

ULUSLARARASI 3B YAZICI TEKNOLOJİLERİ
VE DİJİTAL ENDÜSTRİ DERGİSİ

INTERNATIONAL JOURNAL OF 3D PRINTING
TECHNOLOGIES AND DIGITAL INDUSTRY

ISSN:2602-3350 (Online)

URL: <https://dergipark.org.tr/ij3dptdi>

CNC TEZGAHLARININ DİJİTAL İKİZ MODELİ İLE KOMUT TAMAMLANMA SÜRELERİNİN TAHMİN EDİLMESİ

EXPERIMENTAL INVESTIGATION OF THE THERMAL
PERFORMANCE IN THERMOELECTRIC GENERATORS

Yazarlar (Authors): Elif Cesur^{id*}, Muhammet Raşit Cesur^{id}, Beyza Nur Aydoğan^{id}

Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article): Cesur E., Cesur M. R., Aydoğan B. N., "CNC Tezgahlarının Dijital İkiz Modeli ile Komut Tamamlanma Sürelerinin Tahmin Edilmesi" *Int. J. of 3D Printing Tech. Dig. Ind.*, 7(2): 303-321, (2023).

DOI: 10.46519/ij3dptdi.1215353

Araştırma Makale/ Research Article

Erişim Linki: (To link to this article): <https://dergipark.org.tr/en/pub/ij3dptdi/archive>

CNC TEZGAHLARININ DİJİTAL İKİZ MODELİ İLE KOMUT TAMAMLANMA SÜRELERİNİN TAHMİN EDİLMESİ

Elif Cesur^a , Muhammet Raşit Cesur^a , Beyza Nur Aydoğan^b 

^aİstanbul Medeniyet Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Endüstri Mühendisliği Bölümü, TÜRKİYE

^bYıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Veri Bilimi ve Büyük Veri Programı, TÜRKİYE

* Sorumlu Yazar: elif.karakaya@medeniyet.com

(Received: 06.12.22; Revised: 07.07.23; Accepted: 18.08.23)

ÖZ

Endüstride dijital dönüşümün başlamasıyla fiziksel sistemlerin dijital ortamda modellenerek üretim verimliliğinin artması için çok sayıda çalışma yapılmıştır. Bu çalışmalar mevcut yöntemlere kıyasla daha karmaşık sorunları çözmek, maliyet ve kalite açısından daha etkin üretim yapmak amacıyla gerçekleştirilmektedir. Dijitalleşme çalışmalarında yapay zekâ ve makine öğreniminin endüstriyel operasyonlara dahil edilmesi oldukça önemli bir adım olmuştur. IoT ile entegre yapay zekâ ve makine öğrenimi, veri toplama, işleme ve bilgi çıkarımın tek bir yerde yapılmasına izin verdiği için büyük bir potansiyele sahip olduğu görülmüştür. Bu teknolojilerin kullanıldığı alanlardan biri ise Dijital İkiz (Dİ) uygulamalarıdır. Dİ ile, gerçek dünyanın sanal ortamda birebir modeli oluşturularak sistemlerin gerçek zamanlı kontrolü sağlanmaktadır. Endüstriyel kontrolde Dİ teknolojisinin uygulanabileceği en etkin bileşenler ise 3 boyutlu yazıcılar, robotlar ve CNC tezgâhlarıdır. Bu çalışmada, öncelikle üretim sistemlerinin Dİ modelinin geliştirilmesi hedeflenmiştir. Çalışmanın ikinci aşamasında ise geliştirilen Dİ modeli ile esnek imalat sistemi tezgâhlarında doğrusal hareket komutlarının tamamlanma süresi tahmin edilmiştir. Tahmin aşamasında birden çok makine öğrenmesi algoritmaları kullanılmış ve performansları karşılaştırılmıştır. 0.995745 R² ve 0.991615 doğruluk değerleri ile Yapay sinir ağı modeli en iyi yöntem olduğu görülmektedir.

Anahtar Kelimeler: Dijital İkiz, Zeki İmalat Sistemleri, CNC tezgâhları.

THE DIGITAL TWIN MODEL OF CNC MACHINES TO ESTIMATE OPERATION COMPLETION TIMES

ABSTRACT

As digital transformation takes hold in the industry, studies are exploring how modeling physical systems in digital environments can boost production efficiency. The objective is to tackle more complex issues than traditional methods and achieve more cost-effective and higher-quality production. The integration of artificial intelligence and machine learning into industrial processes is a very important step in digitalization studies. Integrating artificial intelligence and machine learning using the Internet of Things (IoT) has shown great potential, as data collection, processing, and extraction can be done through a single platform. One of the areas where these technologies are being used is in the Digital Twin (DT) applications. Digital transformation enables real-time control of systems by creating a virtual environment that mirrors the real world. The most effective targets for applying DT technology in industrial control are 3D printers, robots, and CNC benches. In this study, the main objective is to develop a DT model for manufacturing systems. In the second phase of the study, the execution time of linear motion commands on machines of flexible

manufacturing systems was estimated using the developed DT model. In the estimation phase, different machine learning algorithms were used and their performances were compared.

Keywords: Digital Twin, İntelligent Manufacturing Systems, CNC Workbench.

1. GİRİŞ

Dijital dönüşüm endüstride otonom teknolojilerin geliştirilmesini ve veri odaklı planlamaya yönelik çok sayıda çalışma yapılmasını sağlamıştır [1-5]. Özellikle bilgi ve iletişim teknolojilerinin yaygınlaşması ve gelişimi otomasyonda yapay zekâ ve makine öğrenimi kullanımını yaygınlaştırmış ve daha karmaşık kontrol sistemlerinin gelişimine olanak sağlamıştır. Zeki kontrol sistemlerinin endüstriyel operasyonlara dahil edilmesi de oldukça önemlidir. Bu alanların endüstride kullanımının artmasıyla birlikte sağladıkları faydalar rekabeti daha da artırmaktadır. İşletmeler rekabette yer edinebilmek için yapay zekaya odaklanacağından, yapay zekâ ve makine öğrenimi ile en az ilgilenen işlerin sektörden ilk ayrılan işler olacağı düşünülmektedir [6]. Yapay zekanın gelişimi nesnelerin interneti (IoT) teknolojisi ile desteklendiğinde çevrelerinin farkına varan nesnelerin üretimi mümkün hale gelmektedir [7]. Özellikle günümüzde internete insanlardan daha fazla cihaz bağlı [8] olduğu düşünüldüğünde dijital dönüşümün çok hızlı gerçekleştiği anlaşılmaktadır.

Dijital dönüşümün ana bileşenlerinden biri olan Dİ teknolojisi, fiziksel bir varlığın sanal ortamda tüm davranışlarının modellenmesi ve fiziksel varlığın kontrolünde kullanılmasını kapsamaktadır [9]. Dİ, gelişmiş sensör teknolojileriyle bir maddenin, sürecin veya bir öğenin gerçek zamanlı izlenimini yapabilir. Bununla birlikte görsel olarak da modellenmesi sağlanır. Eksiksiz olarak geliştirilen ve gerçekleştirilen bir Dİ modeli ile, sistemlerin güvenliği artırabilmektedir [10]. Aynı zamanda üretim maliyetlerini azaltırken sürecin yönetimine de katkıda bulunabilmektedir. Dİ'in ilerleyen zamanlarda geleneksel üretim süreçlerinin değişiminde yadsınamaz bir rolü olacağı düşünülmektedir. Dijital dönüşümün hızı ve dijital alt yapıdaki gelişim düşünüldüğünde Dİ teknolojisindeki gelişimin

bu dönüşümün tamamlanmasına katkı sağlayacağı yadsınamaz bir gerçektir.

Firmaların üretim maliyetlerini düşürme, ürünlerini daha kısa sürede üretme, taleplere daha çabuk karşılık verme, aynı zamanda bunları gerçekleştirirken üretimde yaşanan aksamaları kaldırma isteği güncel bir konu olarak tartışılmaktadır. Endüstri 4.0'la bu ihtiyaçlara çözüm olarak gerçek zamanlı karar verebilme yetisine sahip nesnelerin arayışı ön plana çıkmıştır. Bu doğrultuda akıllı üretim, simülasyon modelleri, tahminlere odaklı yazılımlar, gerçek zamanlı izleme ile verimliliğin ve esnekliğin artırılması amaçlanmıştır [11-12]. Endüstrinin günümüz ihtiyaçları ve amaçları doğrultusunda Dİ yeni bir trend olarak baş göstermiştir. Literatürdeki çalışmalar dikkate alındığında, özellikle son beş yılda gelişme süreci oldukça hızlanmıştır. Bu süreçte akıllı üretim sistemlerin hassas simülasyon, kendini algılama, kendinden ayarlama, kendini tahmin etme, öz değerlendirme şeklinde nitelikler kazandığı ifade edilebilir [13].

Makine Öğrenimi (ML), endüstride en yaygın kullanılan uygulamalardan biridir. ML, verilerden öğrenebilen ve tahminler yapabilen yapay zekanın (AI) bir alt kümesidir ve algoritmalara odaklanır. Destek Vektör Makinesi, Rastgele Orman, Naive Bayes, KNN ve Lojistik Regresyon gibi algoritmalar makine öğrenimi algoritmalarıdır. Makine öğrenme algoritmaları Dİ oluşturmak için de ayrıca kullanılan araçlardan biridir. Dİ çalışmalarında veri karakteristiklerine göre algoritmalar kullanılır ve arka planda çeşitli parametrelerle ML algoritmalarını deneyerek en iyi modeli ve en iyi parametreyi çıktı olarak döndürür.

Bu çalışmada üretim sistemlerinin Dİ modelinin geliştirilmesi hedeflenmektedir. Esnek imalat sistemini oluşturan tezgahlarda (CNC, 3B yazıcılar, robotlar) doğrusal hareket komutlarının yürütme süresini tahmin eden bir

Dİ modeli geliştirilir. Dİ modeli, önerilen aşamalar ile herhangi bir CNC tezgahı simüle etmeyi amaçlar. İlk aşama veri toplama aşamasıdır. İkinci aşama, yapay zekâ modelini eğitmek için veri ön işleme adımlarının gerçekleştirilmesidir. Çalışmanın bir sonraki aşamasında ise makine öğrenmesi algoritmaları ile modellenmek istenen komutların tamamlanma sürelerinin tahmini yapılacaktır.

Bölüm 2 Dİ ve kullanım alanlarına yönelik literatür taramasını, Bölüm 3 bu alana yönelik teorik arka planı sunmaktadır. Bölüm 4 yöntemler hakkında bilgi sağlamaktadır. Bölüm 5 konunun uygulama kısmını içermektedir. Burada örnek veri üzerinden yapılan vaka çalışmaları ve analizler bulunmaktadır.

