



Ethem Sefa Küçükylmaz

Firat University, Graduate School of Natural and Applied Sciences,
eskucukyilmaz@firat.edu.tr, Elazığ-Türkiye

Erhan Akın

Firat University, eakin@firat.edu.tr, Elazığ-Türkiye

Gizem Öztürk

SERKON Makina A.Ş., ozturkggizem@gmail.com, İstanbul-Türkiye

DOI	http://dx.doi.org/10.12739/NWSA.2025.20.4.1A0500		
ORCID ID	0009-0008-6912-1851	0000-0001-6476-9255	0009-0008-2328-4903
Corresponding Author	Ethem Sefa Küçükylmaz		

TEKSTİL ENDÜSTRİSİNDE GİZLİ KAPASİTENİN ORTAYA ÇIKARILMASI: GELENEKSEL ZAMAN ETÜDÜ VE KÖK NEDEN ANALİZİ ENTEGRASYONU

Öz

Bu çalışmanın amacı, hazır giyim sektöründe darboğaz oluşturabilen otomatik serim makinelerinin operasyonel verimliliğini ölçmek, gizli kapasite kayıplarını belirlemek ve bu kayıpların kök nedenlerini analiz etmektir. Metodolojik olarak, Phakphonhamin (2018) tarafından önerilen "Adam-Makine Şeması" ve "Kayıp Zaman Analizi" yöntemleri temel alınmış, bu geleneksel yöntemler Makine Öğrenmesi (Random Forest ve K-Means) algoritmaları ile desteklenmiştir. Elde edilen bulgular, işletmeler arasında önemli performans farkları olduğunu göstermektedir; benchmark olarak belirlenen işletme %89.4 verimlilik oranına ulaşırken, diğer işletmelerde verimlilik oranlarının %18,6 ile %64,6 arasında değiştiği tespit edilmiştir. Veri analizi sonuçlarına göre, en büyük verimlilik kaybı kalemi, toplam işlem süresinin %51,1'ine kadar ulaşabilen "Rulo Değişim Süreleri"dir. Çalışma kapsamında geliştirilen Random Forest tabanlı simülasyon modeli, rulo değişim süreçlerinde sağlanacak %50'lik bir iyileştirmenin, genel işletme verimliliğinde yaklaşık %6 puanlık (net %31,67'den %37,66'ya) bir artış sağlayacağını öngörmektedir. Sonuç olarak bu çalışma, serim operasyonlarında makine hızından ziyade hazırlık (setup) süreçlerinin verimlilik üzerindeki belirleyici etkisini nicel verilerle kanıtlamaktadır.

Anahtar Kelimeler: Otomatik Serim Makinesi, OEE, Verimlilik Analizi, Makine Öğrenmesi, Tekstil Endüstrisi

REVEALING HIDDEN CAPACITY IN THE TEXTILE INDUSTRY: INTEGRATION OF TRADITIONAL TIME STUDY AND ROOT CAUSE ANALYSIS

ABSTRACT

The aim of this study is to measure the operational efficiency of automatic spreading machines that may create bottlenecks in the ready-to-wear apparel industry, to identify hidden capacity losses, and to analyze the root causes of these losses. Methodologically, the Man-Machine Chart and Loss Time Analysis methods proposed by Phakphonhamin (2018) were adopted as the foundational approaches, and these traditional techniques were further supported by Machine Learning algorithms, namely Random Forest and K-Means. The findings reveal significant performance differences among the enterprises: while the benchmark company achieved an efficiency rate of 89.4%, efficiency levels in the other companies ranged between 18.6% and 64.6%. According to the data analysis results, the largest source of efficiency loss was identified as Roll Changeover Times, accounting for up to 51.1% of the total operation time. The Random Forest-based simulation model developed within the scope of the study predicts that a 50% improvement in roll changeover processes would result in an approximately 6 percentage-point increase in overall operational efficiency (from a net efficiency of 31.67% to 37.66%). In conclusion, this study quantitatively demonstrates that, in spreading operations, preparation and setup processes have a more decisive impact on efficiency than machine speed itself.

Keywords: Automatic Spreading Machine, OEE, Efficiency Analysis, Machine Learning, Textile Industry

How to Cite:

Küçükylmaz, S.E., Akın, E. ve Öztürk, G., (2025). Tekstil endüstrisinde gizli kapasitenin ortaya çıkarılması: geleneksel zaman etüdü ve kök neden analizi entegrasyon. Engineering Sciences, 20(4):113-128, DOI: 10.12739/NWSA.2025.20.4.1A0500.

1. GİRİŞ (INTRODUCTION)

Küresel hazır giyim endüstrisi, üretim döngülerinin giderek kısaldığı ve maliyet baskısının arttığı rekabetçi bir yapıya sahiptir. Bu üretim zinciri içerisinde "kesimhane" (cutting room), hammaddenin nihai ürüne dönüşüm sürecinin başladığı ve en büyük maliyet kalemi olan kumaşın işlendiği stratejik bir merkezdir. Kesimhane operasyonlarının verimliliği, sadece malzeme kullanım oranlarını değil, aynı zamanda dikim bantlarının beslenme hızını ve genel işletme kapasitesini doğrudan belirlemektedir. Bu süreçte otomatik serim makineleri, kumaş katlarını kesime hazırlayarak üretim hızını ve kalitesini standardize eden en kritik teknolojik yatırımlardan biridir. Ancak, yüksek teknolojiye sahip bu makinelerin varlığı, tek başına yüksek üretim performansı anlamına gelmemektedir. Mevcut veriler incelendiğinde, makine hızları (m/dk) ile gerçekleşen verimlilik arasında her zaman doğrusal bir korelasyon bulunmadığı görülmektedir. Örneğin, teorik hızı yüksek olan makinelerin dahi, operasyonel yönetim hataları ve plansız duruşlar nedeniyle düşük verimlilikle çalışabildiği tespit edilmiştir. Serim operasyonları, üretim akışında bir "darboğaz" (bottleneck) oluşturma potansiyeli taşımaktadır. Makine performansının tam olarak kullanılamaması, literatürde ve sektörel analizlerde "Gizli Kapasite" (Hidden Capacity) olarak tanımlanan üretim kayıplarına yol açmaktadır. Özellikle rulo değişimi, kumaş hata kontrolü ve pastal hazırlığı gibi "kesim dışı operasyonlar", makinenin katma değer yaratmayan sürelerini artırmakta ve toplam ekipman verimliliğini (OEE) düşürmektedir. Dolayısıyla, serim makinelerinin darboğaz potansiyelini minimize etmek; makinenin mekanik hızını artırmaktan ziyade, hazırlık süreçlerinin (setup times) optimize edilmesine ve operasyonel kayıpların kök nedenlerinin yönetilmesine bağlıdır.

