter under spindle rotation", *Mechanical Systems and Signal Processing*, 171 (2022) 108904.
- [8] B. S. Bayram, İ. Korkut, Parmak Frezelerde Kesme Kuvvetlerinin Modellenmesi. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım Ve Teknoloji*, 10(4) (2022) 964-977.
- [9] T. Debroy, W. Zhang, J. Turner, S. S. Babu, Building digital twins of 3D printing machines. *Scripta Materialia*, 135 (2017) 119-124.
- [10] A. Kusiak, Smart manufacturing. *International Journal of Production Research*, 56(1-2) (2018) 508-517.
- [11] J. Wang, Y. Ma, L. Zhang, R. X. Gao, D. Wu, Deep learning for smart manufacturing: Methods and applications. *Journal of manufacturing systems*, 48 (2018), 144-156.
- [12] M. A. Tnani, M. Feil, K. Diepold, Smart Data Collection System for Brownfield CNC Milling Machines: A New Benchmark Dataset for Data-Driven Machine Monitoring. *Procedia CIRP*, 107 (2022) 131-136.
- [13] W. Cai, F. Liu, H. Zhang, P. Liu, J. Tuo, Development of dynamic energy benchmark for mass production in machining systems for energy management and energy-efficiency improvement, *Applied Energy*, 202 (2017) 715-725.
- [14] W. Cai, C. Liu, K. H. Lai, L. Li, J. Cunha, L. Hu, Energy performance certification in mechanical manufacturing industry: A review and analysis, *Energy Conversion and Management*, 186 (2019) 415-432.
- [15] A. Dogan, D. Birant, Machine learning and data mining in manufacturing. *Expert Systems with Applications*, 166 (2021) 114060.
- [16] E. Traini, G. Bruno, G. D'antonio, F. Lombardi, Machine learning framework for predictive maintenance in milling. *IFAC-PapersOnLine*, 52(13) (2019) 177-182.
- [17] A. Aslan, Machine learning models and machinability analysis for comparison of various cooling and lubricating mediums during milling of Hardox 400 steel. *Tribology International*, 198 (2024) 109860.
- [18] R. Teimouri, M. Grabowski. Effect of ultrasonic vibration on fatigue life of Inconel 718 machined by high-speed milling: Physics-enhanced machine learning approach. *Mechanical Systems and Signal Processing*, 224 (2025) 112115.
- [19] H. K. Elminir, M. A. El-Brawany, D. A. Ibrahim, H. M. Elattar, E. A. Ramadan, An efficient deep learning prognostic model for remaining useful life estimation of high speed CNC milling machine cutters. *Results in Engineering*, 24 (2024) 103420.
- [20] V. H. Nguyen, T. T. Le, A. T. Nguyen, X. T. Hoang, N. T. Nguyen, N. K. Nguyen, Optimization of milling conditions for AISI 4140 steel using an integrated machine learning-multi objective optimization-multi criteria decision making framework. *Measurement*, 242 (2025) 115837.
- [21] Y. Li, Y. Zeng, Y. Qing, G. B. Huang, Learning local discriminative representations via extreme learning machine for machine fault diagnosis. *Neurocomputing*, 409 (2020) 275-285.
- [22] Y. Lei, B. Yang, X. Jiang, F. Jia, N. Li, A. K. Nandi, Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mechanical Systems and Signal Processing*, 138 (2020) 106587.
- [23] Y. Yang, M. Huang, Z. Y. Wang, Q. B. Zhu, Robust scheduling based on extreme learning machine for bi-objective flexible job-shop problems with machine breakdowns. *Expert Systems with Applications*, 158 (2020) 113545.
- [24] A. S. Roque, V. W. Krebs, I. C. Figueiro, N. Jazdi, An analysis of machine learning algorithms in rotating machines maintenance. *IFAC-PapersOnLine*, 55(2) (2022) 252-257.
- [25] B. Dietrich, J. Walther, M. Weigold, E. Abele, Machine learning based very short term load forecasting of machine tools", *Applied Energy*, 276 (2020) 115440.