2. DİJİTAL İKİZ KAVRAMI VE GELİŞİMİ

Dİ teknolojisi son zamanlarda yüksek ilgi görmüştür. Dünyanın en yetkili bilişim ve teknoloji araştırma ve danışmanlık firması Gartner, 2016'dan bu yana ilk on stratejik teknoloji trendinden biri olarak Dİ'yi seçmiştir. Dünyanın en büyük silah üreticisi Lockheed Martin, Dİ dünyadaki en iyi altı teknolojidenden ilki olarak sıralamıştır. 2017'de savunma ve havacılık endüstrisi, Çin Bilim ve Akıllı Üretim Derneği akademik konsorsiyumu, Dİ akıllı üretim montajını 2017'de akıllı üretimdeki ilk 10 bilimsel ve teknolojik ilerlemeden biri olarak seçmiştir. NASA'nın Apollo uzay programı, 'ikiz' konseptini kullanan ilk programdır. Program, dünyadaki uzay aracının uzaydaki diğerinin koşullarını yansıtabilmesi, simüle edebilmesi ve tahmin edebilmesi için iki özdeş uzay aracı inşa etmiştir. Dünyada kalan araç, uzayda görev yapan aracın ikizidir [14]. Dİ terminolojisinin ilk kullanımı kentsel yol ağlarının tasarımında yinelemeli değişiklikler için Dİ kullanımı ile ortaya çıkmıştır. Bununla birlikte, terminolojinin ilk olarak 2003 yılında Michigan Üniversitesi'nde Michael Grieves tarafından "fiziksel bir ürüne dijital eşdeğer" olarak tanıtıldığı yaygın olarak kabul edilmektedir [15]. "Ürün avatarı" kavramı 2006 yılında tanıtılmıştır [16], Dİ'e benzer bir kavramdır. Ürün avatar konsepti, ürün merkezli perspektiften iki yönlü bir bilgi akışını destekleyen bilgi yönetimi mimarisini

oluşturmayı amaçlamıştır. Ürün avatarıyla ilgili araştırmalar 2015'ten önce bulunabilir [17-19]. Ancak o zamandan beri ürün avatar konseptinin yerini Dİ'in aldığı görülmektedir. Dİ'in ilk ayrıntılı tanımı NASA tarafından verilmiştir [20]. Dr. Grieves kavramı sunduğundan ve NASA ilk spesifik tanımı verdiğinden beri, Dİ ile ilgili çok sayıda literatür yayınlanmıştır.

2.1. Dİ Uygulama Alanları

Montaj görevlerini gerçekleştirmek üzere robotla veya insan gücü ile koordine edilebilen esnek bir üretim hücresinin Dİ'ni oluşturmak ve nesne yönelimli bir simülasyon oluşturmak arasındaki farklılıklar tartışılmaktadır. Dİ, bir üretim sisteminin tasarım aşamasında geliştirilen sanal simülasyon modellerinin kullanımını gerçek zamanlı kontrol operasyonlarına, insan ve robot arasında dinamik beceriye dayalı görev dağılımına, görevlerin sıralanmasına ve buna göre robot programı geliştirmeye kadar genişletir. Metodoloji, esnek insan-robot çalışma ekiplerine giden yolda insan-robot iş birliğinde yalın manuel montaj yöntemlerini birleştirir. Bilberg vd. arkadaşlarının [21] kullandığı, insan-robot iş birliğinin 3 boyutlu sanal simülasyon modelidir. Tecnomatix Process Simulate yazılımı seçilir ve deney sırasında simülasyon aracı olarak kullanılır. Sonuçlar, yaklaşımın montaj esnekliğini korurken otomasyon kavramını desteklediğini göstermektedir.

Meng vd. arkadaşları [22], Robotik montaj sistemi için sanal simülasyon modeli, davranış modeli ve bilgi modelini içeren dijital bir ikiz modeli sunar. Dİ modele dayalı olarak, endüstriyel robotun bileşeni ilk konumundan hedef konuma hareket ettirmesi için çarpışmasız bir yol oluşturmak üzere olasılıksal yol haritası yöntem (PRM) planlayıcısı gerçekleştirir. Planlanan yol, robot çevrimdışı programcısı tarafından hareket dizilerine çevirir. Deney sonuçları, önerilen yöntemin hızlı bir şekilde çarpışmasız bir montaj yolu planlayabildiğini ve ardından endüstriyel robotu otomatik, güvenli ve verimli bir şekilde büyük ölçekli bileşenlerin kurulumunu tamamlamak için kontrol edebildiğini gösterir. Liu vd. arkadaşları [23], otomatikleştirilmiş akış

atölyesi üretim sisteminin hızlı bireyselleştirilmiş tasarımı için Dİ güdümlü bir metodoloji sunar. Dİ'in sistem davranışını tanımlamada ve optimize etmede nasıl uygulanacağını tartışır. Konfigürasyondaki tasarım değişkenlerinin analizinin yanı sıra süreç kısıtlamalarını ve karmaşık bağlantı ilişkilerini karşılamak için gereken dinamik yürütme mekanizması aracılığıyla, bu makale 'statik konfigürasyon ve dinamik yürütme arasında yinelemeli tasarım optimizasyonu' fikrini önermektedir. Amaç, konfigürasyon maliyeti minimizasyonu ve sistem performans maksimizasyonu arasında ortak bir optimizasyon olarak tanımlanır. Botkina vd. arkadaşları [24], bir kesici takımın Di'ni anlatır. Kesici takım verileri gösterimi ve değişimi ISO 13399 ve hat bilgi sistemi mimarisi LISA için uluslararası standardı temel alır. Standartlaştırılmış verileri otomatik olarak toplayan ve dijital modelin sürekli ayarlanmasını sağlayan bir bilgi modeli geliştirilir. Ayarlama, bir tweet makinesi aracılığıyla yapılır. Ayarlanan model, kesici takımın özelliklerini doğru bir şekilde temsil eder ve hassas süreç simülasyonu, kontrolü ve analizine uygulanabilir ve nihayetinde üretim sürecinin sürekli iyileştirilmesine yol açar. Üretim atölyesinde Dİ uygulaması uygulandığında, atölyedeki makine ve ürünlerin durumu gerçek zamanlı olarak sanal modele yansıtılmakta ve bu sayede ürünün imalatı daha akıllı hale getirilmektedir.

2.2. CNC, 3D Yazıcılar ve Dİ

Şu anda, CNC takım tezgâhları üzerine yapılan araştırmalar, esas olarak arıza tespiti, hata kompanzasyonu, parametre optimizasyonu vb. üzerine odaklanmaktadır ve bunlar, arıza tespit verimliliğini ve CNC takım tezgâhlarının işleme hassasiyetini büyük ölçüde geliştirmektedir. CNC takım tezgâhları üzerine yapılan araştırma, ürünlerin, akıllı takım tezgâhlarının ve yeşil imalatın çevrimiçi gerçek zamanlı izlenmesini de genişletilecektir. Birçok araştırmacı, CNC takım tezgâhları üzerinde akıllı imalatla ilgili araştırmalar yapmıştır.

Bozdemir [25], yapay zekâ destekli bir kavramsal tasarım modelini takım tezgâhlarına uygulamıştır. Bu model için bir yapay zekâ

programı uygulaması geliştirmiştir. Bu program kullanarak sistematik tasarımın şartname ve kavramsal tasarım aşamaları arasında hızlı bir bilgi akışı sağlanmaktadır. Bu sayede tasarım işlem süresinin kısalması ve tezgâhın tasarım maliyetlerinde bir düşüş sağlanacaktır.

Sevli [26] , 3D yazıcılara ait çeşitli ayar parametreleri ve üretilecek ürünün niteliklerini ifade eden bir veri seti üzerinde çalışmıştır. Bu verilerle basım için kullanılacak malzemenin tahminlemesine yönelik makine öğrenmesi temelli sınıflandırmalar gerçekleştirmiştir. Bu çalışmayla 3D imalat sektöründe isabetli öngörülerde bulunmak, üretim sürecini daha etkin hale getirip ideal maliyetlerle kaliteli ürünler oluşturma konusunda yol gösterici sonuçlar ortaya koymak amaçlanmaktadır.

Altunkaynak vd. arkadaşları [27], 5 eksen 3D yazıcının tasarımı ve prototip üretimini gerçekleştirmiştir. Prototip üretilen 3D yazıcıda geleneksel Kartezyen tip hareket eksenleri (X, Y ve Z) ile yazıcı tablasının dönüş hareketini sağlayan (A ve C) eksenler eklenerek 5 eksenli 3D yazıcı elde edilmiştir. Geleneksel 3D yazıcı ile kıyaslandığında, destek malzemesinin 5 eksen 3D yazıcıda kullanılmamasından dolayı zamandan tasarruf ve daha az hasarlı bölgelere sahip bir ürün elde edilmiştir.

Wanga vd. arkadaşları [28], birleştirilmiş çok gövdeli besleme tahrik sistemlerinin aslına uygun dinamik modellerini oluşturmak için yeni bir yaklaşımı tanıtır. Yaklaşım oldukça geneldir ve seri kinematikli geniş birtakım tezgâhlara ve robotlar sınıfına uygulanabilir. Model tahmini, doğrusal olmayan ve doğrusal dinamiklerin önerilen ayrıştırması nedeniyle oldukça verimlidir. Yeni yaklaşım, kısa proses içi CNC veri paketleri aracılığıyla 5 eksenli lazer delme makinesi için Dİ tahmininde gösterilmiştir. Liu vd. arkadaşları [29], CNC takım tezgâhının hareket eksenini için zamanla değişen hata tahminini incelemiş ve fiziksel varlık için değişen trendi tahmin etmede Dİ'i uygulamıştır. Isı transfer teorisi ve görsel modele dayalı zamanla değişen bir hata modeli içeren hareket ekseninin Dİ'i, zamanla değişen hatayı tahmin etmek ve telafi etmek için kullanıma hazır bir yazılım olarak

oluşturulmuştur. Bir iş parçası için delik aralığı zamanla değişen hatanın tahmin deneyi gerçekleştirilmiştir. Deneysel sonuçlar, Dİ'e dayalı zamanla değişen hata tahmini ve telafi yönteminin etkili ve uygulanabilir bir şema olduğunu göstermektedir. Dİ'e dayalı hareket ekseninin termal deformasyonu için 3 boyutlu gerçek zamanlı Dİ ilk kez oluşturulmuştur.

Kabaldin vd. arkadaşları [30], CNC makinelerinde ark kaynağı ile 3D baskı için bir sistem geliştirmiştir. Yüksek hızlı hesaplama ve sinir ağlarının eğitimi (geri bildirim ile) için modüller, kaynak işlemini optimize etmek ve ürün kalitesini iyileştirmek için bu 3D baskı sistemine bağlanabilir. Dİ, CNC makineleri için kontrol programları ve ekipman hazırlamada CAM sistemlerinin yeteneklerini genişletir. Paripooranan vd. arkadaşları [31], bir kullanıcının iki yönlü bilgi alışverişini destekleyen etkileşimli bir arayüz oluşturmasını sağlayarak veri görselleştirmesini ve kontrolünü geliştirmeye yardımcı olan 3D baskı için artırılmış gerçeklik özellikli Dİ'in bir uygulamasını önermiştir. Bu uygulama metodolojisi, fiziksel nesnenin 3-D CAD modeline ve 3-D CAD modelini artıran bir arayüze sahip olarak, çoklu kullanım durumlarına genişletilebilir. Özel olarak oluşturulmuş bir uygulama, kullanıcının özellikleri görüntülemesine ve fiziksel nesneyi kontrol etmesine olanak tanır.

