



Journal of Turkish Operations Management

Denetimli makine öğrenme algoritmalarıyla iş kazası ve meslek hastalıklarının önlenmesi: Farklı sektör uygulamaları

¹Adnan Karabulut, ²Mehmet Baran, ³Ergün Eraslan

¹ Yıldırım Beyazıt Üniversitesi Doktora Öğrencisi, Enerji ve Tabii Kaynaklar Bakanlığı, Ankara, Türkiye
e-mail: adnan.karabulut@hotmail.com, ORCID No: <https://orcid.org/0000-0002-0643-098X>

² İnşaat Müh., Mühendislik ve Doğa Bilimleri Fakültesi, Yıldırım Beyazıt Üniversitesi, Ankara, Türkiye
e-mail: mehmet.baran@ybu.edu.tr, ORCID No: <https://orcid.org/0000-0001-6674-7308>

³ Endüstri Müh., Mühendislik ve Doğa Bilimleri Fakültesi, Yıldırım Beyazıt Üniversitesi, Ankara, Türkiye
e-mail: eraslan@ybu.edu.tr, ORCID No: <https://orcid.org/0000-0002-5667-0391>

Makale Bilgisi

Makale Geçmişi:

Geliş: 15.03.2023
Revize: 02.10.2023
Kabul: 21.11.2023

Anahtar Kelimeler:

Algoritma,
İş Kazası,
Meslek Hastalığı

Özet

İş sağlığı ve güvenliği, proaktif bir yöntemle iş kazalarını ve meslek hastalıklarını önleyen bir disiplindir. Çalışan sağlığı için, ülkelerin uluslararası sözleşmelerde ve işverenlerin ulusal mevzuatta sorumlulukları bulunmaktadır. İşverenlerce risk değerlendirmesinin yapılması, iş güvenliği eğitimlerinin verilmesi, denetimlerin gerçekleştirilmesi, iş güvenliği uzmanı ve işyeri hekimi çalıştırılması ve ilgili tüm çalışmaların kayıt altına alınması zorunludur. Ülkelerde iş müfettişleri ile denetimler yapılmakta ve özel şirketler iş güvenliği hizmeti vermektedir. Ancak, işçi, malzeme, iş ekipmanı akışının çok hızlı ve fazla olduğu petrokimya, rafineri gibi büyük sanayi tesislerinde yetkililerin iş güvenliğini izlemesi zorlaşmaktadır. İşyeri kapasitesi, çalışan sayısı ve malzeme akışı arttıkça iş kazaları ve meslek hastalıklarının türü ve sayısı da artmaktadır. Yapay zekâ teknolojileri bu takipleri kolaylaştırmaktadır. Bu makalenin amacı, iş kazaları ve meslek hastalıklarına neden olan etkenlerin proaktif şekilde denetimli makine öğrenme algoritmalarıyla önlenmesinin farklı sektörlerde araştırılmasıdır. Scencedirect, scopus, googlescholar veri tabanları üzerinde literatür taraması yapılmış, sektörlerde kullanılan algoritmalar incelenmiştir. Literatürdeki çalışmalar ve farklı sektörlerdeki uygulamalara göre sensörlerle toplanıp bulut bilişimle saklanan veriler, daha önceden eğitilmiş ilgili denetimli makine öğrenmesi algoritmalarına beslenerek iş kazaları ve meslek hastalıklarına neden olan faktörler önceden belirlenebilmekte ve risk değerlendirme analizleri için tahminler yapılabilmektedir. Ses, metin ve görüntü verilerinin yanı sıra sağlık, konum, ortam, mesafe, seviye ve basınç gibi fiziksel parametreler de sensörlerle anlık takip edilebilmektedir. Aşılan fiziksel eşik değerlerde, tehlikeli bir durum veya davranış tespitinde yöneticiler uyarılmaktadır. Çalışan ve araç konum takibinin yanı sıra üretim, bakım ve lojistik iş araçlarının performansı da izlenerek öngörücü bakım sağlanabilmektedir. Azalan iş kazası ve meslek hastalıklarıyla, iş güvenliği performansı artmakta ve sonuç olarak maliyetler azalmaktadır.

Prevention of occupational accidents and occupational diseases with supervised machine learning algorithms: Different sector applications

Article Info

Article History:

Received: 15.03.2023
Revised: 02.10.2023
Accepted: 21.11.2023

Keywords:

