



Research Article

# Makine Öğrenme Tabanlı Görüntü İşleme Teknikleri ile Ekipman Durumu ve Verimlilik Tespiti Sağlayan Yeni Bir Otomasyon Sistemi

Yunus Emre Yurdağül<sup>1</sup>, Okan Vural<sup>2</sup>, Kaan Çelik<sup>3</sup>, Haluk Atli<sup>4</sup>, Murat Sağlam<sup>5</sup>

<sup>1</sup> Supply Chain Wizard Teknoloji LTD. ŞTİ. Ar-Ge Merkezi, İzmir, Türkiye, yunusemre.yurdagul@scw.ai, Orcid Id: 0000-0003-0639-1922

<sup>2</sup> Supply Chain Wizard Teknoloji LTD. ŞTİ. Ar-Ge Merkezi, İzmir, Türkiye, okan.vural@scw.ai, Orcid Id: 0000-0003-1643-5917

<sup>3</sup> Supply Chain Wizard Teknoloji LTD. ŞTİ. Ar-Ge Merkezi, İzmir, Türkiye, kaan.celik@scw.ai, Orcid Id: 0000-0001-7565-6555

<sup>4</sup> Supply Chain Wizard Teknoloji LTD. ŞTİ. Ar-Ge Merkezi, İzmir, Türkiye, haluk.atli@scw.ai, Orcid Id: 0000-0003-0639-1922

<sup>5</sup> Supply Chain Wizard Teknoloji LTD. ŞTİ. Ar-Ge Merkezi, İzmir, Türkiye, murat.saglam@scw.ai, Orcid Id: 0000-0001-8766-3883

\*sorumlu yazar: haluk.atli@scw.ai

(First received September 23, 2022 and in final form December 21, 2022)

**Reference:** Yurdağül Y. E., Vural O., Çelik, K., Atli, H., Sağlam M. Makine Öğrenme Tabanlı Görüntü İşleme Teknikleri ile Ekipman Durumu ve Verimlilik Tespiti Sağlayan Yeni Bir Otomasyon Sistemi. Orclever Proceedings of Research and Development,1(1), 38-44.

## Özet

Üretim endüstrisinde genel ekipman verimliliği (OEE), üretim süreçlerinin takibi ve geliştirilmesi için gerekli bir parametredir [Nakajima,1988]. OEE hesabının yapılıp karar destek sistemlerine bağlanabilmesi için temelde sahadaki üretim hattının anlık durumunun sağlıklı şekilde sayısal hale getirilip verileştirilmesi vardır. Bu bağlamda geliştirdiğimiz 'Görüntü İşleme ve İleri Analitik Yöntemler Tabanlı Otomatik Makine Durumu ve Verimliliği Tespit Sistemi' çözümü, endüstride verimlilik takibi ve veri güdümlü karar verebilmek için gerekli olan üretim hattı durumu ve OEE verisinin ideal bir şekilde toplanabilmesine olanak sağlamaktadır. Mevcut çözümlerde bulunan sorunlar, video görüntü işleme ve derin öğrenme / makine öğrenmesi gibi ileri analitik yöntemler ile aşılmıştır. Video verilerinde nesne tespiti problemin çözümü için literatürde geleneksel görüntü işleme yaklaşımlarını [Dalal, 2005] veya makine öğrenmesi



yöntemlerini [Felzenszwalb, 2010] kullanan çok sayıda çözüm mevcuttur. Son yıllarda derin öğrenme yöntemleri nesne tespiti de başarılı sonuçlar vermiştir [Girshick, 2014]. Bu ileri yöntemlerin kullanımı ile sunduğumuz çözümün yenilikçi yönü, her üretim hattı için farklı olabilecek örüntüleri kendi kendine öğrenen, yani üretim hattı durumunu otomatik kestiren bir sistem olmasıdır.

**Anahtar Sözcükler:** Derin Öğrenme, Görüntü İşleme, Makine Öğrenmesi, OEE.

## A New Automation System for Equipment Status and Efficiency Detection with Machine Learning Based Image Processing

### Abstract

*Overall equipment effectiveness (OEE) is a necessary metric for monitoring and improving production processes in industry [Nakajima, 1988]. In order to make the OEE calculation properly, one needs to digitize the accurate data coming from the production line on the shopfloor, which is a challenge itself. The solution we present provides the accurate collection of production line status and OEE data required for monitoring and decision making. The problems found in existing solutions are overcome with advanced analytical methods such as video image processing and deep learning / machine learning. There are many solutions in the literature using traditional image processing approaches [Dalal, 2005] or machine learning methods [Felzenszwalb, 2010] to solve the object detection problem in the video. In recent years, deep learning methods have also yielded successful results in object detection [Girshick, 2014]. The innovative aspect of the solution we offer is that it is a system that learns patterns that may be different for each production line, and automatically predicts the production line status.*