İmalat sanayinde üretim performansının ölçülmesi ve iyileştirilmesi sürecinde Toplam Ekipman Etkinliği (OEE), en yaygın kabul gören anahtar performans göstergelerinden (KPI) biridir. Literatürde yapılan sistematik incelemeler, OEE'nin imalat ve hizmet sektörlerinde operasyonel kayıpların tespit edilmesinde standart bir metrik olarak kullanıldığını, ancak "kabul edilebilir" ortalama değerlerin sektöre ve hatta makine tipine göre büyük değişkenlik gösterdiğini ortaya koymaktadır [1]. Özellikle rüzgar çiftlikleri gibi farklı varlıkların karşılaştırmalı analizinde OEE metriğinin operasyonel kayıpları değerlendirmek için değerli bir araç olduğu vurgulanmakta, ancak evrensel bir standarttan ziyade varlık bazlı özelleştirilmiş analizlerin gerekliliği belirtilmektedir [2]. Tekstil ve benzeri hassas materyal işleyen makineler özelinde incelendiğinde, performans ve kalite oranlarının iyileştirilmesinin uluslararası standartlara uyum sağlamak için kritik olduğu görülmektedir. Örneğin, tekstil serim makineleriyle benzer mekanik prensiplere sahip olan sarma (winding) makineleri üzerine yapılan bir çalışmada, OEE ve Hata Türleri ve Etkileri Analizi (FMEA) entegrasyonunun üretim verimliliğini artırmada belirleyici olduğu tespit edilmiştir [3]. Bununla birlikte, inşaat ve proje yönetimi gibi diğer endüstriyel alanlarda yapılan çalışmalarda, verimliliği artırmaya yönelik dijitalleşme (BIM vb.) çabalarının, standart olmayan veri formatları ve yetersiz eğitim gibi engellerle karşılaştığı raporlanmıştır [4]. Bu durum, tekstil endüstrisindeki veri toplama ve analiz süreçlerinde de benzer standardizasyon sorunlarının yaşanabileceğine işaret etmektedir.

Otomatik serim makinelerinde "hedeflenen teorik hız" ile "gerçekleşen operasyonel hız" arasındaki farkı doğrudan ele alan çalışmalar sınırlı olmakla birlikte, benzer kinematik özelliklere sahip sarma ve çözme sistemleri üzerine yapılan araştırmalar, bu sapmanın nedenlerine ışık tutmaktadır. Transformatör sarım makineleri üzerine yapılan bir çalışmada, referans hız (set değeri) ile gerçek hız

arasındaki farkın, malzeme üzerindeki gerilim (tansiyon) kontrolünü doğrudan etkilediği ve bu sapmaların kalite problemlerine yol açabileceği belirtilmiştir [5]. Benzer şekilde, otomatik boru sarma sistemlerinde yapılan deneysel çalışmalarda, makine hızının dış faktörlere (örn. çekici hızı) otomatik uyum sağlaması hedeflense de, hız değişimlerinin %16.3'e varan tansiyon hatalarına neden olabildiği raporlanmıştır [6]. Bu bulgular, serim makinelerinde de teorik olarak yüksek hızlara çıkılsa bile, malzeme kalitesini korumak adına gerçek hızın düşürülmek zorunda kalındığını veya hız dalgalanmalarının verimlilik kayıplarına yol açtığını literatür tabanlı olarak desteklemektedir.

Otomatik serim süreçlerinde duruşlara neden olan bir diğer kritik faktör, hammadde kaynaklı kalite problemleridir (yırtık, leke, ton farkı vb.). Literatür incelendiğinde, kumaş yüzey hatalarının doğrudan serim makinesi verimliliği (OEE) veya serim hızı üzerindeki anlık sayısal etkisini (örn: "bir yırtık serim hızını %X düşürür" şeklinde) analiz eden çalışmaların sınırlı olduğu görülmektedir. Mevcut araştırmalar, sorunu daha çok "Hata Tespiti ve Sınıflandırma" aşamasında çözerek, hatalı kumaşın serim ve kesim hattına girmeden ayıklanmasına ve böylece süreç içi duruşların önlenmesine odaklanmaktadır. Güncel çalışmalarda, derin öğrenme tabanlı modellerin hata tespitinde yüksek başarı oranlarına ulaştığı görülmektedir. Örneğin, Derin Artık Ağ (ResNet50) mimarisinin kullanıldığı bir çalışmada; delik, yağ lekesi ve iplik hataları gibi kusurlar %95.36 doğruluk oranı ve %95.35 F1 skoru ile sınıflandırılmıştır [7]. Bu tür yüksek doğruluklu sistemlerin entegrasyonu, manuel kontrol ihtiyacını ortadan kaldırarak serim öncesi hazırlık sürelerini minimize etme potansiyeli taşımaktadır. Benzer şekilde, Endüstri 4.0 bileşenlerinin kalite kontrol süreçlerine dahil edilmesiyle geliştirilen Otomatik Makine Öğrenmesi (AutoML) modelleri, IoT sensörleri ve Kurumsal Kaynak Planlama (ERP) verilerini kullanarak kumaş kalitesini tahmin edebilmektedir [8]. Bu yaklaşım, hatalı hammadde kaynaklı yeniden işleme (re-work) ve operasyonel gecikme sürelerinin azaltılabileceğini sayısal verilerle ortaya koymaktadır. Polimerik teknik tekstiller üzerine yapılan kapsamlı bir derleme çalışması da, makine öğrenmesi destekli hata tahmin (defect prediction) mekanizmalarının, üretim sürecine anlık müdahale imkanı sağlayarak hem atık oranlarını düşürdüğünü hem de genel hat verimliliğini artırdığını vurgulamaktadır [9]. Dolayısıyla literatür, malzeme kaynaklı kayıpların çözümünün, serim makinesi hızını düşürmekte değil, akıllı hata tespit sistemleri ile hammaddeyi hatta girmeden kontrol etmekte yattığını işaret etmektedir.

Tekstil ve hazır giyim endüstrisinde operasyonel verimliliği artırmak amacıyla Yalın Üretim tekniklerinden biri olan SMED (Single Minute Exchange of Die) metodolojisi sıkça uygulanmaktadır. Ancak mevcut literatür incelendiğinde, bu uygulamaların genellikle baskı, kesim ve dikiş hatları üzerine yoğunlaştığı, spesifik olarak serim (spreading) makinelerindeki rulo değişim süreçlerine odaklanan çalışmaların sınırlı olduğu görülmektedir. Örneğin, düz yatak baskı makinelerinde 5S ve SMED tekniklerinin entegre kullanımıyla model değişim süresinin 142 dakikadan 117 dakikaya indirildiği ve bu iyileşmenin genel hat verimliliğini artırdığı raporlanmıştır [10]. Benzer şekilde, TPM ve SMED temelli bakım yönetim modellerinin, plansız duruşları ve uzun kurulum sürelerini minimize ederek tekstil işletmelerinde üretim kapasitesini optimize ettiği belirtilmektedir [11]. Bangladeş hazır giyim endüstrisi üzerine yapılan güncel bir çalışma da, SMED uygulamasının sadece zaman tasarrufu sağlamadığını, aynı zamanda maliyet ve israfı azaltarak sürdürülebilir bir performans artışı sunduğunu ortaya koymaktadır [12]. Hazırlık ve kurulum (setup) sürelerinin kısaltılmasının toplam ekipman verimliliği (OEE) üzerindeki doğrudan etkisi, farklı endüstriyel alanlarda yapılan

nicel analizlerle de desteklenmektedir. Serim makinelerindeki rulo değişim sürecine benzer bir akışa sahip olan tel kaplama ekstrüder makinelerinde yapılan bir vaka çalışmasında, kurulum süresinin 58.7 dakikadan 32.0 dakikaya düşürülmesiyle makine çalışma veriminde %45.5 oranında bir artış sağlandığı tespit edilmiştir [13]. Otomotiv montaj hatlarında yapılan bir başka çalışmada ise SMED tekniği ile değişim süresinin 291 saniye kısaltılması, efektif çalışma süresi kullanımını %63.4'ten %84.7'ye yükseltmiş ve üretim biriminin yüklenme oranını %97 seviyesine çıkarmıştır [14]. Benzer bir korelasyon lastik üretim endüstrisinde de gözlemlenmiş; setup süresinde sağlanan %22.5'lik bir iyileştirme, OEE değerini %55.7'den %68.8'e taşımıştır [15]. Bu bulgular, bu çalışmada öne sürülen "rulo değişim sürelerinin azaltılması yoluyla serim makinesi verimliliğinin artırılması" hipotezini literatürdeki benzer endüstriyel uygulamalarla doğrulamaktadır.