Algorithm,
Work Accident,
Occupational Disease

Abstract

Occupational health and safety is a discipline that prevents work accidents and occupational diseases with a proactive method. Countries have responsibilities for employee health in international agreements and employers in national legislation. It is mandatory for employers to carry out risk assessments, provide occupational safety training, carry out inspections, employ occupational safety experts and workplace physicians, and record all relevant work. In countries, inspections are carried out by labor inspectors and private companies provide occupational safety services. However, it becomes difficult for authorities to monitor occupational safety in large industrial facilities such as petrochemicals and refineries, where the flow of workers, materials and work equipment is very fast and abundant. As workplace capacity, number of employees and material flow increases, the type and number of work accidents and occupational diseases also increase. Artificial intelligence technologies make these tracking easier. The aim of this article is to investigate the proactive prevention of factors that cause occupational accidents and occupational diseases in different sectors with supervised machine learning algorithms. A literature review was conducted on Scencedirect, Scopus and Google Scholar databases, and the algorithms used in the sectors were examined. According to studies in the literature and applications in different sectors, data collected with sensors and stored in cloud computing can be fed to relevant supervised machine learning algorithms that have been previously trained and tested, and the factors that cause occupational accidents and occupational diseases can be determined in advance and predictions can be made for risk assessment analyses. In addition to sound, image, health, location and environment data, physical parameters such as distance, level and pressure are monitored instantly with sensors. Managers are warned when physical threshold values are exceeded or a dangerous situation or behavior is detected. In addition to employee and vehicle location tracking, predictive maintenance can be provided by monitoring the performance of production, maintenance and logistics work vehicles. With decreasing work accidents and occupational diseases, occupational safety performance increases and, as a result, costs decrease.

1-Giriş

İş Kazaları (İK) ve Meslek Hastalıklarıyla (MH) ilgili ekonomik maliyet tahminleri; ülkelerin yıllık üretim değer toplamının %1,8 ila %6'sı arasında değişmekte olup, Uluslararası İş Organizasyonuna (ILO) göre ortalama %4'tür (Takala vd., 2014). Dünyada her yıl 100 milyon iş kazasında 100 bin ve 11 milyon meslek hastalığı teşhisinde 700 bin çalışanın hayatını kaybettiği tahmin edilmiştir (Leigh vd., 1999). Aradan geçen 22 yıl süre sonunda ILO verileri incelendiğinde her yıl meydana gelen 340 milyon İK ile 160 milyon MH teşhisinde toplam 2,3 milyon çalışan hayatını kaybettiği belirtilmektedir (ILO, 2023).

2011 yılında Almanya'da ortaya çıkan ve temelinde Yapay Zekâya (YZ) dayalı dijital üretim olan Endüstri 4.0 son yıllarda yaygınlaşmaya başlamış ve Endüstriyel YZ, genel YZ'dan daha önemli hale gelmiştir (Peres vd., 2020). Endüstri 4.0 paralelinde YZ temelli İş Sağlığı ve Güvenliği (İSG) gelişmekte olup, İSG 4.0 teknolojileriyle İK ve MH'nin önlenmesi mümkün olmaktadır. Büyük veri, nesnelere interneti, bulut bilişim, robotik sistemler, artırılmış ve sanal gerçeklik gibi YZ teknolojileri ile İSG 4.0 performansının artırılması mümkün olmaktadır (Çelik, 2019).

Denetimli Makine Öğrenimi (DMÖ) ve Denetimsiz Makine Öğrenimi (DzMÖ) ile Derin Öğrenme (DÖ) Makine Öğreniminin (MÖ) alt dallarıdır. DMÖ algoritmaları kamera ve sensörlerden alınan gerçek zamanlı verilerle beslenmektedir. DMÖ'de DzMÖ ve DÖ'nin aksine, veriler etiketlenmekte, sistem eğitilip ardından test edilmektedir. DzMÖ'de sistem etiketsiz verilerle eğitildiğinden ve örneklerin çıkışları bilinmediği için tanıma veya sınıflandırmada değil kümeleme, olasılık yoğunluk tahmini, öznitelikler arasındaki ilişkilerin bulunması ve boyut

indirgeme gibi işlemler için kullanılmakta (Bilgin, 2017) ve elde edilen sonuçlar DMÖ'de veri olarak kullanılabilir (Chao, 2011). DZMÖ'de genellikle parçalayıcı ve hiyerarşik kümeleme algoritmaları kullanılmaktadır (Özgür, 2004). Hinton ve Salakhutdinov tarafından oluşturulan (Hinton ve ark 2016) DÖ'de zamanla pek çok algoritma geliştirilmiştir (Goodfellow ve ark 2016).


Tek katmanlı değil çok katmanlı Yapay Sinir Ağlarının (YSA) ileri düzeyli bir yaklaşımı olan DÖ'de Alexnet, Vgg16, Vgg19 ResNet50, GoogleNet gibi gelişmiş algoritmalar kullanılmaktadır (Doğan ve Türkoğlu, 2018). DÖ çalışmalarının en uç örneği sürücüsüz araçlardır. Navigasyon için GPS, çarpışmaları önlemek için sensör tasarımı ve nesnelere tespit etmek için kamera teknolojileri ile sürüş simülatörü ise DÖ'nin diğer çalışma alanlarıdır (Aki, 2020).