Luo vd. arkadaşları [13], Dİ tarafından yönlendirilen CNC takım tezgâhı (CNCMT) için hibrit bir kestirimci bakım yöntemi önermiştir. Bu yöntem, Dİ modeline dayalı parçacık filtreleme algoritması ile kaynaştırılır ve Dİ verileriyle çalıştırılır. Bu yöntem ile Dİ modeli çoklu alan üzerine kurulur ve gerçek çalışma koşullarını yansıtır. Dİ verileri farklı tipte sensörler tarafından toplanır ve veriye dayalı Kalan Faydalı Ömür (RUL) tahmin modeli için kullanılır. Daha sonra sistem gözlem değeri ile teorik üretim değeri parçacık filtreleme algoritması ile birleştirilir. Bu yöntem, Dİ modelinin ve verilerin daha iyi entegre edilmesini ve uygulanmasını sağlar. Bu sayede tek stratejili yöntemle göre daha doğru bir sonuç verebilir. Önerilen yaklaşımın geçerliliği ve doğruluğu, CNCMT kesici takım

ömrü tahmininin bir vaka çalışması ile doğrulanmıştır. Zhang vd. arkadaşları [32], CNC makinelerinin güvenli çalışmasını sağlamak için, kademeli arızaya dayalı bir arıza teşhis stratejisi önermiştir. Arıza mekanizması analizine göre, takım tezgâhı sistemlerindeki bileşenler arasında arıza yayılımının yönlendirilmiş bir grafik modeli kurulur. Bu çalışmada, fay yayılma modelinin hiyerarşik yapısını matris dönüşümü ve ayrıştırma yoluyla gerçekleştirmek için yorumlayıcı yapısal model yöntemi kullanılmıştır. Ardından, takım tezgâhı sistem bileşenlerinin arıza etkilerini değerlendirmek için PageRank algoritması tanıtılır. Johnson yöntemi daha sonra bileşen arıza sırasını düzeltmek ve zaman korelasyonuna dayalı arızaların meydana gelme oranı modelini oluşturmak için uygulanır. Sonunda, yöntemin geçerliliğini doğrulamak için bir uygulama örneği olarak bir takım tezgâhı ekipmanı kullanılır. Bu yöntem, bakım süresinin azaltılmasında, sistemin güvenilirliğinin artırılmasında ve takım tezgâhı sisteminin güvenli çalışmasının sağlanmasında önem arz etmektedir.

Villalonga vd. arkadaşları [33], CNC takım tezgâhları için koşul tabanlı izleme mimarisinin genel tasarımını ve uygulamasını tanıtır. Öneri, CNC takım tezgâhlarındaki alarmları ve olayları yönetmek için çok sayıda yerel gömülü işleme modülü için bilgi toplamak üzere bir hizmet olarak buluta dayalı küresel bir modül çözümünü entegre ediyor. Çözüm, bileşenleri, öğeleri ve grup davranışlarını izlemek ve takım tezgâhı yaşam döngüsü boyunca arıza modellerini tahmin etmek için sinyal işleme, modelleme, optimizasyon ve karar verme tekniklerini birleştirir. Son olarak, her durumda kullanıcı, diğerlerinin yanı sıra geçmiş verilere, gerçek makine göstergelerine, bileşen durumuna erişim, duruma dayalı izleme sistemi üzerinde tam kontrol elde etmek için yerel modülde uygulanan yerel işlemlere erişebilecektir. Ayrıca, bir grup mesaj, uyarı ve alarm, kullanıcıya, tüm makine durumu tabanlı izleme sistemi için basit bir tahmin eyleminden bulut sistemi tarafından sağlanan yeni bir kararlı güncellemeye kadar her durumda dikkate alınması gereken prosedürü sağlar. Luo vd. arkadaşları [34], CNC takım tezgâhı

(CNCMT) için bir modelleme yöntemi ve Dİ kullanım stratejisi önermiştir. CNC takım tezgâhı çağında Dİ konseptinin bir gösterimi sunulmaktadır. İlk olarak, CNCMT için bir Dİ modelleme ve uygulama çerçevesi önerilir. İkinci olarak, birleşik modelleme dili ve haritalama stratejisini kullanan çok alanlı bir modelleme yöntemi sunulmaktadır. Üçüncüsü, Dİ'in kullanım stratejisi, arıza teşhisi ve tahmini incelenmiştir. Önerinin doğrulanması için yukarıdaki yöntem ve stratejiye dayalı bir vaka çalışması araştırılmıştır.

3. LİTERATÜR TARAMASI

Son yıllarda, Dİ üzerine yapılan bilimsel tartışma büyük ilgi görmektedir. Liu ve diğerleri (2021) Dİ konusunda büyük bir artış olduğunu, bu durumun Google'da 90.200'den fazla aramaya ve Google Scholar, WOS ve Scopus'ta 3000'den fazla akademik arama sonucuna yol açtığını göstermiştir. 2017 yılından önce yayın sayısı oldukça düşüktü. 2018'den sonra akademik dünyada hızlı bir ilerleme kaydedilmeye başlandı. Makalelerin yanı sıra, Dİ üzerine sekiz derleme yayın da yayımlanmıştır [35-39].

Dİ kavramının karmaşıklığından dolayı, literatürde çeşitli tanımlar bulunmaktadır [40-43]. Bu akademik ilerlemelere rağmen, erken çalışmalar neredeyse sadece kavramı tanımlamaya, çerçeve ve paradigmaları oluşturmaya ve endüstride entegrasyon seviyelerini belirlemeye odaklanmıştır. Semeraro ve diğerleri (2021) çalışmayı içeriklerine göre beş gruba ayırarak bu çalışmalarını sınıflandırmıştır:

- 1) Uygulama- Bir Dİ ne zaman kullanılmalıdır? [40, 45-46]
- 2) Yaşam döngüsü- Bir Dİ ne zaman oluşturulmalıdır? [47],
- 3) Fonksiyonlar- Bir Dİ'in faydaları nelerdir? [48-49]
- 4) Mimarlık- Bir Dİ nasıl oluşturulur? [49-50],
- 5) Bileşenler/Teknolojiler- Bir Dİ nasıl uygulanır? [36,51].

Dİ ile ilgili makaleler araştırma odaklarına göre düzenlendiğinde, havacılık [38], [52] otomotiv [53-55], enerji [56-57] imalat [36,51,58,59] ve

sağlık [60-61] gibi başlıklarla karşılaşılmaktadır.

Dİ'in geliştirilmesi ve uygulanmasında, bazı kritik teknolojiler ve aynı zamanda bu teknolojilerin entegrasyonu gereklidir. Bu teknolojiler altı kategoride toplanabilir:

- 1) Simülasyon yöntemleri: Simülasyon modeli, bir Dİ'in oluşturulması ve çalıştırılması için temel teknolojidir, ancak Dİ yaklaşımı ile geleneksel simülasyon yaklaşımları arasındaki temel fark, gerçek zamanlı sanal-fiziksel entegrasyondur [38 ,62-63].
- 2) Fiziksel sistem modelleme [64-65].
- 3) Endüstriyel Nesnelerin İnterneti (IIoT): IIoT, dinamik ve sanal fiziksel bir sistem oluşturmak için birçok farklı sensörden oluşan bir verici olup, gerçek bir fiziksel ve sanal model oluşturmak için veri akışlarını Dİ'e sağlar [66-68].
- 4) Büyük Veri analitiği: Veri akışlarının artan kullanılabilirliği ve geçmiş verilerin genişlemesiyle birlikte, veri analitiği giderek daha önemli hale gelmektedir [69-70].
- 5) Yapay Zeka (YZ): Yapay zeka algoritmalarının Dİ modelleriyle entegrasyonu, Dİ'in uygulama alanını genişletmesi beklenmektedir. Derin öğrenme, yapay zeka alanındaki en heyecan verici gelişmelerden biridir [53,71-73].
- 6) Görselleştirme teknikleri: Son araştırmalar, tasarım verimliliğini artırmak için Dİ sistemini sanal gerçeklik (VR), artırılmış gerçeklik (AR) veya karma gerçeklik (MR) teknolojilerini kullanarak geliştirmeye odaklanmıştır [74-75].

Hareket süresi tahminleri üzerine yapılan çalışmalara bakıldığında, interpolasyon yaklaşımı kullanılarak tahminlerin yapıldığı görülmektedir [76-77]. Bu çalışma, tahmin değerlerini hesaplamasında makine öğrenmesi algoritmalarını kullanarak önceki çalışmalardan farklılık göstermektedir. Öte yandan, hareket hızı ile zaman arasındaki ilişkinin tahmini için farklı yapay sinir ağı teknikleri oluşturulmuş olsalar da, genellikle tek bir gizli katmana sahip mimariler kullanılmıştır [78-79]. Çalışmamızın

temel katkısı, komut tamamlama süresinin tahmininde birçok makine öğrenmesi algoritması kullanılmış ve performanslarının karşılaştırılmış olmasıdır. Öte yandan Dİ'i araştıran bilim insanlarının ve uygulayıcıların sayısı zamanla büyük ölçüde artmasına rağmen ve Dİ üzerine birçok makale imalat ortamından örnekler sunmasına rağmen [80-81], üretim planlama yeteneğini açısından Dİ'in nasıl kullanılabileceğini anlamak adına yeterli sayıda çalışma henüz yoktur. Kapsamlı bir literatür taramasından sonra, bu çalışmada önerilen model, işleme süresi tahmini ile planlama süreci için de ayrıca veriler sağlamayı hedeflemektedir.

4. TEORİK ARKAPLAN

Dİ, canlı veya cansız bir fiziksel varlığın dijital kopyasıdır. Fiziksel ve sanal dünyaları [82] birbirine bağlamaktadır. Bu alanlar arasında sorunsuz bir veri aktarımı sağlar. Bu sayede sanal varlıkların fiziksel varlıklarla aynı anda bulunmasına izin verir. Dİ teknolojisi, ürün yaşam döngüsünün farklı mertebelerinde yer almakta ve her mertebede birbirinden farklı unsurlar tanıtılmaktadır. Bu sebeple Dİ'in ayrı performans biçimleri vardır. Dİ uygulamasını üç farklı açıdan tanımlamak mümkündür. Bunlar 1) ürün tasarımı, 2) imalat ve 3) ürün servisidir.