Endüstri 4.0 dönüşümüyle birlikte, tekstil üretim hatlarındaki verimlilik darboğazlarını tespit etmek için geleneksel yöntemlerin yerini giderek veri odaklı yaklaşımlar almaktadır. 2020 sonrası literatür incelendiğinde, özellikle zaman serisi verilerinin işlenmesinde derin öğrenme tekniklerinin öne çıktığı görülmektedir. Örneğin, dokuma ve konfeksiyon süreçlerinde global üretim verilerini zaman serisi bilgi grafına dönüştüren bir çalışma (TKG4TA modeli), Grafik Evrişimli Ağlar (GCN) ve LSTM kombinasyonu kullanarak darboğaz istasyonlarını tahmin etmiştir. Bu hibrit modelin, tek başına kullanılan yöntemlere kıyasla %8-15 oranında daha yüksek tahmin doğruluğu sağladığı raporlanmıştır [16]. Kalite kaynaklı darboğazların yönetiminde de görüntü işleme ve derin öğrenme teknikleri etkin bir şekilde kullanılmaktadır. Boya-terbiye hatlarında yapılan bir araştırmada, iplik dolaşma (entanglement) anomalileri zaman serisi görüntü analizi ve CNN algoritmaları ile tespit edilmiş, bu sayede duruşlara bağlı planlama sapmalarının önüne geçilmiştir [17]. "Gizli Kapasite" (Hidden Capacity) kavramı, sistemin teorik sınırları ile gerçekleşen performansı arasındaki kullanılmayan potansiyeli ifade eder.

Tekstil literatüründe bu kavram üzerine yapılan doğrudan çalışmalar sınırlı olsa da, veri analitiği yoluyla gizli potansiyelin ortaya çıkarılması metodolojisi, inşaat mühendisliğinden biyoteknolojiye kadar karmaşık sistemlerin analizinde kendini kanıtlamış bir yaklaşımdır. Örneğin, yapısal varlık yönetimi üzerine yapılan kapsamlı bir derlemede; köprülerden alınan yük testleri ve sürekli izleme verilerinin modellenmesiyle, yapıların "rezerv taşıma kapasitesinin" ortaya çıkarılabildiği ve bu sayede gereksiz bakım veya yenileme maliyetlerinin önleildiği belirtilmiştir [19]. Benzer bir veri madenciliği yaklaşımı biyoloji alanında da kullanılmaktadır; genom madenciliği ve metabolomik analizler sayesinde, normal koşullarda aktif olmayan "sessiz" gen kümeleri taranarak, organizmaların "gizli biyosentetik kapasitesi" keşfedilmektedir [20]. Farklı disiplinlerdeki bu uygulamalar, operasyonel verilerin derinlemesine analizinin, görünürde olmayan üretim rezervlerini ortaya çıkarabileceğini kanıtlamaktadır. Bu çalışma da benzer bir analitik yaklaşımla, serim makinelerindeki operasyonel verileri işleyerek, atıl kalan üretim kapasitesini görünür kılmayı hedeflemektedir.

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

Çalışmada, Akarteks, Fella ve Arıkbey Tekstil firmalarından elde edilen gerçek zamanlı üretim verileri kullanılmıştır. Hazır giyim endüstrisinde makine verimliliği üzerine yapılan mevcut çalışmaların büyük çoğunluğu, kronometraj, iş örnekleme veya "Adam-Makine Şemaları" gibi geleneksel endüstri mühendisliği araçlarına dayanmaktadır. Bu yöntemler, mevcut durumun fotoğrafını çekmekte (deskriptif analiz) başarılı olsa da, karmaşık veriler arasındaki gizli örüntüleri keşfetmekte ve "gelecekteki

olası senaryoları" tahmin etmekte yetersiz kalabilmektedir. Ayrıca, operasyonel verilerin genellikle sınırlı zaman aralıklarında toplanabilmesi, istatistiksel olarak genellenebilir modellerin kurulmasını zorlaştırmaktadır. Bu çalışmayı literatürdeki benzerlerinden ayıran temel özgün değer, geleneksel verimlilik analizini modern veri bilimi teknikleriyle birleştiren hibrit bir metodoloji sunmasıdır. Çalışma kapsamında sadece mevcut verimlilik (OEE) ölçülmekle kalmamış; gerçek üretim verilerinin istatistiksel dağılımları temel alınarak sentetik veri üretimi (synthetic data generation) gerçekleştirilmiştir. Bu yaklaşım sayesinde, sınırlı sayıdaki gözlemden yola çıkılarak 1000 satırlık genişletilmiş bir veri seti oluşturulmuş ve makine öğrenmesi algoritmaları (Random Forest) için eğitilebilir bir zemin hazırlanmıştır. Böylece çalışma, verimlilik kayıplarının sadece "ne kadar" olduğunu değil, değişkenler arasındaki karmaşık ilişkileri analiz ederek "neden" olduğunu (Kök Neden Analizi) yüksek doğrulukla (%99 R² Skoru) tahmin edebilen bir model ortaya koymuştur. Ek olarak, K-Means kümeleme algoritması ile firmaların performans sınıfları (A, B, C) otomatik olarak belirlenmiş ve simülasyon teknikleri kullanılarak "rulo değişim süresindeki iyileşmenin toplam verimliliğe marjinal etkisi" sayısal olarak öngörülmüştür. Bu yönüyle çalışma, tekstil endüstrisinde "pasif izleme"den "kestirimci analitiğe" geçiş için somut bir uygulama örneği teşkil etmektedir.

Önemli Noktalar (Highlights)

- **Gizli Kapasite:** Hazır giyim kesimhanelerinde otomatik serim makinelerinin teorik hızları ile gerçekleşen verimlilik arasındaki fark, hazırlık süreleri ve plansız duruşlar nedeniyle ortaya çıkan ve operasyonel optimizasyonla açığa çıkarılması gereken "Gizli Kapasite"yi işaret etmektedir.
- **Optimizasyonun Önceliği:** Serim makinesi verimliliğini artırmak, makinenin mekanik hızını yükseltmekten ziyade, rulo değişimi gibi kesim dışı operasyonların süresini SMED gibi tekniklerle kısaltmaya ve hammadde kaynaklı duruşları akıllı sistemlerle önlemeye bağlıdır.
- **Hibrit Analitik Yaklaşım:** Çalışma, geleneksel OEE analizini Makine Öğrenmesi (Random Forest) ve Sentetik Veri Üretimi ile birleştirerek, verimlilik kayıplarının nedenlerini yüksek doğrulukla tahmin eden ve iyileşmelerin etkisini sayısal olarak öngören hibrit bir metodoloji sunmaktadır.