Literatürde, İK'ları ve MH'ına neden olan etkenlerin gerçekleşmeden MÖ teknikleri ile önceden tespiti kapsamında çalışmalar bulunmaktadır. Çalışanların konum ve sağlık bilgileri, iş araçlarının konum bilgileri, çalışma ortamı havasının termal bilgileri takip edilerek İSG'ne zarar verecek etkenler önceden tespit edilebilmektedir. Tehlikeli iş ortamlarına çalışan yerine Drone ve Lidar gibi YZ kullanan ekipmanlar görevlendirilmektedir. Yaş, eğitim, tecrübe, işbaşı ve İSG eğitimi gibi bilgiler çalışan bilgileri iken tehlikeli durum ve tehlikeli davranışlar ile çalışma havası termal bilgileri işyerine ilişkin bilgilerdir. İK'larına neden olabilecek çalışan ve işyeri bilgileri; YSA gibi MÖ tekniklerinde veri olarak kullanılarak iş kaza sayısı ve yaralı sayısı gibi İSG verileri tahmin edilebilmektedir (Özden ve Acı, 2016; Akşehir vd., 2019). DMÖ algoritmaları ile İK'na neden olabilecek baret takmama, emniyet kemeri kullanmama gibi tehlikeli davranışlar görüntü işleme ile tespit edilebilmektedir. Dolayısıyla DMÖ algoritmalarının teoride nasıl oluştuğu, eğitimi ve testi önem kazanmaktadır.

Bu makale çalışmasında İK ve MH'na neden olan etkenlerin DMÖ algoritmalarını kullanan YZ teknolojilerinin kullanılarak önceden proaktif şekilde tespit edilmesidir. Böylelikle İK ve MH'nın oluşmadan önlenmesi amaçlanmıştır. İşletmelerde kamera ve sensörlerle anlık toplanan verilerin etiketli verilerle önceden eğitilen algoritmalarda işlenmesi ile İK ve MH'na neden olabilecek etkenlerin anlık takibi sayesinde çalışan sağlığının korunmasının yanında, üretim araçlarının ve çevrenin korunması ile İK ve MH'nın önlenmesi ve İSG maliyetlerinin düşürülmesi makalenin özünü oluşturmaktadır.


1.1. Denetimli Makine Öğrenmesi Algoritmaları

Sinir bilimci McCulloch ve matematikçi Pitts 1943 yılında yayınladıkları “*Sinirsel aktivite için matematiksel hesaplama*” adlı makalelerinde, bir nöronun biyolojik çalışmasını matematiksel olarak modellemişlerdir. Nöronun uçlarında bulunan dendritler dış dünyadan aldıkları giriş değerlerini ağırlıkları oranında çarpıp nöronun merkezine iletmektedir. Nöron merkezinde toplanan çarpımlar, eşik değeri aşarsa akson üzerinden sonraki nöronların uçlarına (dendritlerine) iletilmektedir. Şekil 1'de nöronlar arası karmaşık bağlantılar ve örnek bir nöronun yapısı görülmektedir. Dendritlerden giren veriler, hücre çekirdeğinde giriş kanallarının ağırlık değerleri ile çarpılarak toplanmakta ve çıkış değeri akson üzerinden diğer nöronlara iletilmektedir. 1943'te McCulloch ve Pitts'in önerdiği model, ağırlık, iletim ve hücre gövdesi hakkında hesaplamalar içermekte olup perception modeli olarak kabul edilmiştir (Wu vd., 2019).




Şekil 1. McCulloch ve Pitts nöron modeli (a:Advancedsciencenews 2023, b:Javapoint 2023)

1950 yılında Alan Turing, “*Makine düşünebilir mi?*” başlıklı makalesinde, Turing testini geçen makinenin (yazılımın/robotun) insan zekâsına sahip olacağını belirtmiştir. Turing testinde, bilgisayardan yazarak soru soran bir sorgucu bulunmaktadır (Şekil 2'de C). Perdenin arkasında bulunan gerçek kişi (Şekil 2'de B) ve makine (Şekil 2'de A) sorgucunun sorularına yazarak cevap vermektedir. Sorgucu cevaplardan, hangisinin insan olduğunu belirleyemezse, makine Turing testini geçmiş kabul edilmektedir. Günümüze kadar Eugene Goostman adlı bilgisayar % 33 başarı sağlamış bulunmaktadır (Ingram, 2014).



Şekil 2. Turing testi modeli (Webtekno, 2023)

YZ terimini ilk kez 1956 yılında ABD/Dartmouth konferansında McCharty kullanmıştır. McCharty tüm nöronların algoritmalarının yazılabilmesi halinde insan zekâsı gibi karar veren bir YZ'nın 2050 yılına kadar oluşturulabileceğini belirtmiştir (Moore, 2006). 1950'li yıllarda, insan beyinde 10^{11} adet nöron bulunduğu ve her nöronun onbinlerce bağlantısı sonucu beyinde oluşan milyarlarca bağlantıyı açıklayacak bir algoritmanın yazılamayacağı teorik çerçevede tartışılmıştır. Bu sorunu aşmak için 1959 yılında Arthur Samuel, bilgisayarlara her seferinde programlama yazmadan öğrenme yeteneğini kazandıran MÖ'sini bulmuştur (Alzubi vd., 2018). Şekil 3'de görüldüğü gibi klasik programlamada x_1 ve x_2 değerleri girilerek y bulunmaktradır. MÖ'de ise x ve y değerleri girilerek $x+2$ değeri tespit edilmektedir. MÖ'de verilerden algoritma elde edilmektedir. Günümüzde Python, Lisp, Prolog, C++, Java gibi YZ yazılım dillerinde algoritmalar oluşturulabilmektedir. Daha gelişmiş ChatGPT gibi programlarda ise algoritmalarındaki hatalar düzeltilebilmektedir.