Ürün tasarımındaki Dİ uygulamasına dijital tasarım ve dijital simülasyon da dahildir. Dijital tasarım, modelleme araçları, fiziksel parametrelerini görsel olarak ifade etmek için ürünlerin sanal modellerini oluşturmakta kullanılır. Dİ güdümlü ürün tasarım yöntemi, araştırmacıların ürünleri tasarlarken tasarım kusurlarını hızla bulmasını ve tasarım verimliliğini artırmasını sağlar.

Dijital simülasyonda uyum kabiliyeti, ürün performansını doğrulamak için bir dizi simülasyon deneyi yoluyla tasarım aşamasında doğrulanabilir. Yerleşik esnek Dİ'i kullanmak, tasarımcıların farklı tasarımları hızla değerlendirmesine ve tasarım kusurlarını bulmasına yardımcı olur.

Üretimdeki Dİ uygulaması, kesin üretim kontrolü elde etmek için ürün işleme ve montaja

uygulanan katı bir model oluşturmak için Dİ'i sanal simülasyon modeline dayanır. Bu konu, üretim süreci simülasyonunu, dijital üretim hattını ve ekipman durumu izlemeyi içerir.

Üretim süreci simülasyonu, ürün üretiminden önce, üretim sürecini sanal üretim aracılığıyla simüle edilebilir. Üretkenlik ve verimlilik kapsamlı bir şekilde analiz edilebilir.

Dijital üretim hattı, üretim aşamasının tüm unsurları, otomatikleştirilmiş bir üretim süreci elde etmek için dijital yöntemlerle yakından koordine edilmiş bir üretim sürecine entegre edilmiştir. Ekipman durum izleme, üretim ekipmanının gerçek zamanlı çalışma verileri toplanarak üretim süreci görsel olarak izlenebilir. Anormal ekipman, üretim sürecini optimize etmek için zamanında ele alınmalı ve ayarlanmalıdır.

Dİ ile birden fazla mühendislik disiplininin gereksinimleri entegre edilir ve tüm yaşam döngüsü boyunca gerçek zamanlı haritalama verilerine dayalı olarak sistem düzeyinde simülasyon ile kendi kendine karar verebilir. Endüstride Dİ'in uygulanabileceği araçlardan biri de CNC tezgâhlarıdır. Endüstrinin ana makinesi olan CNC takım tezgâhı, akıllı imalatla önemli bir ekipmandır. Akıllı üretim modunda, karmaşık işleme görevini ve özelleştirilmiş üretim gereksinimlerini yerine getirmek için bazı niteliklere sahip olmalıdır. Bu nitelikler; 1) hassas simülasyon, 2) kendini algılama, 3) kendinden ayarlama, 4) kendini tahmin etme, 5) öz değerlendirme şeklinde ifade edilebilir.

Hassas simülasyon ile CNC takım tezgâhında (CNCMT) tasarım parametresi ve fiili çalışma koşulları farklıdır. CNCMT modelinin simülasyonu, fiziksel ekipmandan toplanan veri ve bilgileri dikkate alınmalıdır. Hassas simülasyon, çok alanlı modelleme ve simülasyonu CNCMT'den alınan doğru ve güvenilir verilerle entegre edecektir.

Kendini algılama, CNCMT için bir siber fiziksel sistem geliştirmenin ilk adımıdır. Kendi kendine algılama, CNCMT ve bileşenlerinden doğru ve güvenilir veriler elde edebilir ve ardından verilerden anlamlı bilgiler çıkarılabilir.

Kendinden ayarlama yeteneğine sahip CNCMT, üretim görevine göre daha az zaman, daha az fire ve daha iyi kalite için kendini ayarlayabilir. Ayrıca, üretimin minimum kullanıcı endişesi yaratmasını sağlamak için kendini ayarlayabilir.

Kendini tahmin etme; CNCMT, düzensiz olarak farklı hatalara neden olabilir, bu da hatalı hassasiyete neden olur ve üretimi etkiler. Kendi kendini tahmin etme yeteneğine sahip CNCMT, arızayı ciddi arızalar oluşmadan önce çevreye ve kendi koşullarına göre zamanında izleyebilir ve tahmin edebilir.

Öz değerlendirme; kendi kendini değerlendirme yeteneğine sahip CNCMT, çalışma durumunu değerlendirebilir, çalışma parametrelerini optimize edebilir ve makine öğrenimine dayalı kararlar verebilir.

CNCMT'yi bahsedilen yetenekleri elde edecek kadar akıllı hale getirmek için CNCMT'nin Dİ (DTMT) üzerine bir araştırma yapılmıştır. Bu çalışmada, birçok alan için birleşik bir Dİ modelleme yöntemi kurulmuş, fiziksel alan ve dijital alan arasında bir haritalama stratejisi tasarlanmıştır. Buna dayalı bir Dİ kullanma stratejisi araştırılmıştır. DTMT, CNCMT'nin gerçek zamanlı dijital kopyasıdır. Dİ, son derece gelişmiş bilgi işlem, yüksek hassasiyetli simülasyon ve hızlı gelişen yapay zekâ teknolojisi ile sağlanır. Ultra yüksek sadakat modeli tarafından yönlendirilen ve doğru verilere dayalı makine öğrenimi, uzmanlık ve alan bilgisi algoritma modeli ile ifade edilebilir. Bu nedenle DTMT, bir uzman gibi hassas simülasyon, kendini algılama, kendini ayarlama, kendini tahmin etme ve kendi kendini değerlendirme yeteneğine sahiptir. CNCMT'nin tasarım, imalat, kullanım, bakım ve geri dönüşüm aşamalarında kullanılabilir. DTMT ile, CNCMT'nin tüm yaşam döngüsünde birleşik bir model kullanılır. Karmaşık işleme görevini yerine getirmek, plansız bakımın kesinti süresini azaltmak, işleme verimliliğini artırmak ve maksimum yeniden kullanım sağlamak amacıyla birleşik ve gerçek zamanlı algılanan veriler ile çalıştırılmaktadır. Bir DTMT oluşturmak için birleşik model, gerçek

zamanlı algılanan veri desteği ve akıllı kullanım stratejisi çok önemlidir [15].

5. MAKİNE ÖĞRENMESİ ALGORİTMALARI

Yapay zekâ (AI), karmaşık problemleri çözmek için yapay bir varlık tarafından sergilenen zekâ olarak tanımlanır ve böyle bir sistemin genellikle bir bilgisayar veya makine olduğu varsayılır [83]. Yapay zekâ, bilgisayar bilimi ve fizyolojinin bir entegrasyonudur. Basit dilde zekâ, dünyadaki hedeflere ulaşma yeteneğinin hesaplamalı kısmıdır. Zekâ, ezberleme ve anlama yaratmayı, kalıpları tanımayı, değişime uyum sağlayarak seçimler yapmayı ve deneyimlerden öğrenmeyi hayal etme yeteneğidir. Yapay zekâ, bilgisayarların insanlar gibi davranmasını sağlamakla ilgilenir. Yapay zekâ, daha çok insan gibi moda olan ve bir insanın aldığından çok daha kısa sürede karmaşık sorunları çözmeye çalışır. Bu nedenle Yapay Zekâ olarak adlandırılır [84]. AI araştırmasının önemli bir amacı, normalde insan zekâsı gerektiren çeşitli görevleri yerine getirmek için makineler tasarlamaktır. Makine öğrenimi yapay zekanın bir alt kümesi olarak kabul edilir. Makine öğrenimi, insan zekâsı ile ilişkili deneysel "öğrenmeyi" sergilerken, aynı zamanda hesaplama algoritmalarının kullanımı yoluyla analizlerini öğrenme ve geliştirme kapasitesine sahiptir. Bu algoritmalar, kalıpları tanımak ve makineyi otonom öneriler veya kararlar vermek üzere eğitmek için etkin bir şekilde "öğrenmek" için büyük veri girdileri ve çıktıları kullanır. Algoritmanın yeterli tekrarı ve modifikasyonundan sonra, makine bir girdi alabilir ve bir çıktı tahmin edebilir [85-86].

Bu çalışmada, farklı karakteristik özelliklere sahip makine öğrenmesi algoritmaları kullanılmak istenmiştir. Bellek tabanlı sınıflandırıcı olarak K en yakın komşu algoritması ile optimizasyon tabanlı sınıflandırma algoritmalarından DVM seçilmiştir. Yapay sinir ağları modelleri çoklu regresyon tabanlı çalıştığından dolayı doğrusal regresyon yöntemi ile birlikte çalışmaya dahil edilmiştir.

5.1. Destek Vektör Makineleri (DVM)

Destek Vektör Makinesi popüler bir sınıflandırma tekniğidir. Genellikle verileri eğitim ve test setlerine ayırmayı kapsar. Eğitim setindeki her model, bir “hedef değer” ve birkaç “nitelik” içerir. DVM'nin amacı, yalnızca test verisi öznelikleri verilen test verilerinin hedef değerlerini tahmin eden bir model oluşturmaktır. Algoritma, her veri örneğinin gerçek sayıların bir vektörü olarak temsil edilmesini gerektirir. Bu nedenle, kategorik öznelikler varsa, önce sayısal verilere dönüştürülmesi gerekir. DVM uygulamadan önce yapılması gereken bir diğer şey de ölçekleme yapmaktır. Ölçeklemenin ana avantajı, daha küçük sayısal aralıklardaki niteliklere hâkim olan daha büyük sayısal aralıklardaki özneliklerden kaçınmaktır. Diğer bir avantaj, hesaplama sırasında sayısal zorluklardan kaçınmaktır [87]. Şekil 1’ de farklı özellikte iki kümenin çizilen birden fazla vektörler ile nasıl ayrıldığı gösterilmiştir.

Aşağıdakiler dört temel çekirdek fonksiyonlarıdır:

1) Doğrusal:

$$K(x_j, x_j) = x_i^T x_j. \quad (1)$$

2) Polinom:


$$K(x_j, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0. \quad (2)$$

3) Radyal Tabanlı Fonksiyon:

$$K(x_j, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0. \quad (3)$$

4) Sigmoid:

$$K(x_j, x_j) = \tanh(\gamma x_i^T x_j + r). \quad (4)$$



Şekil 1: Destek vektör makinesi şekilsel gösterimi.

5.2. K-en Yakın Komşu (KNN)

K-En Yakın Komşu, var olan tüm durumları saklayan ve bir benzerlik ölçütüne göre sınıflandıran bir algoritmadır. KNN, istatistiksel tahmin ve örüntü tanımda parametrik olmayan bir yöntem olarak kullanılmıştır [88]. Şekil 2’de farklı gözlem değerlerinin arasında uzaklıklar hesaplanarak diğer bir ifade ile K-en yakın komşu algoritması kullanılarak farklı gözlem değerlerinin nasıl ayrıldığı gösterilmektedir.