3. MATERYAL VE YÖNTEM (MATERIALS AND METHODS)

Bu bölümde, araştırmanın temelini oluşturan veri setinin kaynağı, kapsamı ve çalışma kurgusu detaylandırılacaktır. Araştırma metodolojisi, hazır giyim üretim sahasından elde edilen gerçek zamanlı verilerin, geleneksel endüstri mühendisliği teknikleri ve modern veri bilimi algoritmaları ile hibrit bir yapıda analiz edilmesine dayanmaktadır. Çalışmanın genel model mimarisi ve veri akış şeması Şekil 1'de sunulmuştur.



Şekil 1. Tekstil üretiminde verimlilik ve gizli kapasite analizi model mimarisi

(Figure 1. Model architecture for efficiency and hidden capacity analysis in textile manufacturing)

3.1. Veri Toplama ve Örneklem (Data Collection and Sampling)

Bu çalışma, Türkiye'de hazır giyim sektöründe faaliyet gösteren üç farklı üretici firmanın kesimhane departmanlarında gerçekleştirilmiştir. Araştırmanın evrenini, yüksek hacimli üretim yapan işletmelerdeki otomatik serim süreçleri oluşturmaktadır. Çalışma örnekleme, operasyonel dinamikleri ve verimlilik seviyeleri birbirinden farklılık gösteren Akarteks (4 farklı işletme ünitesi), Fella Tekstil ve Arıkbey Tekstil (2 farklı işletme ünitesi) olmak üzere toplam 7 farklı üretim hattını kapsamaktadır. İncelenen tüm hatlarda, kumaşın gerilimsiz ve hizalı bir şekilde kesime hazırlanmasını sağlayan endüstriyel tip Otomatik Serim Makineleri (Automatic Spreading Machines) kullanılmaktadır. Veri toplama sürecinde, makinelerin anlık performans göstergeleri ve operasyonel çıktıları gerçek zamanlı olarak kayıt altına alınmıştır. Her bir makine ve üretim partisi için toplanan temel veri setleri şunlardır:

- **Makine Kinematikiği:** Ortalama serim hızı (m/dk).
- **Operasyonel Parametreler:** Pastal boyu (m), kat sayısı (ply count) ve toplam serilen metraj.
- **Zaman Verileri:** İşlemin tamamlanması için gereken ideal süre ile duruşlar dahil gerçekleşen fiili süre (dk).
- **Verimlilik Göstergeleri:** Toplam duruş sayısı, duruş nedenleri (Rulo değişimi, kumaş hatası, pastal ayarı) ve hesaplanan verimlilik oranları (%).

Örneklem grubunda yer alan işletmelerin performans çeşitliliği (Benchmark seviyesinden operasyonel sorunlu seviyeye kadar), çalışmanın hem "en iyi uygulamaları" (best practices) hem de "iyileştirmeye açık alanları" tespit etmesine olanak tanımıştır.

3.2. Analiz Yöntemi (Analysis Method)

Çalışmanın ilk aşamasında, serim makinelerinin mevcut performansını nicel olarak değerlendirmek amacıyla Phakphonhamin (2018) tarafından LECTRA otomatik kesim makinesi optimizasyonunda kullanılan "Adam-Makine Şeması" (Man-Machine Chart) ve "Kayıp Zaman Analizi" metodolojisi temel alınmıştır [21]. Bu yaklaşım, üretim sürecini operatör ve makine aktiviteleri olarak ayrıştırarak, katma değer

yaratmayan duruşların (Non-Value Added Time) tespit edilmesini sağlamaktadır. Analiz süreci, makinenin kesintisiz çalışması gereken süreler ile operasyonel nedenlerle durduğu anların kıyaslanmasına dayanmaktadır. Çalışmada, makine verimliliğini düşüren temel kayıp kalemleri üç ana kategoride sınıflandırılmıştır:

- **Rulo Değişim Kayıpları:** Yeni kumaş topunun yüklenmesi ve sisteme tanıtılması sırasında geçen süreler.
- **Malzeme Kaynaklı Kayıplar:** Kumaş üzerindeki yırtık, delik veya ton farkı gibi hataların operatör tarafından manuel olarak **düzeltilmesi veya ayıklanması sırasında oluşan duruşlar.**
- **Pastal Ayar Kayıpları:** Operatörün pastal başı ve sonu ayarlarını yaparken makineyi beklettiği süreler.

Gizli Kapasiteyi (Hidden Capacity) ortaya çıkarmak için, her bir serim görevi (job) için teorik olarak olması gereken süre (İdeal Süre) ile sahada ölçülen süre (Gerçek Süre) karşılaştırılmıştır.

- **İdeal Süre:** Makinenin teknik özellikleri ve iş emri parametreleri (pastal boyu ve kat sayısı) dikkate alınarak hesaplanan, hiçbir duruşun yaşanmadığı teorik minimum süredir. Hesaplama mantığı aşağıdaki gibidir:

$$T_{ideal} = \frac{L_{pastal} \times N_{kat}}{V_{ortalama}} \quad (1)$$

Burada L_{pastal} pastal boyunu (metre), N_{kat} kat sayısını ve $V_{ortalama}$ ise makinenin o iş emri için ayarlanan ortalama hızını (m/dk) ifade etmektedir.

- **Gerçek Süre ($T_{gerçek}$):** İş emrinin başladığı andan bittiği ana kadar geçen, tüm planlı ve plansız duruşları (rulo değişimi, arıza, mola vb.) içeren toplam operasyon süresidir.

Bu iki değer arasındaki fark, işletmenin o iş emrindeki verimsizliğini ve potansiyel üretim kaybını (Kaybedilen Metraj) ortaya koymaktadır.

3.3. Hesaplama Metrikleri (Calculation Metrics)

Serim makinelerinin performansını standardize etmek ve farklı işletmeler arasında objektif bir kıyaslama yapabilmek adına aşağıdaki temel performans göstergeleri (KPI) tanımlanmış ve hesaplanmıştır. İşletmenin serim sürecindeki zamanı ne kadar etkin kullandığını gösteren temel metriktir. Hesaplama, hedeflenen ideal sürenin gerçekleşen toplam süreye oranı esas alınmıştır:

$$n = \left(\frac{T_{ideal}}{T_{gerçek}} \right) \times 100 \quad (2)$$

Bu formülde n yüzdesel verimliliği ifade ederken, $T_{gerçek}$ planlı ve plansız tüm duruşları içeren toplam operasyon süresini temsil etmektedir. Literatürdeki standart OEE analizlerinden farklı olarak bu çalışmada, verimsizlikten kaynaklanan üretim kaybı sadece zaman (dakika) olarak değil, "Kaybedilen Metraj" (metre) cinsinden de somutlaştırılmıştır. Bu metrik, makinenin duruşta geçirdiği süre boyunca, ortalama hızında çalışmaya devam etseydi üretebileceği potansiyel kumaş miktarını ifade eder:

$$L_{kayıp} = (T_{gerçek} - T_{ideal}) \times V_{ortalama} \quad (3)$$

Burada $V_{ortalama}$ makinenin ilgili iş emrindeki ortalama serim hızını (m/dk) göstermektedir. Bu metrik, özellikle Fella Tekstil ve Akarteks 2 örneklerinde görülen yüksek kapasite kayıplarının (sırasıyla 192.6m ve 209.9m) ekonomik boyutunun anlaşılmasında kritik rol oynamaktadır. Toplam verimsizliğin hangi faktörlerden kaynaklandığını belirlemek için, her bir duruş tipinin toplam süre içindeki ağırlığı hesaplanmıştır. Özellikle "Rulo Değişim Kaybı" (K_{rulo}), toplam işlem süresi içindeki payına göre aşağıdaki gibi formüle edilmiştir:

$$K_{rulo}(\%) = \left(\frac{T_{rulo_{değişim}}}{T_{gerçek}} \right) \times 100 \quad (4)$$

Bu hesaplama yöntemi, Pareto analizi için gerekli veri setini oluşturarak, hangi kaybın (rulo, hata veya ayar) öncelikli olarak iyileştirilmesi gerektiğini sayısal olarak ortaya koymaktadır.