Şekil 3. Makine öğrenimsi modeli

MÖ verilerden öğrenmeyi amaçlayan bir bilgisayar bilim dalıdır (Jiang vd., 2020). MÖ'de mevcut veriler kullanılarak sınıflama, kümeleme, tahmin ve birliktelik kuralları oluşturma çalışmaları yapılmaktadır (Singh, 2016). MÖ'nin denetimli, denetimsiz, yarı denetimli ve pekiştirilmiş öğrenme gibi alt dalları bulunmaktadır. Bu çalışmanın konusu kapsamında DMÖ incelenmiştir. Literatüre göre DMÖ çalışmalarında çoğunlukla verilerin %70'i eğitim için ve %30'u test için kullanılmaktadır (Hernán vd., 2019).

1.2. Denetimli Makine Algoritmalarının Eğitimi ve Testi

MÖ güvenlik teorileri, tıp, bilgi teknolojisi, istatistik, olasılık, psikoloji, nörobiyoloji, finans ve mühendislik gibi birçok disiplinde kullanılmaktadır. MÖ algoritmasının görevi değişkenler arasındaki kalıpları bulmak ve ilgili matematiksel modelleri oluşturmaktır ve verimli çalışabilmesi için yeterli sayıda ve kalitede veri gerektirmektedir (Suthaharan, 2016). MÖ'de, denetimli, denetimsiz, yarı denetimli, takviye, aktarım ve öğrenmeyi öğrenme olmak üzere altı farklı eğitim metodu bulunmaktadır (Nateski, 2017). DMÖ'de etiketli verilerle sınıflama ve regresyon (tahmin) yapılırken, DzMÖ'de etiketsiz verilerle sadece gruplama (kümeleme) işlemleri yapılabilmektedir. DMÖ'de sürekli veriler için regresyon, karar ağaçları ve rasgele ormanlar gibi algoritmalar kullanılırken, kategorik veriler için en yakın komşu, karar ağaçları, lojistik regresyon, naive bayes ve destek vektör makineleri gibi sınıflama algoritmaları kullanılmakta olup her birinin avantaj ve dezaavantajları bulunmaktadır (Bhavsar vd., 2012). MÖ algoritması eldeki veri matrisinden tecrübe ile öğrenmektedir (Brynjolfsson vd., 2018). E-postalar spam veya normal posta olarak etiketlenmektedir. Etiketlenen verilere göre yeni e postalarda doğru sayıda sınıflanan e-posta sayısı MÖ'nin performansı kabul edilmektedir (Shetty vd., 2022).

MÖ istatistik ve öğrenme süreçlerini birleştirdiğinden DMÖ algoritmalarının verimli çalışabilmesi için eğitilip test edilmesi gerekmektedir (Şekil 4). Literatürde genellikle verilerin %70'i eğitim, %30'u test için kullanılmaktadır (Muhammad vd., 2021). Örneğin Corona test sonuçları belli olan 1000 adet akciğer filminin 800'ü eğitim için kullanılmış olsun. Test için kullanılan 100'ünün pozitif ve 100'ünün negatif olduğunu farz edelim. Sistem 100 pozitifin 95'ini ve 100 negatifin 90'ını doğru tespit edebiliyorsa ilgili DMÖ algoritması ortalama %92,5 doğrulukla yeni akciğer filmlerinde Corona testini doğru teşhis edecektir.



Şekil 4. Denetimli makine öğrenme modeli (Turhost, 2023)

Bir DMÖ algoritmasının ne derece sağlıklı sonuç verdiğini belirten göstergeler Şekil 5'deki karışıklık matrisinde bulunmaktadır. Örnek vermek Şekil 5'de 0 Korona testi negatif demek iken 1 Korona testi pozitif demek olsun. Gerçekte korona negative olanların tahminde negatif bulunması Doğru Negatif (TN), gerçekte korona pozitif olanların tahminde pozitif bulunması ise Doğru Pozitifdir (TP). Diğer bir benzetmeye göre TP (True positive-Doğru Pozitif) hastaya hasta demek, FP (False positive- Yanlış Pozitif) hasta olmayana hasta demek, TN (True negative-Doğru Negatif) hasta olmayana hasta değil demek ve FN (False negative-Yanlış Negatif) ise hasta olana hasta değil demek anlamına gelmektedir. Gerçekte negatif olanların tahminde pozitif bulunması Yanlış Pozitif (FP), gerçekte pozitif olanların tahminde negatif bulunması ise Yanlış Negatifdir (FN). TN ve TP değerleri ne derece fazlaysa algoritma o derece verimli sonuçlar sağlayacaktır (Choudhary vd., 2017).