**Keywords:** Deep Learning, Video Processing, Machine Learning, OEE.

### 1. Giriş

Endüstride bir hattın verimli ve kaliteli üretim yapacak şekilde çalışır durumda olması, planlı ya da plansız nedenlerle hat durma süresinin minimuma indirilmesi ile mümkündür. Bu hedefe üretim hattının durumunu temsil eden verilerin doğru bir şekilde toplanması ile ulaşılabilir. Bu noktada, sahadan verinin uygun maliyetle, yaygın şekilde ve kaliteli (doğru) toplanabilmesi husuları öne çıkmaktadır. Sunduğumuz çözümde, üretim sahasındaki makinelerin üretim durumunu gösteren görsel işaretler (sinyal kuleleri) görüntü işleme ve makine öğrenmesi teknolojileri ile yorumlanarak, üretim hattının analizini sağlayan yapay zeka tabanlı bir yazılım geliştirilmiştir.



## 2. Amaç

### 2.1. Mevcut uygulamaların eksiklikleri ve yetersizlikleri

Hat durumu verisinin doğru, ekonomik ve ölçeklenebilir şekilde toplanabilmesine engel olan problemler aşağıda listelenmiştir: **(1) Maliyet:** Piyasada önerilen mevcut sistemler yüksek maliyetli cihaz entegrasyonu (örn. Programmable Logic Controller [PLC] entegrasyonu) gerektirmektedir. PLC entegrasyonu üretim hattındaki tüm makine bileşenlerine tek tek elektriksel bağlantı yapma ya da yazılım katmanında her bir makinenin protokolünü anlayan uyumlu karşı yazılımı geliştirmeye tekabül eder. Ancak bu şekilde maliyetli entegrasyonlar sonucunda veri çeşitliliği ve kalitesine ulaşılabilmektedir. **(2) Ölçeklenebilirlik:** Bir üretim firması maliyetli entegrasyon yapsa dahi uygulanan çözüm değişen protokoller, marka model çeşitliliği düşünüldüğünde üretim hattını oluşturan her bileşen makina için sil baştan tekrar edilmelidir. **(3) Veri Kalitesi:** Maliyet problemini aşmaya çalışan alternatif çözümler ise entegrasyon olmadan bir arabirim vasıtası ile operatörden veri toplayarak hat durumu hakkında veri elde edebilir. Ancak insana bağımlı operatör veri girişi hata ve sapmalara açıktır.

### 2.2. Ortaya konulan çözümün amacı

Sağladığımız “Görüntü İşleme ve İleri Analitik Yöntemler Tabanlı Otomatik Makine Durumu ve Verimliliği Tespit Sistemi”, firmalarının üretim hattı durumunun, yani OEE verisinin, verimli şekilde toplanabilmesine olanak sağlayan mevcut çözümlerin aksine, maliyet düşüklüğü, ölçeklenebilirlik ve veri kalitesi anlamında öne çıkmaktadır. Konvansiyonel yüksek efor/maliyet/zaman gerektiren PLC entegrasyonu benzeri uygulamaların aksine, yenilikçi olarak “görüntü işleme”, “makine öğrenmesi” (spesifik olarak “derin öğrenme”) yöntemleri kullanılmaktadır. “Öğrenebilen” sistem, operatör hatalarından bağımsız, ölçeklenebilir ve veri güdümlü karar sistemlerini besleyebilecek inovatif bir çözümdür.

## 3. Materyal ve Yöntem

### 3.1 Endüstriyel üretim hatlarından IP kamera ile video bazlı veri toplama

Üretim hattının bulunduğu ortama yerleştirilen geniş açılı, yüksek çözünürlüklü IP kamera sayesinde üretim ortamı sürekli olarak izlenmektedir. Yerleştirilen bu kamera sayesinde üretim ortamından elde edilen gerçek-zamanlı video verisi görüntü işleme ve makine öğrenmesi yöntemleri kullanılarak üretim hattının durumu, örn. üretme modu, atıl durumda duruş, arıza kaynaklı duruş gibi oluşan durumlar ve hattı oluşturan alt makinelerin durum tespiti yapılmaktadır.