3.4. Makine Öğrenmesi Modeli ve Simülasyon (Machine Learning Model and Simulation)

Geleneksel analiz yöntemleri, mevcut durumu tanımlamakta başarılı olsa da, karmaşık değişkenler arasındaki ilişkileri modellemek ve "gelecekteki potansiyel senaryoları" (what-if analysis) tahmin etmekte sınırlı kalmaktadır. Bu kısıtı aşmak amacıyla, çalışma kapsamında Python programlama dili ve Scikit-Learn kütüphaneleri kullanılarak hibrit bir makine öğrenmesi mimarisi geliştirilmiştir. Makine öğrenmesi modellerinin yüksek doğrulukla eğitilebilmesi için geniş veri setlerine ihtiyaç duyulmaktadır. Ancak saha çalışmasında elde edilen gerçek veri seti (7 farklı üretim hattı), istatistiksel olarak genellenebilir bir model kurmak için sayısal olarak yetersizdir. Bu problemi çözmek için "Sentetik Veri Üretimi" tekniği uygulanmıştır. Gerçek verilerin ortalama ve standart sapma değerleri temel alınarak, normal dağılıma uygun varyasyonlar türetilmiş ve 1000 satırlık genişletilmiş bir veri seti oluşturulmuştur. Üretilen bu veri seti, "Profil" (Operasyonel Sorunlu, Yüksek Performans vb.), "İdeal Süre", "Gerçek Süre" ve spesifik kayıp sürelerini (Rulo, Hata, Ayar) içeren çok değişkenli bir yapıya sahiptir. Verimlilik üzerindeki etki faktörlerini belirlemek ve simülasyon yapabilmek amacıyla, topluluk öğrenmesi (ensemble learning) yöntemlerinden biri olan Random Forest Regresyon algoritması kullanılmıştır.

- **Model Girdileri (Features):** Rulo Değişim Kaybı, Kumaş Hata Kaybı, Pastal Ayar Kaybı.
- **Model Çıktısı (Target):** Operasyonel Verimlilik (%).

Model eğitimi sonucunda elde edilen R^2 (Belirlilik Katsayısı) değeri 0.99 olarak hesaplanmıştır. Bu skor, modelin verimlilikteki değişimlerin %99'unu girdi değişkenleri ile açıklayabildiğini ve simülasyon çalışmaları için yüksek güvenilirliğe sahip olduğunu göstermektedir. Ayrıca, algoritmanın "Feature Importance" (Özellik Önem Düzeyi) yeteneği kullanılarak, hangi kaybın verimlilik üzerinde ne kadar etkili olduğu matematiksel olarak derecelendirilmiştir.

İşletmeleri sadece verimlilik oranlarına göre değil, kayıp karakteristiklerine göre de objektif bir şekilde gruplandırmak için denetimsiz öğrenme (unsupervised learning) yöntemi olan K-Means Clustering algoritması uygulanmıştır. Algoritma, işletmeleri benzer davranış örüntülerine göre otomatik olarak üç ana sınıfa ayırmıştır:

- **A Sınıfı (Yüksek Performans):** Düşük kayıp, yüksek verim.
- **B Sınıfı (Orta/Riskli):** İyileştirmeye açık alanları olanlar.
- **C Sınıfı (Sorunlu):** Acil müdahale gerektiren, yüksek rulo ve hata kaybına sahip işletmeler.

4. BULGULAR VE TARTIŞMALAR (FINDINGS AND DISCUSSIONS)

Bu bölümde, incelenen üretim hatlarından elde edilen operasyonel verilerin analizi sonucunda ulaşılan nicel ve nitel bulgular sunulmaktadır. Sonuçlar hiyerarşik bir yapıda; öncelikle mevcut performansın tespiti, ardından verimlilik kayıplarının kök neden analizi ve son olarak makine öğrenmesi modeli ile gerçekleştirilen gelecek senaryosu simülasyonları şeklinde ele alınmıştır.

4.1. Mevcut Durum ve OEE Analizi (Current Situation and OEE Analysis)

İncelenen 7 farklı üretim hattına ait operasyonel performans verileri, makine verimliliği ve kapasite kullanım oranları açısından işletmeler arasında belirgin farklılıklar olduğunu ortaya koymaktadır. Analiz sonuçları, çalışmanın temel veri seti olan Tablo 1'de özetlenmiştir.

Tablo 1. Gizli kapasite ve performans analizi
(Table 1. Hidden capacity and performance analysis)

Firma	Verimlilik (%)	Duruş Sayısı	Gerçek Süre (dk)	İdeal Süre (dk)	Toplam Metraj (m)	Kaybedilen Metraj (m)
Akarteks 3	26.7	0	3	12.8	21	57.7
Fella Tekstil	64.6	17	50	26.9	352	192.6
Akarteks 2	18.6	2	6	14.5	48	209.9
Akarteks 4	46.0	0	5	13.9	48	56.3
Arıkbey Tekstil 2	63.1	0	7	17.2	0	0
Arıkbey Tekstil	89.4	0	9	13.9	80	9.4
Akarteks 1	47.7	4	5	15.0	48	52.7

Elde edilen bulgulara göre, Arıkbey Tekstil %89.4'lük verimlilik oranı ile örneklem grubu içerisindeki en yüksek performansı sergilemiş ve bu çalışmada "Benchmark" (Referans İşletme) olarak konumlandırılmıştır. Bu performans, literatürdeki referans çalışmada (Phakphonhamin, 2018) hedeflenen iyileştirme sonrası değerleri dahi aşmış durumdadır. Buna karşılık, Akarteks işletmelerinde verimlilik oranlarının ciddi oranda düştüğü, özellikle Akarteks 2 işletmesinde bu oranın %18.6 seviyesinde kalarak operasyonel açıdan en sorunlu noktayı oluşturduğu görülmüştür.