| | | Tahmin edilen sonuç | |
|--------------|---|---------------------|----|
| | | 0 | 1 |
| Gerçek sonuç | 0 | TN | FP |
| | 1 | FN | TP |

Şekil 5. Denetimli makine öğrenme performans kriterleri (Towardsdatascience, 2023)

Literatürde DMÖ algoritmalarının verimliliğini belirlemek için Şekil 5'de belirtilen TN, TP, FN ve FP değişkenlerini kullanan farklı formüller kullanılmaktadır. Bir DMÖ algoritmasının doğruluk (Acc) değeri (1) numaralı formülle, kesinlik değeri (2) numaralı formülle, duyarlılık değeri (3) numaralı formülle, F1 değeri (4) numaralı formülle ve özgüllük değeri (5) numaralı formülle tespit edilmektedir (Ciortuz, 2008).

$$Acc = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (1)$$

$$P = \frac{TP}{(TP+FP)} \quad (2)$$

$$R = \frac{TP}{(TP+FN)} \quad (3)$$

$$F1 = \frac{2*P*R}{(P+R)} \quad (4)$$

$$Sp = \frac{TN}{(TN+FP)} \quad (5)$$

Doğruluk (Acc) değeri doğru olarak sınıflandırılan örneklerin yüzdesidir ancak tek başına yeterli değildir. Kesinlik pozitif olarak tahminlenen değerlerin kaçının gerçekte pozitif olduğudur. Duyarlılık pozitif olarak tahmin edilmesi gerekenlerin ne kadarının pozitif olarak tahmin edildiğidir. F1 skoru (4 numaralı formül) bir algoritmanın doğruluk (Acc) ölçütünün (1 numaralı formül) bir göstergesi olup kesinlik (2 numaralı formül) ve duyarlılığın (3 numaralı formül) harmonik bir ortalamasıdır. Negatifliği daha doğru bir şekilde tanımlamak önemliyse 5 numaralı

formüldeki özgüllük ölçütü kullanılır.

Covid19 tespitinde kullanılan DMÖ algoritmalarının verimliliklerinin karşılaştırıldığı bir çalışmada, ücretsiz (açık kaynak kodlu) bir YZ yazılımı olan WEKA kullanılmış ve Tablo 1’de görülen sonuçlar elde edilmiştir (Osisanwo vd., 2017).

Tablo 1. Denetimli makine öğrenme algoritmaları performans değerleri (Muhammad vd., 2020)


| DMÖ algoritması | %Doğruluk (1 nolu formül) | %Duyarlılık (3 nolu formül) | %Özgüllük (5 nolu formül) |
|--------------------------|---------------------------|-----------------------------|---------------------------|
| Karar Ağacı | 94.99 | 89.20 | 93.22 |
| Lojistik Regresyon | 94.41 | 86.34 | 87.34 |
| Navie Bayes | 94.36 | 83.76 | 94.30 |
| Destek Vektör Makineleri | 92.40 | 93.34 | 76.50 |
| Yapay Sinir Ağları | 89.20 | 92.40 | 83.50 |

Daha güçlü MÖ algoritmaları için eğitim ve test verilerinin aynı dağılımdan alınmaması önemlidir (Bagnell, 2005) ancak literatür çalışmalarında genellikle aynı veri setinden alındığı görülmektedir. Veri sayısı ve kalitesi arttıkça MÖ algoritmalarının performansının arttığı bilinmektedir (Kaynar vd., 2016).

İSG’de İK ve MH’na neden olacak etkenlerin DMÖ ile önceden tespiti mümkündür. Kamera ve ses sensörlerden elde edilen saha verilerinin IoT üzerinden bulut bilişimde depolanarak etiketlenmesi (işaretlenmesi) sağlanmalıdır. Etiketlenen verilerle eğitilmiş DMÖ algoritmalarında örneğin kameralarla tespit edilen görüntülerden emniyet kemeri takmayan çalışan, çalışma ayakkabısının altına yerleştirilen ses sensöründen yüksekte düşen işçi tespit edilebildiği gibi DzmÖ ile kaza tutanaklarından kaza nedenleri de tespit edilebilmektedir. Bu kapsamdaki uygulamaların daha iyi anlaşılması için bilgisayar dilinde görüntü, ses, metin verilerinin nasıl işlendiği önem kazanmaktadır.