### 3.2 Veri etiketleme ve işaret kulelerinin tespiti

Anlamalı görsel işaretin videonun hangi bölgesinde olduğunun sağlıklı tespiti için, operatör video kayıtlarında sinyal kulelerini içine alan ilgi alanlarını (region-of-interest) seyrek aralıklarla (örn. günde 1 defa) işaretleyerek (dikdörtgen içine alarak) sisteme veri eklemektedir. Üretilen bu etiketli veri, görüntü işleme ve makine öğrenmesi temelli çözümlerin geliştirilmesi için kullanılmaktadır. Bu aşamada: Video verisinden sinyal kulelerinin otomatik tespiti derin öğrenme ile gerçekleştirilmektedir. Tespit edilmiş sinyal kulesi ilgi alanları kullanılarak video çerçevelerinden (frame) ışık bilgisi elde edilmektedir. Her sinyal kulesine ait ışık bilgisi zaman-serisine çevrilerek çok-kanallı zaman-serisi üzerinde makine öğrenmesi/derin öğrenme kullanılarak arızanın üretim hattının hangi makinesinde oluştuğu belirlenmektedir. Bu çerçevede sinyal kulelerinin otomatik tespiti için bölge temelli evrimsel sinir ağları (region-based convolutional neural networks) ve YOLO (You Only Look Once) gibi derin öğrenme mimarilerinden faydalanılmıştır. Bu mimarilerin problemimize uyarlanması için öğrenme aktarımı (transfer learning) yaklaşımı kullanılmış ve mimarilerin ilk katmanlarına ait ağırlık değerleri sabit tutularak sadece son katmanları etiketli verimiz ile eğitilmiştir. Derin öğrenme mimarisinin çıktısı, video verisinde sinyal kulelerinin yerlerini belirten ilgi alanlarıdır (region-of-interest).

### 3.3 Hat durumunu temsil eden zaman serisi oluşturma

Sinyal kulesi tespiti sayesinde elde edilen ilgi alanları kullanılarak her bir video çerçevesinde sinyal kulelerinin sinyalizasyon/rek bilgisi çıkarılmaktadır. Bu amaçla ilgi alanı içine düşen piksellerin renk dağılımları renk histogramı kesişimi (color histogram intersection), renk eş-oluşum matrisi (color co-occurrence matrix), baskın renk temsili gibi çeşitli görüntü işleme yaklaşımları RGB, HSV gibi farklı renk uzaylarında koşturulmaktadır ve en iyi yaklaşım kullanılarak sinyal kulelerindeki renkler tespit edilmektedir (örn. bkz Fig 1). Çok-kanallı zaman-serisinden hangi anda hangi makinede arıza olduğunun tespitini gerçekleştirebilmek için operatör tarafından etiketlenmiş veriyi kullanarak hem geleneksel makine öğrenmesi yaklaşımlarının hem de derin kalıntı ağları (deep residual networks), uzun kısa-süreli bellek (long short-term memory) gibi verideki zamansal bağlantılılıktan (temporal coherence) faydalanan derin öğrenme yaklaşımları kullanılmaktadır.

### 3.4 Kullanılan Veri Seti

Kullandığımız veri seti iki farklı kategoriye ayrılmaktadır:

**Görüntü verisi:** Kullanılan video, saniyede 30 çerçeve olmak üzere toplam 8 saat 56,6 dakikadır. Bütün veri seti  $[(8*60)+56,6]*60=32197$  çerçevedir. Kamera hattın

makinelere bağı olan 6 ışık kulesini gözlemleyecek şekilde konumlandırılmıştır. Işık kuleleri, 9 saatlik bu video üzerinde, saniyede bir çerçeve örneklenecek şekilde sırasıyla YOLO ve DeepSORT modelleriyle tespit edilmiştir. Takip edilen kuleler bir renk aralıklandırma algoritmasıyla 1 saniye aralıklı, 8 saniyelik sliding window zaman serisine dönüştürülmüştür.

**Hat Durum Kestirimi İçin Etiket Verisi:** Hat durum kestirimi safhasında, eğitimi ve testi gerçekleyebilmek adına, hat durum etiketleri toplanmıştır. Bunun için, hat operatörlerinden, hattın durum etiketlerini doğru zamanda, doğru bir şekilde işlenmesi istenmiştir. Elde edilen veri setinde, ortalama 25,5 dakikalık aralıklı, toplamda 21 farklı hat durumu değişimi mevcuttur.

#### 4. Bulgular




**Şekil 1:** Üretim hattı video kaydından bir kesit. Hattaki sinyal kuleleri algoritma tarafından tespit edilmiş aynı zamanda hat durumu kulelerin sağladığı sayısal veri derin öğrenme modeli tarafından skorlanarak doğru şekilde kesitirilmiştir.