Çalışmanın en kritik bulgularından biri, verimlilik yüzdelerinin tek başına kaybın büyüklüğünü ifade etmekte yetersiz kalmasıdır. OEE oranları ile birlikte "Kaybedilen Metraj" (Gizli Kapasite) verileri incelendiğinde, işletmelerin üretim potansiyellerinin ne kadarını atıl bıraktığı somutlaşmaktadır:

- **Fella Tekstil:** İşletme %64.6 gibi kabul edilebilir bir verimlilik oranına sahip olmasına rağmen, uzun operasyon süreleri ve yüksek işlem hacmi nedeniyle, tek bir iş emrinde dahi 192.6 metre kumaş serim kapasitesi kaybetmiştir. Bu durum, makinenin çalışmadığı her dakikanın, yüksek hızlı üretim yapan işletmelerde ne kadar büyük bir metraj kaybına dönüştüğünü kanıtlamaktadır.
- **Akarteks 2:** Düşük verimliliğin (%18.6) bir sonucu olarak, toplam potansiyel üretimin 209.9 metresi kaybedilmiştir. Bu kayıp, makinenin teknik kapasitesinin neredeyse tamamının katma değersiz işlere (duruşlara) harcandığını göstermektedir.


Bu veriler, sorunun sadece makineyi "daha hızlı" çalıştırmak değil, makinenin "kesintisiz" çalışmasını sağlamak olduğunu, aksi takdirde gizli kapasite kayıplarının (Akarteks 3: 57.7m, Akarteks 4: 56.3m) toplam üretim çıktısını önemli ölçüde kısıtladığını göstermektedir.

4.2. Kök Neden Analizi (Root Cause Analysis)

İşletmelerdeki verimlilik kayıplarının kaynaklarını belirlemek ve en büyük etkiye sahip faktörleri ayırtmak amacıyla Pareto analizi uygulanmıştır. Verimlilik kayıplarının nedenlerine göre dağılımı Tablo 2'de, bu nedenlerin kümülatif etkisini gösteren Pareto grafiği ise Şekil 2'de sunulmuştur.

Tablo 2. Verimlilik kayıplarının nedenlere göre dağılımı (%)
(Table 2. Distribution of efficiency losses by cause (%))

Firma	Verimlilik (%)	Rulo Değişim Kaybı (%)	Kumaş Hata Kaybı (%)	Pastal Ayar Kaybı (%)
Akarteks 3	26.7	51.1	0.0	11.1
Fella Tekstil	64.6	15.0	17.5	1.0
Akarteks 2	18.6	31.4	22.2	11.1
Akarteks 4	46.0	40.0	0.0	6.7
Arıkbey Tekstil 2	63.1	11.2	0.0	5.7
Arıkbey Tekstil	89.4	6.7	0.0	3.9
Akarteks 1	47.7	33.3	0.0	11.0



Şekil 2. Verimlilik kayıplarının kök neden analizi grafiği
(Figure 2. Root cause analysis chart of efficiency losses)

Analiz sonuçları, incelenen işletmelerin büyük çoğunluğunda en kritik darboğazın "Rulo Değişimi" (Roll Changeover) olduğunu göstermektedir. Özellikle operasyonel sorunların yoğun olduğu işletmelerde, toplam işlem süresinin yarısına yakınının sadece kumaş topunu değiştirmek için harcandığı tespit edilmiştir.

- Akarteks 3 işletmesinde toplam sürenin %51.1'i,
- Akarteks 4 işletmesinde %40.0'ı,
- Akarteks 1 işletmesinde ise %33.3'ü rulo değişim operasyonlarında kaybedilmektedir.

Bu veriler, Phakphonhamin (2018) tarafından literatürde belirtilen "makinenin hazırlık personeli beklemesi" sorununun, bu çalışma sahasında da geçerli olduğunu ve en büyük iyileştirme potansiyelinin (High Impact) bu alanda yattığını doğrulamaktadır.

Rulo değişiminin aksine, bazı işletmelerdeki temel verimlilik kaybının operasyonel yönetimden ziyade hammadde kalitesinden kaynaklandığı görülmüştür.


- Akarteks 2 işletmesinde kayıpların %22.2'si,
- Fella Tekstil'de ise %17.5'i "Kumaş Hata Kaybı" kategorisindedir.

Bu işletmelerde makine, kumaş üzerindeki yırtık, delik veya ton farkı gibi hatalar nedeniyle operatör tarafından sık sık durdurulmakta ve manuel müdahale gerektirmektedir. Bu bulgu, verimlilik probleminin tek boyutlu olmadığını; bazı hatlarda "hazırlık sürelerine" (Setup

Reduction), bazı hatlarda ise "tedarikçi kalite yönetimine" (Quality Control) odaklanılması gerektiğini ortaya koymaktadır.

4.3. Simülasyon ve Tahminleme Sonuçları (Simulation and Prediction Results)

Çalışmanın bu aşamasında, sentetik veri ile genişletilen veri seti üzerinde Makine Öğrenmesi algoritmaları çalıştırılarak, verimlilik üzerindeki etki faktörleri modellenmiş ve geleceğe yönelik iyileştirme senaryoları simüle edilmiştir. Verimlilik tahmini için eğitilen Random Forest Regresyon modeli, test verisi üzerinde $R^2=0.99$ (1.00 üzerinden) gibi oldukça yüksek bir başarı skoruna ulaşmıştır. Bu sonuç, modelin serim makinesi verimliliğindeki değişimlerin %99'unu, belirlenen üç temel kayıp faktörü (rulo, hata, ayar) ile açıklayabildiğini göstermektedir. Şekil 3 modelin "Feature Importance" (Özellik Önem Düzeyi) analiz sonuçları, verimliliği etkileyen en kritik faktörün, diğer tüm değişkenlerin önünde yer alan "Rulo Kaybı" (Roll Change Loss) olduğunu istatistiksel olarak doğrulamıştır. Bu bulgu, Pareto analizi ile elde edilen gözlemsel sonuçları algoritmik olarak desteklemektedir.




Şekil 3. Verimliliği etkileyen faktörlerin önem derecesi (kök neden analizi)

(Figure 3. Significance level of factors affecting efficiency (root cause analysis))

Modelin yüksek tahmin gücünden yararlanılarak, "Operasyonel Sorunlu" olarak tanımlanan fabrikalarda bir iyileştirme simülasyonu gerçekleştirilmiştir. Senaryo kapsamında, en büyük darboğaz olan Rulo Değişim Sürelerinde %50 oranında bir iyileştirme (örneğin SMED teknikleri ile sürenin yarıya indirilmesi) yapıldığı varsayılmıştır. Simülasyon sonuçlarına göre:

- **Mevcut Durum:** İyileştirme öncesi ortalama verimlilik %31.67 seviyesindedir.
- **İyileştirilmiş Durum:** Hazırlık süreçlerindeki %50'lik iyileştirme sonrası verimlilik %37.66 seviyesine yükselmiştir.
- **Net Etki:** Şekil 4'de sadece rulo değişim sürecine yapılan bu müdahalenin, toplam işletme verimliliğinde %5.99 puanlık net bir artış sağladığı öngörülmektedir.