1.3. Denetimli Makine Algoritmalarında Ses, Metin ve Görüntü İşleme

YZ teknolojilerinde ses, metin ve görüntü işlenebilmektedir. Kaydedilen ses verileri öncelikle metne çevrilmektedir. Metin ve görüntü verileri ise doğrudan (0,1) ikili sisteme çevrilmektedir. Genel olarak bilgisayar görmesine bilgisayarlı tomografi, manyetik rezonans ve uzaktan algılama gibi iki veya üç boyutlu olanlar konu olmaktadır (Zhang ve Dahu, 2019). Görüntü tanıma (sayısallaştırma) tarama, örnekleme ve niceleme süreçlerinin toplamıdır ki görüntü dili analogdan dijitale dönüştürülmektedir. Görüntüler sisteme girildiğinde piksellere bölünerek her pikselin renk değeri hesaplanmaktadır. Farklı görüntü işleme teknikleri olmakla birlikte Şekil 6’da görüldüğü gibi hangi girilik seviyesinde kaç piksel olduğu görülmektedir. Grilik seviyesi 0 beyaz demek iken 1 ise siyah olup diğer renkler (0,1) arası değer almaktadır. Renkli resimler ve video görüntüleri de aynı teknikle tanımlanmaktadır. Görüntü ve videolarda Evrişimli Sinir Ağları (CNN) ve Konvolüsyonel Sinir Ağları (RNN) gibi gelişmiş DÖ algoritmaları da kullanılarak daha başarılı nesne tespiti yapılabilmektedir. Kamera görüntüleri ile eğitilen DMÖ algoritmaları ile emniyet kemeri takmayan çalışan, devrik bir kimyasal varil, yorgun bir sürücü kolaylıkla tespit edilebilmektedir.



Şekil 6. Resim işleme (V7labs, 2023)

Metin verileri doğal dil işleme teknikleriyle işlenebilmektedir. Tablo 2’de iki İş Kaza Raporu (İKR) ve iki Meslek Hastalığı Raporunda (MHR) geçen kelimelere göre İK ve MH türleri bulunmaktadır. Belge 1 sisteme taratıldığında en çok kelime benzerliği olan hepatit MH olarak tespiti edilecektir. Belge 2 sisteme taratıldığında ise İK olarak yüksekte düşmeyi tespit edilecektir. Belge 3 İK olarak patlama ve belge 4 MH olarak kuduz olarak tespit edilecektir.

Tablo 2. Metin işleme

| | | | | | | | | | |
|---|---|-------|-------|---------|---------|------|---------|-----------|-------|
| İK R1 | Düşme, kırık, ...> İK türü 1 (yüksekten düşme) | | | | | | | | |
| İK R2 | Kazan, patlama ...> İK türü 2 (patlama) | | | | | | | | |
| MHR1 | Hastane, iğne, sarılık ...> MH türü 1 (hepatit) | | | | | | | | |
| MHR2 | Veteriner, kedi ...> MH türü 2 (kuduz) | | | | | | | | |
| Belge 1 (iğne, düşme, sarılık, kazan) | | | | | | | | | |
| Belge 2 (düşme, hastane, kırık) | | | | | | | | | |
| Belge 3 (kazan, sarılık, patlama, kedi) | | | | | | | | | |
| Belge 4 (veteriner, hastane, kedi, kırık) | | | | | | | | | |
| | düşme | kırık | kazan | patlama | hastane | iğne | sarılık | veteriner | kuduz |
| İK R1 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| İK R2 | 0 | 0 | 1 | 1 | 0 | 0 | 0 | 0 | 0 |
| MHR1 | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 0 | 0 |
| MHR2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 1 |

İş kaza tutanakları ile MH raporları yararlı bilgiler içermektedir. Bununla birlikte söz konusu tutanak ve raporlarda bulunan veriler yapılandırılmamış veya yarı yapılandırılmış halde bulunmaktadır ve analiz etmek uzun ve zorlu bir süreçtir. İK tutanakları ve MH raporları DÖ algoritmalarında işlenerek İK ve MH için kök nedenleri veren örüntülerin tespit edilmesi mümkün olmaktadır (Zhong vd., 2020). Çalışmanın 4. Literatür Araştırması ve Sektör Uygulamaları kısmında belirtildiği üzere İK ve MH'na neden olan etkenlerin önceden tespiti kapsamında genelde görüntü işleme teknikleri kullanılmaktadır. İK tutanakları ve MH raporlarının MÖ kapsamında inceleyen çalışmalar ise çok fazla bulunmamaktadır. Çalışmada İK tutanakları ile MH raporlarının MÖ'de işlenmesi incelenmemiş, sahadan kamera ve sensörlerle elde edilen verilerin önceden eğitilen DMÖ algoritmalarında işlenerek İK ve MH'na neden olacak etkenlerin önceden tespiti yapılmıştır.