##### 4.1 Makine Öğrenmesi Uygulamaları

GRU makine öğrenme algoritması, veri seti %67 eğitim ve %33 test olacak şekilde rastgele bölünerek saha verisi üzerinde uygulanmıştır. Bu bağlamda modelin

öğreniminde ayarlama yapılan hiper parametreleri şöyle listenebilir: Epoch, Batch Size, Hidden Layer Sayısı, Hidden Layer Aktivasyon Fonksiyonu. Bu hiper parametre denemeleri sırasında en iyi sonuçlardan birini veren parametre seti de aşağıdaki gibidir: Epoch: 300, Batch Size: 256, Hidden Layer Sayısı: 3, Aktivasyon Fonksiyonu: ReLu. Bu parametre setiyle eğitilen modelin testte gösterdiği performans metrikleri şöyledir: Doğruluk: 0.9809 Duyarlılık: 0.9545. Bu performansı temsil eden karışıklık matrisi ise **Figür 2A**'da görülebilir. Modelin performansının bu hiper parametrelerdeki değişimlerden nasıl etkilendiğini gözlemlemek amaçlı bir çalışma yapılmıştır. **Figür 3**'te hiper parametre setindeki parametrelerden her birinin izole değişiminin Doğruluk ve Duyarlılık ölçütlerine karşı grafikleri görülebilir.



**Şekil 2:** A) GRU performans matrisi B) Noise-injection analizi



**Şekil 3:** GRU: Hiper parametre setindeki elemanların izole edilmiş şekilde Doğruluk ve Duyarlılık ölçütlerine karşı grafikleri

## 5. Sonuçlar ve Öneriler

Elde edilen sonuçlar 4 ana başlıkta toplanabilir:

Makine öğrenmesi modelinin video verisi üzerinde görsel belirteç ilgi alanlarını tutarlı tespiti için yapılan saha uygulamalı denemelerde, 6 kulenin minimum 4'ünün



rastgele seçilen 500 çerçeve içerisinde tespit edilme oranı hedef olarak belirlenmiştir. 4 kulenin tespit edilebilmesi aktivite kestirimi için yeterli olduğundan, nesne tespiti için 4 kule hedef kabul edilmiştir. Sonuç olarak %90 oranında (463/500) başarı yakalanmıştır.

Görüntü işleme fazından çıkan zaman serisinin üretim hattı durumunu tutarlı kestirimi konusunda, GRU çıktıların göze alındığında %97 gibi oldukça yüksek bir başarı oranı yakalanmıştır. Bu başarı oranı, üretim hattı durumunun detay seviyede kestirimi için de geçerlidir. Detay seviye kestirimi ile ilgili 'etiketleme' sistemi geliştirilmiş, makine öğrenmesi sistemlerinin öğrenmeye çalıştığı ilişki, yani "hat durumu" - "ışık kulesi ışık yanma örüntüsü" arasındaki bağıntı başarılı bir şekilde gerçekleştirilmiştir. Operatör örneğin duruş tuşuna basıp daha sonra karşısına çıkan ekranda duruş sebebini seçebilmekte ve ilgili duruma "etiket" verisi girilmesi suretiyle detay seviyede kestirime olanak sağlamaktadır.

Sahada görülebilecek olumsuz durumların analizi için, görüntü işleme fazından çıkan zaman serisinin kesintiye uğramalarına karşı gürbüzlüğü (robustness) kontrol edilmiştir. YoLo ve DeepSORT algoritmalarının kullanarak elde edilen çıktıların sonuçlarına göre, %10 seviyesinde 'noise injection' uygulanan durumda %95 doğruluk oranında başarı yakalanmıştır. Farklı 'noise injection' seviyelerindeki başarılı oranları için aşağıda bulunan Figür 2-B'de görülebilir.

Sonuç olarak sağlanan yöntem ve uygulamalar, yüksek başarı oranları ile endüstride geliştirilerek, daha az maliyetli bir çözüm olarak kullanılabilir.

## Referanslar

- [1] Nakajima, S. (1988), An Introduction to TPM, Productivity Press, Portland, OR.
- [2] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," in CVPR, 2005.
- [3] P. F. Felzenszwalb, R. B. Girshick, D. McAllester, and D. Ramanan, "Object detection with discriminatively trained part-based models," IEEE Trans. Pattern Anal. Mach. Intell., vol. 32, pp. 1627–1645, 2010.
- [4] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," in CVPR, 2014.