Şekil 4. Simülasyon sonucu: rulo değişim sürecinde %50 iyileştirme
(Figure 4. Simulation result: 50% improvement in roll changeover process)

İşletmeleri benzer performans özelliklerine göre gruplandırmak amacıyla uygulanan K-Means kümeleme algoritması, firmaları otomatik olarak üç ana sınıfa ayırmıştır. Sınıflandırma sonuçları Tablo 3'te özetlenmiştir:

Tablo 3. Makine öğrenmesi ile firmaların performans sınıflandırması
(Table 3. Performance classification of companies using machine learning)

Performans Sınıfı	Ortalama Verimlilik (%)	Rulo Kaybı (Dk)	Hata Kaybı (Dk)	Tanım
A Sınıfı	68.68	2.25	0.81	Yüksek Performans (Benchmark)
B Sınıfı	44.58	7.63	4.50	Orta Seviye/ Riskli
C Sınıfı	23.51	12.43	3.92	Sorunlu (İyileştirme Öncelikli)

Bu sınıflandırma, Arıkbey Tekstil'in "A Sınıfı" özelliklerini (düşük rulo kaybı, yüksek verim) taşıdığını teyit ederken, Akarteks şubelerinin ağırlıklı olarak "C Sınıfı" kategorisinde yer aldığını ve rulo değişim sürelerinin (ortalama 12.43 dk) acilen iyileştirilmesi gerektiğini veriye dayalı olarak ortaya koymaktadır.

4.4. Tartışmalar (Discussions)

Bu çalışmanın en çarpıcı sonuçlarından biri, aynı teknolojik altyapıya sahip olsalar bile işletmeler arasında devasa performans farklarının bulunmasıdır. Arıkbey Tekstil, ulaştığı %89.4 verimlilik oranı ile sadece bu çalışmanın örneklem grubu içinde lider olmakla kalmamış, aynı zamanda referans alınan Phakphonhamin (2018) çalışmasındaki hedef değerleri de geride bırakmıştır. Arıkbey işletmesinde rulo değişim kayıplarının %6.7 gibi oldukça düşük bir seviyede tutulabilmesi, serim operasyonlarında yüksek verimliliğin "teknik bir şans" değil, bilinçli bir "süreç yönetimi başarısı" olduğunu kanıtlamaktadır. Bu durum, Arıkbey modelinin sektördeki diğer firmalar (özellikle Akarteks şubeleri) için ulaşılabilir bir "En İyi Uygulama" (Best Practice) örneği teşkil ettiğini göstermektedir. Sektördeki yaygın kanının aksine, bu çalışma makine hızının (m/dk) artırılmasının doğrudan verimlilik artışı sağlamadığını ampirik verilerle ortaya koymuştur.

Örneğin, dakikada 9.60 metre ile en yüksek hıza sahip olan Akarteks 1 ve 4 işletmeleri, yüksek duruş süreleri nedeniyle %46-47 bandında bir verimlilikte kalmıştır. Buna karşılık, 7.04 m/dk gibi daha düşük bir hızla çalışan Fella Tekstil, operasyonel sürekliliği (daha az duruş, daha uzun pastallar) sayesinde %64.6 verimliliğe ulaşabilmiştir. Bu bulgu, işletmelerin odak noktasını "makineyi hızlandırmaktan" ziyade "makineyi durdurmamaya" kaydırması gerektiğini işaret etmektedir. Özellikle Fella Tekstil örneğindeki uzun operasyon sürelerine rağmen yaşanan 192.6 metrelik gizli kapasite kaybı, problemin sadece hızla değil, süreç yönetimiyle (hata giderme, rulo değiştirme) ilgili olduğunu doğrulamaktadır.

Makine öğrenmesi modelinin (Random Forest) çıktıları, verimlilik üzerindeki en baskın faktörün "Rulo Değişim Kaybı" olduğunu belirlemiştir. Akarteks 3 işletmesinde toplam sürenin yarısından fazlasının (%51.1) bu sürece harcanması, literatürdeki "hazırlık personeli beklemesi" sorunuyla tam bir örtüşme içerisindedir. Çalışma kapsamında gerçekleştirilen simülasyon, rulo değişim süreçlerinde yapılacak %50'lik bir iyileştirmenin, genel verimlilikte yaklaşık 6 puanlık (net %20'ye yakın oransal artış) bir kazanç sağlayacağını öngörmektedir. Bu sonuç, işletmelerin yeni makine yatırımı yapmadan önce, mevcut makinelerindeki hazırlık sürelerini minimize edecek SMED (Single Minute Exchange of Die) tekniklerine, demetleme sistemlerine veya ekstra hazırlık personeli istihdamına yönelmelerinin maliyet-etkin bir çözüm olduğunu bilimsel olarak desteklemektedir.

5. SONUÇ VE ÖNERİLER (CONCLUSION AND RECOMMENDATIONS)

Bu çalışma, hazır giyim üretiminde kesimhane verimliliğinin, teknolojik yatırımdan ziyade operasyonel süreç yönetimine bağlı olduğunu nicel verilerle ortaya koymuştur. Farklı işletmelerden elde edilen verilerin Makine Öğrenmesi (Random Forest) destekli analizi sonucunda ulaşılan temel çıkarımlar şunlardır:

- **Hız-Verimlilik Paradoksu:** Yüksek makine hızlarına (9.60m/dk) sahip işletmelerin, yüksek duruş süreleri nedeniyle düşük verimlilik (%46) seviyelerinde kalabilmesi; verimliliğin "hız" ile değil, "süreklilik" ile sağlandığını kanıtlamıştır.
- **Gizli Kapasitenin Büyüklüğü:** Düşük OEE oranları, işletmelerde ciddi boyutlarda "Gizli Kapasite" oluşumuna neden olmaktadır. Tek bir iş emrinde dahi 200 metreyi aşan üretim kayıpları, maliyetleri doğrudan etkilemektedir.
- **Temel Darboğaz:** Verimlilik önündeki en büyük engel, makine arızaları değil, toplam sürenin %50'sine varan "Rulo Değişim Süreleri"dir.
- **Modelin Güvenilirliği:** Geliştirilen Random Forest modeli %99 doğruluk oranı ile çalışmış ve rulo değişim süreçlerindeki iyileştirmelerin toplam verimliliğe marjinal katkısını başarıyla simüle etmiştir. Elde edilen bulgular ve "Benchmark" işletme (Arıkbey Tekstil - %89.4 Verimlilik) pratikleri ışığında, sektör yöneticilerine aşağıdaki iyileştirme adımları önerilmektedir:
- **SMED (Single Minute Exchange of Die) Uygulaması:** Rulo değişim sürelerinin minimize edilmesi için SMED teknikleri serim makinelerine uyarlanmalıdır. Operatör makine çalışırken bir sonraki kumaş topunu hazırlamalı (Dış Hazırlık) ve makine duruşu sadece rulo takma işlemi (İç Hazırlık) ile sınırlandırılmalıdır.
- **Destek Personel İstihdamı:** Simülasyon sonuçları, hazırlık süresinin yarıya inmesinin verimliliği %6 artırdığını göstermektedir. Bu artışın getireceği üretim kazancı, rulo taşıma

ve ön hazırlık için istihdam edilecek ekstra bir personelin maliyetini fazlasıyla karşılayacaktır.

- **Kalite Kontrolün Öne Çekilmesi:** Fella Tekstil örneğinde görülen malzeme kaynaklı duruşları önlemek için, kumaş kontrolü serim makinesinde değil, kumaş depoya giriş aşamasında (kumaş kontrol makinelerinde) yapılmalı ve hatalı toplar hata haritası ile birlikte hatta verilmelidir.