Algoritmada bir olay, komşularının çoğunluk oyu ile sınıflandırılır. Bu olay, bir mesafe fonksiyonu ile ölçülen K en yakın komşusu arasında en geniş kitleye sahip olan sınıfa atanır. $K = 1$ ise, durum basitçe en yakın komşusunun sınıfına atanır. Sürekli değişkenler için kullanılan üç uzaklık vardır: Öklid (5), Manhattan (6), Minkowski (7). Kategorik değişkenlerde Hamming mesafesi (8) kullanılmalıdır.

$$\sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (5)$$

$$\sum_{i=1}^k |x_i - y_i| \quad (6)$$

$$(\sum_{i=1}^k (|x_i - y_i|^q))^{1/q} \quad (7)$$

$$D_H = \sum_{i=1}^k |x_i - y_i| \quad (8)$$

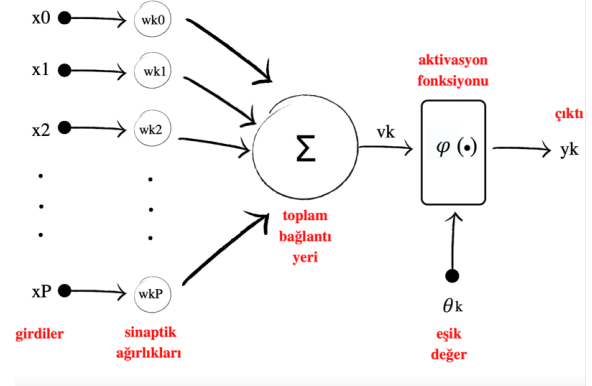


Şekil 2: K-En yakın komşu şekilsel gösterimi.

5.3. Yapay Sinir Ağları

Yapay Sinir Ağı (YSA) bilgisayar bilimleri alanlarında yeni bir bilgi işlem teknolojisi olarak kabul edilmiştir. YSA, biyolojik sinir sistemlerinin matematiksel modellerinin genellemeleri olarak geliştirilmiştir. Şekil 3'de biyolojik sinir sistemlerine ait nöron görülmektedir. Bir YSA, her biri muhtemelen (küçük miktarda) yerel belleğe sahip olan çok basit işlemcilerin (nöronlar) koleksiyonlarından oluşan bir ağıdır. Birimler yalnızca kendi yerel verileri üzerinde ve tek yönlü bağlantılar veya bağlantılar aracılığıyla aldıkları girişler üzerinde çalışır [89]. Bir ağ biriminin gelen sinyalleri toplamak ve bir çıkış sinyalini hesaplamak için bir kuralı vardır. Devamında diğer ağ birimlerine gönderilir. Callen'e göre çıktıyı hesaplama kuralları aktivasyon fonksiyonu olarak bilinir [90]. Bir sinir ağının yapısında üç katman vardır. Birinci katman, dış dünyalarla doğrudan etkileşime giren girdi katmanıdır. İkinci katman, sağlanan fonksiyona göre hesaplamaların yapıldığı gizli birimdir. Son katman ise çıktı aldığımız çıktı katmanıdır. Sinir ağlarındaki bilgi, nöronlar arasında sinaptik ağırlıklar olarak depolanır. Ağ, çıktı verileri oluşturulana kadar girdi verilerini katmandan katmana yayar. Eğer ağlar, Geri Yayılım Algoritması ile çok katmanlı algılayıcı ve çıktı istenen çıktıdan farklı ise, bir hata hesaplanır. Sonrasında ağ üzerinden geriye doğru yayılır. Hata yayıldıkça sinaptik ağırlıklar değiştirilir [91]. Genelleştirme, YSA'ları bu kadar güçlü bir araç yapan tek yetenektir.

Uygun bir gösterim kuralı verildiğinde, beklenen yanıtın, v_k 'nin, $v_k = \sum_{j=1}^p w_{kj}x_j$ 'ye göre ortak değişkenlerin $x = (x_0, \dots, x_p)$ değerleriyle ilişkili olduğu bir çoklu doğrusal regresyon modelinin şematik bir temsili vermektedir. Notasyon kuralı, dairenin, içine x_j 'lerin beslendiği ve ilgili w_{kj} 'ler ile çarpıldığı bir hesaplama birimini temsil etmesidir. Şekil 3'de $(w_{k0}, w_{k1}, \dots, w_{kp})$, X_n vektörlerinin girdi vektörlerinin kuvvetlerini belirlemek için ağırlıklardır. Her girdi ağırlık vektörleri ile çarpılır. Nöron y_k 'nin çıktısı, v_k değeri üzerindeki bazı aktivasyon fonksiyonlarının sonucudur.



Şekil 3: Sinir ağının matematiksel modeli.

Genel olarak, sinir ağları (temsil edilen matematiksel modeller), bir bağlantı sistemiyle birbirine bağlanan basit hesaplama birimlerinin bir koleksiyonudur. Birimlerin sayısı çok büyük olabilir ve bağlantılar karmaşık olabilir.

Sinir ağları, örüntü sınıflandırma ve örüntü tanımanın birçok uygulaması için kullanılır: Döviz kurları gibi finansal endekslerin tahmini, radar nokta kaynaklarının konumu, hedef tanıma ve mayın tespiti, uzay aracının yeniden giriş yörüngelerinin tahmini, el yazısı karakterlerin otomatik olarak tanınması, yüzlerin cinsiyetlerinin belirlenmesi, gezgin satıcı problemi gibi optimal yönlendirme problemlerinin çözümü, zaman serilerinin tahmininde düzensizliğin gürültüden ayırt edilmesi [92].


6. VAKA ÇALIŞMASI

6.1. Veri Analizi

Bu çalışmada kalite kontrol yapan bir cihaza ait veri seti ile çalışılmıştır. Bu cihaz kartezyen eksenli kalite kontrol cihazıdır. Bu veri setiyle kalite kontrol cihazına ait operasyon sürelerinin tahmin edilmesi amaçlanmaktadır. Hız faktörünün dinamikliği ile gerçeğe yaklaşılmaya çalışılmış ve olası bütün hız parametreleri denenmiştir. Bu doğrultuda hareket ve hız sütunları, $hız = yol/zaman$ formülü dikkate alınarak tek sütuna düşürülür. Amaç, verilen süreyi hareket/hız ile karşılaştırarak tahminleme yöntemlerini bu veriler üzerinden yürütmektir. Yani yeni veri seti iki sütundan oluşmuş olur. Birinci sütun "süre", ikinci sütun ise "hareket/hız" değerlerinden meydana gelir. Hız parametre değerleri (mm/dakika) 125, 250, 500, 750 ve 1000 ve hareket miktarları değerleri (mm) 10, 15, 25, 35, 50, 65, 75, 85, 100, 115, 125, 135, 150, 165, 175, 185, 200, 215, 225, 235, 250, 285, 300 olarak belirlemiş ve toplamda 115 operasyon süresi ölçülmüştür. Verinin %80'I eğitim verisi olarak ele alınmıştır. Kullanılan veri setinin başlangıç kısmı Çizelge 1 'de verilmiştir. Literatüre katkı sağlaması açısından verinin tamamı da github üzerinden paylaşılmıştır. [93]


Çizelge 1: Veri setinin ilk on değeri

#	Süre (sn)	Hız (mm/dk)	Hareket (mm)
1	12870.5	1000	100
2	6868.3	1000	50
3	3266.2	1000	20
4	2066	1000	10
5	21302.9	500	100
6	10904.7	500	50
7	4669.4	500	20
8	2592.1	500	10
9	41839.7	250	100
10	21058.7	250	50




Şekil 4: Düzeltme çizgisi ile beraber dağılım grafiği.

Şekil 4'te dağılım grafiği çizilerek üstüne düzeltme çizgisi eklenmiştir. Sadece noktalarla trendleri görmek zor olabilir. Trendlerin nasıl görüldüğünü görmek için çoğu zaman bir düzeltme çizgisi eklenir. Özellikle gerilemeleri anlamaya çalışırken yardımcı olabilir. Ggplot nesnesinden `geom_smooth, method=lm` kullanılarak çizimi yapılmıştır. Verilerin 0 ile 50000 süre değerleri arasında yoğunlaştığı görülür.



Şekil 5: Kutu grafiği.

Şekil 5 verilerin kutu grafiği verilmiştir. Verilerin 0-0,5 aralığında yığıldığını söylemek mümkündür. Üst ve alt "menteşeler" birinci ve üçüncü çeyreklere karşılık gelir. Kutunun içindeki çizgi ise medyayı temsil eder. Üst tarafta kalan nokta olarak gözükken değerler de aykırı olarak kabul edilir.



Şekil 6: Histogram grafiği üzerine çizilmiş olan yoğunluk grafiği.

Şekil 6’da öncelikle verilerin histogram grafiği çizilmiştir. Bu çizilen grafiğin üzerine yoğunluk grafiği de eklenmiştir. Histogramlar, verileri gruplandırarak ve her bir kutudaki gözlemlerin sayısını sayarak oluşturulur. Amaç genellikle dağılımın şeklini görselleştirmektir. Yoğunluk grafikleri, düzeltilmiş histogramların grafikleri olarak düşünülebilir.

Normalizasyon sonucunda elde edilen verilerle R’da makine öğrenmesi algoritmaları ile tahminlemeler yapılacaktır. Burada asıl amaç, süre (arızaya kalan süre) tahmini yapmaktır. Ayrıca çalışmanın sonucunda elde edilen değerler ile süre (duration) sütun verileri karşılaştırılarak hata hesaplamaları yapılacaktır.

6.2. Komutların İcra Süresinin Tahmini

Bir robot, 3B yazıcının veya CNC tezgahının Di modeli tezgahın gerçek üretim ortamındaki davranışlarını (enerji tüketimi, işlem süresi, arıza durumu v.b.) hesaplamaktadır. Bundan dolayı Dİ modeli üretim süreçlerinin kontrolünde ve optimizasyonunda faydalanılacak bir araçtır. Çalışmada G-Code komutlarının icra sürelerini doğru tahmin edebilen bir model önerilmiştir. Bu model tezgahın çeşitli fonksiyonlarının oluşturduğu etkileri hesaplayacak diğer modellerle birlikte tezgah Dİ’ini oluşturduğunda bütüleşik üretim ve proses planlama, proses optimizasyonu, gerçek zamanlı üretim planlama ve kontrol alanlarında katkı sağlayan bir model ortaya çıkmış olacaktır. Dolayısıyla önerilen süre tahmin 3 boyutlu yazıcıların ve CNC tezgahların Dİ’lerinin tasarımı için referans nitliğinde olacaktır.

Bu çalışmada kalite kontrol yapan bir cihaza ait veri seti kullanılmıştır. Veri odaklı olarak geliştirilen Dİ modelinde icra süresinin tahmini için makine öğrenmesi yöntemlerinden yararlanılmıştır. Modelin tasarımı için kullanılan veri seti doğrusal ve eliptik hareketlerin verilerinden oluşmaktadır. Hareket süresinin ölçümü için harekete başlama ve hareketin bitiş anı akım sensörü ile ölçülen değerlerin bir eşiği geçip geçmemesine bağlı olarak tespit edilmiştir. Makine öğrenmesi modelleriyle de hareket süresi ile G-Code parametreleri arasında korelasyon kurulmuştur.