2. Çalışmanın Amacı

Bu çalışmada DMÖ algoritmaları kullanılarak ses (titreşim), görüntü ve çalışma ortamındaki termal veriler ile iş ekipmanlarındaki kritik çalışma değerleri anlık takip edilerek İK ve MH'nın önlenmesi araştırılmıştır. Literatür ve sanayi uygulamalarında işletmelerde söz konusu verilerin gerçek zamanlı takibinde daha çok DMÖ algoritmaları kullanıldığından çalışmada diğer daha fazla DMÖ'ne yoğunlaşmıştır. Çalışma ile İK ve MH'na neden olan etkenlerin proaktif şekilde tespitinde DMÖ algoritmalarına genel bir bakış açısı sağlanmak amaçlanmıştır, tarım, petrol, maden, ulaşım ve inşaat sektörlerinde kullanılan algoritmalar literatür desteğinde incelenmiştir.

3. Metodoloji

İK ve MH'nın ülke ekonomilerine olan maliyetleri incelendikten sonra, YZ'nı alt dalları olan genelde MÖ özelde DMÖ ile İK ve MH'na neden olan etkenlerin proaktif şekilde önlenmesinin önemine değinilmiş, DMÖ'nin teorik gelişim süreci anlatılmıştır. DMÖ algoritmalarının nasıl eğitilip ile test edildikleri konusu incelendikten sonra DMÖ'de ses, metin ve görüntü verilerinin nasıl işlendiği anlatılmıştır. Tarım, petrol, maden, ulaşım ve inşaat sektörlerinde kullanılan DMÖ algoritmalarına örnekler verilerek literatür eşliğinde analizler yapılmıştır. Çalışmanın son bölümünde;

- Artan nüfusla birlikte İK ve MH'dan kaynaklanacak maliyet artışları,
- YZ ile ilgili literatür çalışmalarının ne aşamada olduğu,
- ABD ve AB ülkelerinde İSG kapsamında YZ teknolojilerinin kullanımı ve
- Kullanılan sensör ve YZ tabanlı akıllı sistemler

hakkında literatür eşliğinde tartışma yapılmış, DMÖ algoritmaları ile çalışan İSG teknolojilerini kullanacak işverenlere kısa vadede karşılaşılabilecekleri engeller hakkında önerilerde bulunulmuştur.

4. Literatür Araştırması ve Sektör Uygulamaları

Robotların, sesnsörlerle gördüklerini doğru bir şekilde tanıma yetenekleri %90'a kadar artmış bulunmaktadır (Tkach vd., 2011). ABD’de tarım, madencilik, petrol, ulaşım ve inşaat sektörlerinde DMÖ algoritmalarıyla çalışan YZ teknolojileri kullanılmakta olup bir kısım sesnsör ve DMÖ algoritmaları Tablo 3’de bir arada görülmektedir.

Tablo 3. Makine öğrenim algoritmaları ve sensör bilgileri (Pishgar vd., 2021)

| Sektör | Sensör Türü | Makine Öğrenme Algoritma Türü |
|------------|---|--|
| Tarım | Laser, Kamera, Eeg, Ultrasonic, Gps, Infrared Laser, Basınç, İvme, Ses | Sinyal Algılama Teorisi, Sdt, Svm, Görüntü İşleme, Doğrusal Karışık Model |
| Petrol | Sıcaklık, Basınç, Gaz, Rfid, Akış, Ses, Nem, Rüzgar, Gps | Svm, Gmm, Knn, Ann, Dönüştürme, Yerelleştirme |
| Madencilik | Hareket, Hız, Dönme, Manyetometre, Gps, Nem, Ses, Sıcaklık, Gaz, Toz, Nabız, Kızılötesi, Kamera, Sigara | Görüntü İşleme, Ann, Dt, Rf |
| Ulaşım | Kızılötesi, Kamera, EMG, Basınç, Araç, ECG, PPG, EOG, EEG, Hız, Dönme | GMM, Helly Model, ANN, CNN, Bayes Nöral Ağlar, Dijital Sinyal, İşleme, Bulanık Nöral Ağlar, Derin Öğrenme, İkili Karar, Sınıflama, ANN, NN, CNN |
| İnşaat | Basınç, Hareket, Hız, Ses, Dönme, Basınç, Elektromiyografi, Kamera, Titreşim, Ortam | Svm, Ann, Knn, Rbf, Ppca, Lda, Gmm, Hmm, Yüksek Seviye Bulanıklık, Petri Ağı, Karar Ağacı, Bilgisayar Görmesi, Navei Bayes, Desen Eşleştirme, Markov Zinciri |

İşletmelerde yaralanma ve ölüm açısından tarım, madencilik, petrol, ulaşım ve inşaat önde gelen sektörlerdir. Söz konusu sektörlerde İK ve MH’na neden olan etkenleri gerçekleştirilmeden tespit eden DMÖ algoritmaları; PubMed, Google Scholar ve Scopus arama motorları kullanılarak incelenmiştir. İK ve MH’na neden olan etkenler Ramak Kala Olayların (RKO) koşullarıdır.