- [26] Y. He, P. Wu, Y. Li, Y. Wang, F. Tao, Y. Wang, A generic energy prediction model of machine tools using deep learning algorithms, *Applied Energy*, 275 (2020) 115402.
- [27] M. Brüllinger, M. Wuwer, M. A. Hadi, F. Haas, Energy prediction for CNC machining with machine learning, *CIRP Journal of Manufacturing Science and Technology*, 35 (2021) 715-723.
- [28] T. Mikołajczyk, K. Nowicki, A. Bustillo, D. Y. Pimenov, Predicting tool life in turning operations using neural networks and image processing, *Mechanical systems and signal processing*, 104 (2018), 503-513.
- [29] T. Mikołajczyk, K. Nowicki, A. Kłodowski, D. Y. Pimenov, 2017 Neural network approach for automatic image analysis of cutting edge wear", *Mechanical Systems and Signal Processing*, 88, 100-110.
- [30] Z. Jurkovic, G. Cukor, M. Brezocnik, T. Brajkovic, A comparison of machine learning methods for cutting parameters prediction in high speed turning process. *Journal of*

- Intelligent Manufacturing, 29(8) (2018) 1683-1693.
- [31] X. Wu, Y. Liu, , Zhou, X., Mou, A. Automatic identification of tool wear based on convolutional neural network in face milling process”, *Sensors*, 19(18) (2019) 3817.
- [32] V. Parwal, B. K. Rout, Machine learning based approach for process supervision to predict tool wear during machining. *Procedia CIRP*, 98 (2021) 133-138.
- [33] Z. Huang, J. Zhu, J. Lei, X. Li, F. Tian, Tool wear predicting based on multi-domain feature fusion by deep convolutional neural network in milling operations. *Journal of Intelligent Manufacturing*, 31(4) (2020) 953-966.
- [34] I. Oleaga, C. Pardo, J. J. Zulaika, A. Bustillo, A machine-learning based solution for chatter prediction in heavy-duty milling machines. *Measurement*, 128 (2018) 34-44.
- [35] M. Kuntoğlu, A. Aslan, D. Y. Pimenov, K. Giasin, T. Mikolajczyk, S. Sharma, “Modeling of cutting parameters and tool geometry for multi-criteria optimization of surface roughness and vibration via response surface methodology in turning of AISI 5140 steel. *Materials*, 13(19) (2020) 4242.
- [36] I. Ragai, A. S. Abdalla, H. Abdeltawab, F. Qian, J. Ma, Toward smart manufacturing: Analysis and classification of cutting parameters and energy consumption patterns in turning processes. *Journal of Manufacturing Systems*, 2022
- [37] H. Guo, Y. Zhang, K. Zhu, Interpretable deep learning approach for tool wear monitoring in high-speed milling. *Computers in Industry*, 138 (2022) 103638.
- [38] E. Kim, T. Bui, J. Yuan, S. C. Mouli, B. Ribeiro, R. A. Yeh, M. B. Jun, Online real-time machining chatter sound detection using convolutional neural network by adopting expert knowledge. *Manufacturing Letters*, 41 (2024) 1386-1397
- [39] J. Xie, P. Hu, J.Chen, W. Han, R. Wang, Deep learning-based instantaneous cutting force modeling of three-axis CNC milling. *International Journal of Mechanical Sciences*, 246 (2023) 108153.
- [40] Z. Weiguo, Z. Jichao, G. Baosu, T. Weixiang, W. Fenghe, An optimized convolutional neural network for chatter detection in the milling of thin-walled parts, *Int. J. Adv. Manuf. Technol.* 106 (9) (2020) 3881–3895.
- [41] W. Zhang, F. Teng, J. Li, Z. Zhang, L. Niu, D. Zhang, Z. Zhang, Denoising method based on CNN-LSTM and CEEMD for LDV signals from accelerometer shock testing. *Measurement*, 216 (2023) 112951.
- [42] J. Duan, X. Zhang, T. Shi, A hybrid attention-based paralleled deep learning model for tool wear prediction. *Expert Systems with Applications*, 211 (2023), 118548.