6.2.1. Doğrusal Regresyon

Regresyon, tek katmanlı varyans analizi ve kovaryans analizi yapmak için kullanılabilir. Formül olarak ‘Süre~Hareket/Hız’ olarak alınmış veri olarak da normalizasyon sonucundaki verilerden yararlanılmıştır.

Çizelge 2: Regresyon istatistiği.

Parametreler	Değerler
Çoklu R	0,99927871
R Kare	0,99855794
Düzeltilmiş R Kare	0,99854518
Standart Hata	181780209
Gözlemler	115

Çizelge 2’de regresyon istatistik değerleri görülmektedir. R2 değerine bakıldığında 0,99 olduğu görülür. Bu durum modeli %99 başarı ile açıkladığı anlamına gelmektedir. 1 değerine yaklaştıkça daha iyi olan regresyon çizgisi verilere uyar. P değerinin 0.05’ten düşük olması da modelin doğruluğunu gösterir. Regresyon katsayıları yardımıyla tahminlemeler yapılmış ve %8 hata oranına ulaşılmıştır.

6.2.2. Destek Vektör Makineleri (DVM)

DVM bir destek vektör makinesini eğitmek için kullanılır. Yoğunluk tahmininin yanı sıra genel regresyon ve sınıflandırma yapmak için kullanılabilir. İlk parametrede, uygun modelin sembolik bir açıklaması olarak süre sütunu alınır. İkinci parametre olarak da modeldeki değişkenleri içeren isteğe bağlı bir veri çerçevesi, yani test seti kullanılır. Burada normalize edilmiş verilerin %80’i eğitim seti, %20’si test seti olarak alınır. Kernel için 4 farklı yöntem baz alınır. Her biri için de denenerek

tahminlemeler yapılır. Buradaki yöntemler; linear, polynomial, radial basis, sigmoid olarak sıralanmaktadır.

Çizelge 3: DVM matrisi çıktısı.

Genel İstatistik (linear, polynomial, radial)	Değerler
Doğruluk: 0.9565	Doğruluk: 0.6957
95% CI: (0.7805, 0.9989)	95% CI: (0.4708, 0.8679)
Bilgi Oranı Yok: 0.0435	Bilgi Oranı Yok: 0.0435
P-Değeri: < 2.2e-16	P-Değeri: < 2.2e-16
Kappa: 0.9545	Kappa: 0.6818

Çizelge 3’de DVM matrisi sonuçları verilmiştir. Sonuçlara göre linear, polynomial ve radial basis fonksiyonları %96 doğrulukla çalışmıştır. Bununla birlikte p-değerlerine bakıldığında 0.05’ten küçük olduğu için tüm fonksiyonların geçerliliği kabul edilir.


6.2.3. K-en Yakın Komşular (KNN)

KNN, sınıflandırma ve regresyon problemleri için tercih edilen denetimli bir makine öğrenme algoritmasıdır. Verileri sınıflandırmak için hayali bir sınır oluşturur. Tahmin için yeni veri noktaları eklendiğinde, algoritma bu noktayı sınır çizgisinin en yakınına ekler. Bu algorithmada k, kullanıcı tarafından tanımlanan bir sabittir ve en yakın komşuluklar vektörü kullanılarak hesaplanır. 'caret' paketi, regresyon sorunları için KNN'yi uygulamak için 'knnreg' işlevi sağlar. Komşu sayısı 5, 7, 9 şeklinde mimariler oluşturularak tahminlemeler gerçekleştirilmiş ve min hatayı veren komşu sayısı 5 olarak seçilmiştir.

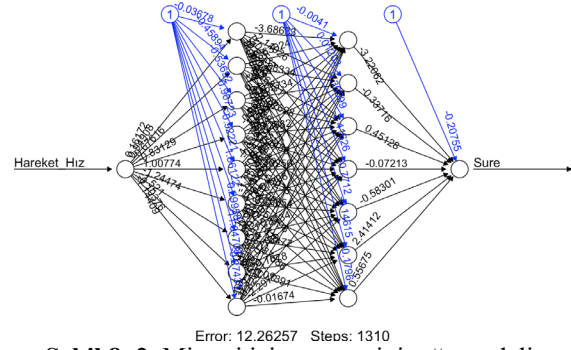
6.2.4. Yapay Sinir Ağları

Normalize edilmiş verilerin %80’i eğitim seti, %20’si test seti olarak alınır. Hidden= c (9, 7), threshold= 0.01, act.fct= “tanh” verilmesiyle minimum hata bulunmuştur (tekli hidden için 6, ikili için (9, 7) şeklindedir). Act.fct için ise “logistic” ve “tanh” seçenekleri mevcuttur. Bunlardan en iyi sonucu da “tanh” fonksiyonu vermiştir. Burada en küçük hatayı bulmaya çalışırken hidden belirlemede önce ikinci değer sabit tutularak birinci değer 1’den 10’a kadar denenmiştir, sonrasında en iyi çıkan birinci değer seçilip sabit tutularak ikinci değer 1’den

10’a kadar denenmiştir. Aynı değerler ile kod tekrardan çalıştırıldığında hata oranları düşük seviyede değişiklik gösterse de minimum hata (9, 7) için elde edilmiştir. Şekil 7 ve Şekil 8’de bu mimarilere ait yapay sinir ağı modelleri bulunmaktadır.



Şekil 7: 1. Mimari için yapay sinir ağı modeli.




Şekil 8: 2. Mimari için yapay sinir ağı modeli.

Yukarıda verilen mimarilerle birlikte R programı üzerinden yapay sinir ağlarıyla farklı kombinasyonlar deneyerek olabilecek en iyi mimari bulunmaya çalışılmıştır. Burada Tensorflow ve Keras kütüphanelerinden yararlanılmıştır. R’deki yapay sinir ağlarının yanında Python’la bağlantı kurarak Keras’i direkt kullanmak denenmiştir. Yinelemeli yerel arama algoritması ile en iyi mimariyi elde etmeye çalışarak bu kodun parametreleri oluşturulmuştur. Bu mimari Çizelge 3’de görülmektedir.

Çizelge 4: Olası optimum yapay sinir ağı mimarisi.

	Düğüm Sayısı	Aktivasyon Fonksiyonu
Girdi Sayısı	3	
Katman 1	30	'Relu'
Katman 2	80	'Relu'
Katman 3	40	'Relu'
Katman 4	30	'Relu'
Çıktı Sayısı	1	"Softplus"

**Şekil 9:** Yapay sinir ağları için hata ölçümleri grafiği.**Çizelge 5:** Hata oranlarına göre performans çizelgesi.

Yöntemler	MSE	MAE	R ²	Doğruluk
Regresyon	1.32E-36	0,0161802	0.985579	0.91722299
DVM-Lineer	0.00603773	0.06689249	0.995651	0.853849
DVM-Radyal	0.07171921	0.1321959	0.9483404	0.8104526
DVM-Polinom	0.4670129	0.471527	0.6636087	0.2650645
DVM-Sigmoid	1.887.448	0.8229177	0.3595363	0.0252
YSA 1. Mimari	0.2917583	0.1407296	0.654525	0.8823262
YSA 2. Mimari	0.2916694	0.1360941	0.6545329	0.8827776
YSA 3. Mimari	0.00015435	0.008385	0.995745	0.991615
KNN 1.Mimari	0.0199952	0.05727025	0.1414044	0.93481055
KNN 2.Mimari	0.03570575	0.06796121	0.1889597	0.93612222
KNN 3.Mimari	0.0598606	0.09467588	0.2446643	0.91496762

7. SONUÇ

Bu çalışmada, dinamik hız ve hareket parametreleri ile çalıştırılan 3 boyutlu yazıcı ve CNC tezgâhları gibi kartezyen eksenli

Şekil 9'da 200 periyot için (epochs) 'adam optimize' ile, 'mse' kayıp fonksiyonu ve 'mse', 'mae', 'mape' metrikleri için 'compile' metodu ile bu şekil çizdirilmiştir. Burada en az dalgalanma 'mse' hesaplanmasında gerçekleşmiştir.

6.3. Yöntemlerin Karşılaştırılması

Kartezyen eksenli tezgahlarda farklı hız parametreleri kullanılarak ölçümler yapılmıştır. Bu işlemlerin cihaz üzerinde gerçekte ne kadar sürdüğü veri setinde mevcuttur. Örneğin bir işlem 21.321 ms olarak tahmin edilirken cihaz üzerinde yapılan ölçüm sonrasında 21.303 sn gerçekleştirilmiştir.

Çizelge 5'te çalışmada uygulanan makine öğrenmesi algortimalarının ortalama kareli hata (MSE), ortalama mutlak hata (MAE), R Kare (R²) ve Doğruluk yöntemleri kullanılarak performansları ölçülmüştür. Z-score normalizasyonu ile normalize edilmiş veri seti ile yapılan tahmin çalışmasında en düşük ortalama mutlak sapmaya sahip olan YSA 3. mimari MSE ve MAE açısından da en iyi performansı sergilemiştir. Bundan dolayı hata miktarı en düşük model YSA 3. mimari olarak değerlendirilmiştir. Diğer taraftan R² ve doğruluk değerlerine bakıldığında YSA 3. Mimarinin diğer methotlara oranla en yüksek değerlere sahip olduğu görülmektedir.

tezgahların işlem sürelerinin çalışma parametrelerine bağlı olarak tahmini için bir model önerilmiştir. Önerilen model üretim planlama açısından kaba kapasite planlama ile

çizelgelemede ve ürün tasarımı aşamasında da maliyet kestiriminde katkı sağlayacaktır. Modelin ön görülen katkıyı sağlayabilmesi için üretim sisteminde kullanılan tezgahlara adapte olması kaçınılmaz bir zorunluluk olduğundan zaman tahmin işleminde makine öğrenmesi modelleri değerlendirilmiştir. Endüstriyel CNC üreticisi DMG MORI'nin Dİ'leri iteratif optimizasyonda, üretim planlama ve kontrolde ve performans öngörülerinde kullandığını açıklaması bu durumu desteklemektedir.[94] Makinelere entegre edilen Dİ üretim sürecinin sanal ortamda detaylı bir simülasyonunun yapılmasını ve optimize edilmesini mümkün hale getirmektedirler.

Dİ oluşturan makine öğrenmesi modellerinin oluşturulma aşamasında kullanılan veriler kalite kontrol yapan kartezyen eksenli bir cihazdan alınmıştır. Örnek veri seti üzerinde veriler ön işlemeden geçirilmiş ve sonrasında işlem sürelerini tahmin etmek için makine öğrenmesi algoritmaları kullanılmıştır. Hata miktarları en düşük olan modeller YSA 3. mimari, doğrusal regresyon, k-en yakın komşu modelleri ve doğrusal DVM modelidir. Buradan, kartezyen eksenli (doğrusal veya eliptik) hareketlerin doğrusal yöntemlerle iyi modellenebildiği görülmektedir. Fakat en iyi yöntem olarak hem doğrusal hem de doğrusal olmayan ilişkileri modelleyebilen YSA modeli en iyi model olarak seçilmiştir. Bunun nedeni 0.00015435 MAE ve 0.008385 MSE değeri ile hata oranları açısından en düşük olan yöntemidir. Diğer yandan $995745 R^2$ değeri ve 0.991615 doğruluk oranıyla de diğer modellerden daha yüksek değerlere sahiptir. Ayrıca lineer yöntemlerin daha başarılı olması varyansın 'da düşük olduğu konusunda fikir vermektedir.