Bu çalışma, sınırlı bir zaman dilimindeki veriler ve sentetik veri artırma yöntemi ile gerçekleştirilmiştir. Gelecek araştırmalarda, IoT (Nesnelerin İnterneti) sensörleri kullanılarak serim makinelerinden anlık ve büyük veri (Big Data) toplanması, modelin genellenebilirliğini artıracaktır. Ayrıca, geliştirilen yapay zeka modelinin sadece serim değil, kesim (cutter) ve dikim bantlarına da entegre edilerek "Uçtan Uca Kesimhane Optimizasyonu" sağlanması önerilmektedir.

İŞBİRLİĞİ (COOPERATION)

Bu makale Üniversite-Sanayi İşbirliği çalışması olup, SERKON Makina San. ve Tic. A.Ş. (İstanbul) tarafından yürütülen "Serim Makineleri için Performans Tabanlı Verimlilik Ölçümü ve Analizi" Ar-Ge projesi kapsamında geliştirilen serim verimliliğini ölçmeye yönelik bir performans analizi çalışmasından üretilmiştir.

FİNANSAL AÇIKLAMA (FINANCIAL DISCLOSURE)

Yazarlar bu çalışma için herhangi bir mali destek almadığını beyan etmiştir.

ETİK STANDARTLAR BEYANI (DECLARATION OF ETHICAL STANDARDS)

Makalenin yazarları bu çalışmada kullanılan materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel izin gerektirmediğini beyan eder.

KAYNAKLAR (REFERENCES)

- [1] Corrales, L., Lambán, M., Korner, M., and Royo, J., (2020). Overall equipment effectiveness: systematic literature review and overview of different approaches. Applied Sciences. <https://doi.org/10.3390/app10186469>.
- [2] Sathler, K., Salonitis, K., and Kolios, A., (2023). Overall equipment effectiveness as a metric for assessing operational losses in wind farms: a critical review of literature. International Journal of Sustainable Energy, 42:374-396. <https://doi.org/10.1080/14786451.2023.2189490>.
- [3] Pitoyo, D., Azwar, A., and Aprilia, A., (2024). Optimizing Operations: Evaluating Overall Equipment Effectiveness (OEE) And Failure Mode Effect Analysis (FMEA) For Muratec Qpro Ex Winding Machines at PT XYZ. Journal of Physics: Conference Series, 2928. <https://doi.org/10.1088/1742-6596/2928/1/012013>.
- [4] Cao, Y., Kamaruzzaman, S., and Aziz, N., (2022). Green building construction: a systematic review of BIM utilization. Buildings. <https://doi.org/10.3390/buildings12081205>.
- [5] Deng, L., Suo, H., and Ren, H., (2021). Design of Insulation Tape Tension Control System of Transformer Winding Machine Based on Fuzzy PID. Sensors (Basel, Switzerland), 21. <https://doi.org/10.3390/s21196512>.
- [6] Meng, Y., Zhang, T., Wei, J., Zhang, J., and Zhai, X., (2023). Design and experiments of an automatic pipe winding machine. Journal of Agricultural Engineering. <https://doi.org/10.4081/jae.2023.1429>.
- [7] Mewada, H., Pires, I., Engineer, P., and Patel, A., (2024). Fabric surface defect classification and systematic analysis

- using a cuckoo search optimized deep residual network. *Engineering Science and Technology, an International Journal*. <https://doi.org/10.1016/j.jestch.2024.101681>.
- [8] Metin, A. and Bilgin, T., (2024). Automated machine learning for fabric quality prediction: a comparative analysis. *PeerJ Computer Science*, 10. <https://doi.org/10.7717/peerj-cs.2188>.
- [9] Malashin, I., Martysyuk, D., Tynchenko, V., Gantimurov, A., Nelyub, V., Borodulin, A., and Galinovsky, A., (2025). Machine Learning in Polymeric Technical Textiles: A Review. *Polymers*, 17. <https://doi.org/10.3390/polym17091172>.
- [10] Bukhsh, M., Khan, M., Zaidi, I., Yaseen, R., Khalid, A., and Ali, M., (2021). Productivity Improvement in Textile Industry using Lean Manufacturing Practices of 5S and Single Minute Die Exchange (SMED). *Proceedings of the International Conference on Industrial Engineering and Operations Management*. <https://doi.org/10.46254/an11.20211282>.
- [11] Vargas-Tapia, K., Amiel-Reategui, G., and Viacava, G., (2022). Increase the efficiency of the production process of machines in textile and clothing companies through a model based on TPM and SMED. *Proceedings of the 20th LACCEI International Multi-Conference for Engineering, Education and Technology*. <https://doi.org/10.18687/laccei2022.1.1.752>.
- [12] Toki, G., Ahmed, T., Hossain, M., Alave, R., Faruk, M., Mia, R., and Islam, S., (2023). Single Minute Exchange Die (SMED): A sustainable and well-timed approach for Bangladeshi garments industry. *Cleaner Engineering and Technology*. <https://doi.org/10.1016/j.clet.2022.100592>.
- [13] Wisetwoharn, P., Vanichchinchai, A., Sumrit, D., and Kitchot, S., (2025). Setup Time Reduction: A Case Study of a Wire Coating Extruder Machine. *Key Engineering Materials*, 1012:101-105. <https://doi.org/10.4028/p-mwwj48>.
- [14] Niekurzak, M., Lewicki, W., Coban, H., and Bera, M., (2023). A Model to Reduce Machine Changeover Time and Improve Production Efficiency in an Automotive Manufacturing Organisation. *Sustainability*. <https://doi.org/10.3390/sul51310558>.
- [15] Aucasime-Gonzales, P., Tremolada-Cruz, S., Chavez-Soriano, P., Dominguez, F., and Raymundo, C., (2020). Waste Elimination Model Based on Lean Manufacturing and Lean Maintenance to Increase Efficiency in the Manufacturing Industry. *IOP Conference Series: Materials Science and Engineering*, 999. <https://doi.org/10.1088/1757-899x/999/1/012013>.
- [16] Wang, G., Liu, G., and Li, Q., (2023). Knowledge Graph-Embedded Time-Serial-Data-Driven Bottleneck Analysis of Textile and Apparel Production Processes. *Machines*. <https://doi.org/10.3390/machines11111005>.
- [17] Wang, C. and Kuo, C., (2023). Detecting dyeing machine entanglement anomalies by using time series image analysis and deep learning techniques for dyeing-finishing process. *Adv. Eng. Informatics*, 55, 101852. <https://doi.org/10.1016/j.aei.2022.101852>.
- [18] Elkateb, S., Métwalli, A., Shendy, A., and Abu-Elanien, A., (2024). Machine learning and IoT - Based predictive maintenance approach for industrial applications. *Alexandria Engineering Journal*. <https://doi.org/10.1016/j.aej.2023.12.065>.
- [19] Bertola, N., Reuland, Y., and Brühwiler, E., (2023). Editorial: Structural sensing for asset management. *Frontiers in Built Environment*, 9. <https://doi.org/10.3389/fbuil.2023.1164719>.



-
- [20] Scherlach, K. and Hertweck, C., (2021). Mining and unearthing hidden biosynthetic potential. *Nature Communications*, 12. <https://doi.org/10.1038/s41467-021-24133-5>.
- [21] Phakphonhamin, V. and Chudokmai, M., (2018, May). Optimizing the performance of the LECTRA automatic fabric cutting machine. In *2018 5th International Conference on Business and Industrial Research (ICBIR)* (pp:282-287). IEEE. <https://doi.org/10.1109/ICBIR.2018.8391207>.