Çalışmanın bir sonraki aşamasında birçok makine öğrenmesi algoritmasını çalıştırabilen ve bu algoritmalara ait parametreleri optimize ederek yöntemlerin performanslarını en iyilemeye çalışan AutoML ve hiper-parametre optimizasyonları yapılacaktır.

KAYNAKLAR

1. Zhang D, "Powering E-Learning In The New Millenium: An Overview of E-Learning and

Enabling Technology, Information System Frontiers," Vol. 5, Issue 2, Page 201–212, 2004.

2. [A. Y. C. Nee, S. K. Ong, G. Chryssolouris, and D. Mourtzis, "Augmented reality applications in design and manufacturing," CIRP Ann Manuf Technol, Vol. 61, Issue 2, Page 657–679, 2012

3. D. Ivanov, A. Dolgui, B. Sokolov, F. Werner, and M. Ivanova, "A dynamic model and an algorithm for short-term supply chain scheduling in the smart factory industry 4.0," Int J Prod Res, Vol. 54, Issue 2, Page 386–402, 2016

4. J. E. Brough, M. Schwartz, S. K. Gupta, D. K. Anand, R. Kavetsky, and R. Pettersen, "Towards the development of a virtual environment-based training system for mechanical assembly operations," Virtual Real, Vol. 11, Issue 4, Page 189–206, 2007

5. Blaga and L. Tamas, "Augmented Reality for Digital Manufacturing," MED 2018 - 26th Mediterranean Conference on Control and Automation, Page 173–178, 2018

6. N. Syam and A. Sharma, "Waiting for a sales renaissance in the fourth industrial revolution: Machine learning and artificial intelligence in sales research and practice," Industrial Marketing Management, Vol. 69, Issue December 2017, Page 135–146, 2018

7. Ramos, J. C. Augusto, and D. Shapiro, "Ambient intelligencethe next step for artificial intelligence," IEEE Intell Syst, Vol. 23, Page 15–18, 2008

8. Duncan, M. Whittington, and V. Chang, "Enterprise security and privacy: Why adding IoT and big data makes it so much more difficult," Proceedings of 2017 International Conference on Engineering and Technology, ICET 2017, Vol. 2018-Janua, Page 1–7, 2017

9. P. Aivaliotis, K. Georgoulis, and K. Alexopoulos, "Using digital twin for maintenance applications in manufacturing: State of the Art and Gap analysis," Proceedings - 2019 IEEE International Conference on Engineering, Technology and Innovation, ICE/ITMC 2019, 2019

10. Altamiranda and E. Colina, "A system of systems digital twin to support life time management and life extension of subsea production systems," OCEANS 2019 - Marseille, OCEANS Marseille 2019, Vol. 2019-June, Page 1–9, 2019

11. Murphy et al., “Representing financial data streams in digital simulations to support data flow design for a future Digital Twin,” *Robot Comput Integr Manuf*, Vol. 61, 2018
12. P. Aivaliotis, K. Georgoulas, and G. Chryssolouris, “The use of Digital Twin for predictive maintenance in manufacturing,” *Int J Comput Integr Manuf*, Vol. 32, Page 1067–1080, 2019
13. W. Luo, T. Hu, Y. Ye, C. Zhang, and Y. Wei, “A hybrid predictive maintenance approach for CNC machine tool driven by Digital Twin,” *Robot Comput Integr Manuf*, Vol. 65, Page 101974, 2020
14. P. Hehenberger and D. Bradley, “Mechatronic futures: Challenges and solutions for mechatronic systems and their designers,” *Mechatronic Futures: Challenges and Solutions for Mechatronic Systems and Their Designers*, Page 1–259, 2016
15. M. Grieves, “Digital Twin: Manufacturing Excellence through Virtual Factory Replication - A Whitepaper by Dr . Michael Grieves,” *White Paper*, Issue March, Page 1–7, 2014.
16. K. A. Hribernik, L. Rabe, K. D. Thoben, and J. Schumacher, “The product avatar as a product-instance-centric information management concept,” *Int J Prod Lifecycle Manag*, Vol. 1, Page 367–379, 2006
17. J. Ríos, J. C. Hernández, M. Oliva, and F. Mas, “Product avatar as digital counterpart of a physical individual product: Literature review and implications in an aircraft,” *Advances in Transdisciplinary Engineering*, Vol. 2, Page 657–666, 2015
18. T. Wuest, K. Hribernik, and K. D. Thoben, “Assessing servitisation potential of PLM data by applying the product avatar concept,” *Production Planning and Control*, Vol. 26, Page 1198–1218, 2015
19. K. Hribernik, T. Wuest, and K. D. Thoben, “Towards product avatars representing middle-of-life information for improving design, development and manufacturing processes,” *IFIP Adv Inf Commun Technol*, Vol. 411, Page 85–96, 2013
20. M. Shafto et al., “Modeling , Simulation , Information Technology & Processing Roadmap-NASA,” *National Aeronautics and Space Administration*, Page 1–38, 2012.
21. Bilberg and A. A. Malik, “Digital twin driven human–robot collaborative assembly,” *CIRP Annals*, Vol. 68, Page 499–502, 2019
22. S. Meng, S. Tang, Y. Zhu, and C. Chen, “Digital Twin-Driven Control Method for Robotic Automatic Assembly System,” *IOP Conf Ser Mater Sci Eng*, Vol. 493, 2019
23. Q. Liu, H. Zhang, J. Leng, and X. Chen, “Digital twin-driven rapid individualised designing of automated flow-shop manufacturing system,” *Int J Prod Res*, Vol. 57, Page 3903–3919, 2019
24. Botkina, M. Hedlind, B. Olsson, J. Henser, and T. Lundholm, “Digital Twin of a Cutting Tool,” *Procedia CIRP*, Vol. 72, Page 215–218, 2018
25. D. Process, M. Supported, and W. Artificial, “Yapay zeka destekli bir tasarim işlem modelinin yapisi,” *Cilt 1*, Sayfa 1–8, 2017.
26. O. SEVLİ, “3 Boyutlu Baskıda Kullanılacak Malzemenin Makine Öğrenmesi Teknikleri İhtisarı,” *International Journal of 3D Printing Technologies and Digital Industry*, Cilt 5, Sayı 3, Sayfa 596–605, 2021
27. D. ALTUNKAYNAK, B. DUMAN, and K. ÇERİNKAYA, “5 Eksen 3B Yazıcı Tasarımı Ve Uygulaması,” *International Journal of 3D Printing Technologies and Digital Industry*, Cilt 4, Sayı 2, Sayfa 124–138, 2020
28. P. Wang, K. Erkorkmaz, J. McPhee, and S. Engin, “In-process digital twin estimation for high-performance machine tools with coupled multibody dynamics,” *CIRP Annals*, Vol. 69, issue. 1, Page 321–324, 2020
29. K. Liu, L. Song, W. Han, Y. Cui, and Y. Wang, “Time-Varying Error Prediction and Compensation for Movement Axis of CNC Machine Tool Based on Digital Twin,” *IEEE Trans Industr Inform*, Vol. 18, issue. 1, Page 109–118, 2022
30. Y. G. Kabaldin, P. V. Kolchin, D. A. Shatagin, M. S. Anosov, and A. A. Chursin, “Digital Twin for 3D Printing on CNC Machines,” *Russian Engineering Research*, Vol. 39, issue. 10, Page 848–851, Oct. 2019
31. S. Paripooran, R. Abishek, D. C. Vivek, and S. Karthik, “An Implementation of AR Enabled Digital Twins for 3-D Printing,” *Proceedings - 2020 6th*

IEEE International Symposium on Smart Electronic Systems, iSES 2020, Page 155–160, 2020

32. Y. Zhang, L. Mu, G. Shen, Y. Yu, and C. Han, “Fault diagnosis strategy of CNC machine tools based on cascading failure,” *J Intell Manuf*, Vol. 30, issue. 5, Page 2193–2202, 2019

33. Villalonga, G. Beruvides, F. Castaño, R. E. Haber, and M. Novo, “Condition-based Monitoring Architecture for CNC Machine Tools based on Global Knowledge,” *IFAC-PapersOnLine*, Vol. 51, issue. 11, Page 200–204, 2018

34. W. Luo, T. Hu, C. Zhang, and Y. Wei, “Digital twin for CNC machine tool: modeling and using strategy,” *J Ambient Intell Humaniz Comput*, Vol. 10, issue. 3, Page 1129–1140, 2019

35. M. Liu, S. Fang, H. Dong, and C. Xu, “15 Review of digital twin about concepts, technologies, and industrial applications,” *J Manuf Syst*, Vol. 58, Page 346–361, 2021

36. Cimino, E. Negri, and L. Fumagalli, “2 Review of digital twin applications in manufacturing,” *Comput Ind*, Vol. 113, 2019

37. J. Wu, Y. Yang, X. U. N. Cheng, H. Zuo, and Z. Cheng, “3 The Development of Digital Twin Technology Review,” in *Proceedings - 2020 Chinese Automation Congress, CAC 2020*, Institute of Electrical and Electronics Engineers Inc., Nov. 2020, Page 4901–4906

38. R. K. Phanden, P. Sharma, and A. Dubey, “6 A review on simulation in digital twin for aerospace, manufacturing and robotics,” in *Materials Today: Proceedings*, Elsevier Ltd, 2020, Page 174–178

39. M. Holler, F. Uebernickel, and W. Brenner, “Digital Twin Concepts in Manufacturing Industries- A Literature Review and Avenues for further Research,” *18th International Conference on Industrial Engineering (IJIE)*, Issue 2002, 2016.

40. M. Shafto, M. Conroy, R. Doyle, and E. Glaessgen, “DRAFT Modeling, Simulation, information Technology & Processing Roadmap,” *Technology Area*, 2010.

41. M. Madni, C. C. Madni, and S. D. Lucero, “Leveraging digital twin technology in model-based systems engineering,” *Systems*, Vol. 7, issue. 1, 2019

42. Q. Liu, B. Liu, G. Wang, and C. Zhang, “A comparative study on digital twin models,” in *AIP* 43. *Conference Proceedings*, 2019.

44. J. Leng, D. Wang, W. Shen, X. Li, Q. Liu, and X. Chen, “13 Digital twins-based smart manufacturing system design in Industry 4.0: A review,” *Journal of Manufacturing Systems*, Vol. 60. Elsevier B.V., Page 119–137, 2021.

45. Semeraro, M. Lezoche, H. Panetto, and M. Dassisti, “14 Digital twin paradigm: A systematic literature review,” *Comput Ind*, Vol. 130, 2021

46. M. Grieves, “Digital Twin : Manufacturing Excellence through Virtual Factory Replication,” *White Paper*, issue. March, 2014.

47. R. Zhang, F. Gu, H. Mansaf, T. Wang, and A. D. Ball, “Gear wear monitoring by modulation signal bispectrum based on motor current signal analysis,” *Mech Syst Signal Process*, Vol. 94, Page 202–213

48. M. W. Grieves, “Product lifecycle management: the new paradigm for enterprises,” *International Journal of Product Development*, Vol. 2, issue. 1–2, 2005

49. S. Haag and R. Anderl, “Digital twin – Proof of concept,” *Manuf Lett*, Vol. 15, 2018

50. K. T. Park et al., “Design and implementation of a digital twin application for a connected micro smart factory,” *Int J Comput Integr Manuf*, Vol. 32, Issue 6, 2019

51. Q. Qi, F. Tao, Y. Zuo, and D. Zhao, “Digital Twin Service towards Smart Manufacturing,” in *Procedia CIRP*, 2018

52. Onaji, D. Tiwari, P. Soulatiantork, B. Song, and A. Tiwari, “Digital twin in manufacturing: conceptual framework and case studies,” *International Journal of Computer Integrated Manufacturing*. Taylor and Francis Ltd., 2022

53. M. Mazzoleni, M. Scandella, F. Previdi, and G. Pispoli, “Data on the first endurance activity of a Brushless DC motor for aerospace applications,” *Data Brief*, Vol. 29, Apr. 2020

54. Theissler, J. Pérez-Velázquez, M. Kettelgerdes, and G. Elger, “Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry,” *Reliab Eng Syst Saf*, Vol. 215, 2021

55. Y. H. Son, K. T. Park, D. Lee, S. W. Jeon, and S. do Noh, "Digital twin-based cyber-physical system for automotive body production lines," *International Journal of Advanced Manufacturing Technology*, Vol. 115, issue. 1–2, 2021
56. Biesinger and M. Weyrich, "The Facets of Digital Twins in Production and the Automotive Industry," in 2019 23rd International Conference on Mechatronics Technology, ICMT 2019, 2019
57. M. Lamagna, D. Groppi, M. M. Nezhad, and G. Piras, "A COMPREHENSIVE REVIEW ON DIGITAL TWINS for SMART ENERGY MANAGEMENT SYSTEM," *International Journal of Energy Production and Management*, Vol. 6, issue. 4, 2021
58. E. Onile, R. Machlev, E. Petlenkov, Y. Levron, and J. Belikov, "Uses of the digital twins concept for energy services, intelligent recommendation systems, and demand side management: A review," *Energy Reports*, Vol. 7, 2021
59. L. Lattanzi, R. Raffaelli, M. Peruzzini, and M. Pellicciari, "12 Digital twin for smart manufacturing: a review of concepts towards a practical industrial implementation," *Int J Comput Integr Manuf*, Vol. 34, issue. 6, Page 567–597, 2021
60. L. Li, B. Lei, and C. Mao, "Digital twin in smart manufacturing," *J Ind Inf Integr*, Vol. 26, 2022
61. O. S. Kobayakova, V. I. Starodubov, N. G. Kurakova, and L. A. Tsvetkova, "Digital twins in healthcare: An assessment of technological and practical prospects," *Vestn Ross Akad Med Nauk*, Vol. 76, issue. 5, 2021
62. K. Bruynseels, F. S. de Sio, and J. van den Hoven, "Digital Twins in health care: Ethical implications of an emerging engineering paradigm," *Front Genet*, Vol. 9, issue. FEB, 2018
63. L. Pan, X. Guo, Y. Luan, and H. Wang, "Design and realization of cutting simulation function of digital twin system of CNC machine tool," in *Procedia Computer Science*, 2021
64. H. dos Santos, J. A. B. Montevechi, J. A. de Queiroz, R. de Carvalho Miranda, and F. Leal, "11 Decision support in productive processes through DES and ABS in the Digital Twin era: a systematic literature review," *International Journal of Production Research*. Taylor and Francis Ltd., 2021
65. Ashtari Talkhestani et al., "An architecture of an Intelligent Digital Twin in a Cyber-Physical Production System," *At-Automatisierungstechnik*, Vol. 67, issue. 9, 2019
66. J. Wilhelm, C. Petzoldt, T. Beinke, and M. Freitag, "16 Review of Digital Twin-based Interaction in Smart Manufacturing: Enabling Cyber-Physical Systems for Human-Machine Interaction," *Int J Comput Integr Manuf*, Vol. 34, issue. 10, Page 1031–1048, 2021
67. J. C. P. Cheng, W. Chen, K. Chen, and Q. Wang, "Data-driven predictive maintenance planning framework for MEP components based on BIM and IoT using machine learning algorithms," *Autom Constr*, Vol. 112, 2020
68. Ashtari Talkhestani et al., "An architecture of an Intelligent Digital Twin in a Cyber-Physical Production System," *At-Automatisierungstechnik*, Vol. 67, issue. 9, 2019
69. S. Ayvaz and K. Alpay, "Predictive maintenance system for production lines in manufacturing: A machine learning approach using IoT data in real-time," *Expert Syst Appl*, Vol. 173, 2021
70. Singh, "Big data, industry 4.0 and cyber-physical systems integration: A smart industry context," in *Materials Today: Proceedings*, 2021
71. M. M. Rathore, S. A. Shah, D. Shukla, E. Bentafat, and S. Bakiras, "The Role of AI, Machine Learning, and Big Data in Digital Twinning: A Systematic Literature Review, Challenges, and Opportunities," *IEEE Access*, Vol. 9, 2021
72. W. J. Lee, H. Wu, H. Yun, H. Kim, M. B. G. Jun, and J. W. Sutherland, "Predictive maintenance of machine tool systems using artificial intelligence techniques applied to machine condition data," in *Procedia CIRP*, Elsevier B.V., 2019, Page 506–511
73. Kammerer, M. Gaust, M. Küstner, P. Starke, R. Radtke, and A. Jesser, "Motor Classification with Machine Learning Methods for Predictive Maintenance," *IFAC-PapersOnLine*, Vol. 54, issue. 1, Page 1059–1064, 2021
74. Gohel, H. Upadhyay, L. Lagos, K. Cooper, and A. Sanzetenea, "Predictive maintenance architecture development for nuclear infrastructure using machine learning," *Nuclear Engineering and*

Technology, Vol. 52, issue. 7, Page 1436–1442, Jul. 2020

75. Q. Zhang, Z. Yang, J. Duan, Z. Liu, and J. Qin, “Three-dimensional visualization interactive system for digital twin workshop,” *Journal of Southeast University (English Edition)*, Vol. 37, issue. 2, 2021

76. Z. Han, Y. Li, M. Yang, Q. Yuan, L. Ba, and E. Xu, “Digital twin-driven 3D visualization monitoring and traceability system for general parts in continuous casting machine,” *Journal of Advanced Mechanical Design, Systems and Manufacturing*, Vol. 14, issue. 7, 2020

77. Shi, Q. Bi, and Y. Wang, “Five-axis interpolation of continuous short linear trajectories for 3[PP]S-XY hybrid mechanism by dual Bezier blending,” *J Shanghai Jiaotong Univ Sci*, Vol. 21, issue. 1, Page 90–102, 2016

78. N. Saikumar, N. S. Dinesh, and P. Kammardi, “Experience mapping based prediction controller for the smooth trajectory tracking of DC motors,” *Int J Dyn Control*, Vol. 5, issue. 3, Page 704–720, 2017

79. M. Endo and B. Sencer, “Accurate prediction of machining cycle times by data-driven modelling of NC system’s interpolation dynamics,” *CIRP Annals*, Vol. 71, issue. 1, Page 405–408, 2022

80. T. Gurgenc, F. Ucar, D. Korkmaz, C. Ozel, and Y. Ortac, “A study on the extreme learning machine based prediction of machining times of the cycloidal gears in CNC milling machines,” *Production Engineering*, Vol. 13, issue. 6, Page 635–647, 2019

81. P. Aivaliotis, K. Georgoulas, and G. Chryssolouris, “The use of Digital Twin for predictive maintenance in manufacturing,” *Int J Comput Integr Manuf*, Vol. 32, issue. 11, 2019

82. H. A. Weiss, N. Leuning, K. Hameyer, H. Hoffmann, and W. Volk, “Manufacturing efficient electrical motors with a predictive maintenance approach,” *CIRP Annals*, Vol. 68, issue. 1, Page 253–256

83. El Saddik, “Digital Twins: The Convergence of Multimedia Technologies,” *IEEE Multimedia*, Vol. 25, issue. 2, Page 87–92, 2018

84. G. F. Luger, *Artificial Intelligence: Structures and Strategies for Complex Problem Solving*, Vol. 5th. 2005.

85. G. K. Jha, “Artificial Neural Networks - Architectures and Applications,” *Artificial Neural Networks - Architectures and Applications*, 2013

86. S. A. Bini, “Artificial Intelligence, Machine Learning, Deep Learning, and Cognitive Computing: What Do These Terms Mean and How Will They Impact Health Care?,” *Journal of Arthroplasty*, Vol. 33, issue. 8, Page 2358–2361, 2018

87. D. Naylor, “On the prospects for a (Deep) learning health care system,” *JAMA - Journal of the American Medical Association*, Vol. 320, issue. 11, Page 1099–1100, 2018

88. C.-W. Hsu, C.-C. Chang, and C.-J. Lin, “Propofol and sevoflurane during epidural/general anesthesia: Comparison of early recovery characteristics and pain relief,” *Middle East Journal of Anesthesiology*, Vol. 17, issue. 5, Page 819–832, 2004.

89. R. O. Duda, P. E. Hart, and D. G. Stork, “Pattern classification,” *Handbook of Neural Computation*, 2004

90. Abraham, “Artificial neural networks,” *Artificial Neural Networks*, Page 1–426, 2011

91. Z. Zhou, “Rule Extraction: Using Neural Networks or for Neural Networks?,” issue. 2, Page 249–253, 2004.

92. F. Nielsen, “Recurrent Neural Networks algorithms and applications,” *Proceedings - 2021 2nd International Conference on Big Data and Artificial Intelligence and Software Engineering, ICBASE 2021*, Page 38–43, 2021

93. Cheng and D. M. Titterington, “[Neural Networks: A Review from Statistical Perspective]: Rejoinder,” *Statistical Science*, Vol. 9, issue. 1, Page 2–30, 2007

94. Cesur Muhammet Raşit and Cesur Elif, “Alcybe CNC Digital Twin” <https://github.com/rasitcesur/Alcybe/tree/DigitalTwin/Models/Workbench/DataSets>.

95. DMG MORI, “What is the Digital Twin?,” 2023. <https://dk.dmgmori.com/news-and-media/blog-and-stories/blog/what-is-the-digital-twin> (accessed Aug. 16, 2023).