İş kazalarına neden olabilecek RKO güvenlik piramidinin en alt seviyesindedir (Reason, 1997). RKO ciddi iş kazalarına göre daha sık meydana gelmekle birlikte ölçekleri daha küçük olup her büyük iş kazasından önce bir dizi RKO yaşanmaktadır (Phimister vd., 2000). Literatürde, karayolu ve demiryolu trafiği (Wright ve Schaaf, 2004), tesis mühendisliği (Uth ve Wiese, 2004), bina güvenliği (Wu vd., 2010), ev güvenliği (Marsh ve Kendrick, 2000) ve sağlık sistemleri (Lyons vd., 2016) gibi iş kazalarına neden olabilecek RKO inceleyen çalışmalar bulunmaktadır. Orman işletmelerinde (Lilley vd, 2002), tarım sahalarında (Lundqvist ve Gustafsson, 1992), iş makineleri kullanımlarında (Raviv vd., 2017), demiryollarında (Wright ve Schaaf, 2004), inşaat sahalarında (Wu vd., 2010) RKO sıkça görülmektedir.

4.1. Tarım Sektörü

Tarımda ilgili tehlikelerin bir sonucu olarak pestisitlen zehirlenme, biçerdöverlere kapılma, traktör devrilmesi, güneş çarpması gibi riskler bulunmaktadır. Diğer taraftan tarım robotları ekim ve hasat sırasındaki ağır işleri yapabilmektedir. İlaçlama ve sulama prosedürleri, aşılama ve kesme, ot ayıklama, budama, mahsullerin izlenmesi, haritalama, hava koşullarının takibi ve depolanma gibi işlerdeki tehlikeler riske dönüşmeden diğer bir ifadeyle İK ve MH’ı gerçekleştirilmeden tespit edilebilmektedir. Tehlikeli çalışma alanları önceden GPS, LIDAR, İnsansız Hava Araçları ve Drone ile belirlenerek işçilerin gitmesi önlenmekte İK’ı oluşmamaktadır (Feritias vd., 2012). Yarı otonom cihazlarla pestisitlerin etkili püskürtülme alanı tespit edilerek işçilerin kimyasala maruz kalması engellenmekte ve MH önlenmektedir. Tarım uçağı gibi gürültülü araçları kullanan işçilerinin maruz kaldığı titreşim takip edilmekte ve titreşim MH oluşmamaktadır (Calvo vd., 2018).

4.2. Petrol ve Doğalgaz Sektörü

Petrol sektöründe yer altından çıkarılan ham petrol ve doğalgaz borularla taşınarak rafinerilerde işlenmekte ve motorin, benzin, doğalgaz gibi ürünler olarak tüketiciye sunulmaktadır. Sensörlerle endüstriyel operasyonların

proses değerlerinin yanı sıra işçilerin güvenliği ve sağlığı ile iş ekipmanlarının kritik çalışma değerleri takip edilebilmektedir. Arama, sondaj, rezervuar mühendisliği ve üretim operasyonlarında MÖ kullanılmakta, delme, inceleme ve erozyon kontrolü gibi zorlu işlerde akıllı robotlar kullanılmaktadır. Sıcaklık veya gaz seviyelerindeki artış tehlikeli olduğundan kuyulardaki seviye, sıcaklık ve gaz kritik değerleri sensörlerle takip edilmekte (Barani vd., 2013) çalışanlar GPS ile izlenmektedir.

- Ham petrol, doğalgaz ve bunlardan elde edilen ürünler taşınırken tıkanma, yangın, patlama ve çevre kirliliği gibi durumları önlemek için boru hattı ve tanker sensörleri kullanılmaktadır (Yu vd., 2012). Ham petrol ve doğalgaz işlenirken kullanılan basınç, sıcaklık ve seviye gibi arıza sensörleriyle olası yangın ve patlamaların önüne geçilerek İK ve MH'ı önlenmektedir (Jung vd., 2014).
- Giyilebilir saatler, akıllı kasklar ve akıllı gözlüklerle işçiler ve iş ortamı takip edilerek tehlikeli durumlar saptanmaktadır (Priyadarsyh vd., 2017).
- Görüntü algoritmalarıyla karadaki petrol sızıntıları (Ozigiris vd., 2019) tespit edilerek çevreye daha fazla yayılması ve halkın kimyasala maruz kalması engellenmektedir.

4.3. Madencilik Sektörü

Maden aranması ve çıkarılması tehlikeli koşullarda gerçekleşmektedir. Özellikle yer altı maden ocaklarında dar çalışma alanı, yetersiz aydınlatma ve havalandırma, göçük, patlama, yangın kaynaklı İK'ları ile toz ve bakteri kaynaklı MH'nı önlemek için DMÖ algoritmaları kullanılmaktadır. Özellikle yer altı maden ocaklarında İK ve MH için bir çok tehlike faktörü bulunmaktadır.

- Otonom matkaplar ve kesiciler kullanılarak işçiler ağır işlerden korunmakta ve göçük önlenmektedir (Ghasem vd., 2012). Havadaki zehirli gaz ve tozlar ile işçi ve iş araçları sensörlerle takip edilerek İK ve MH'ı önlenmektedir.
- Yer altında çalışan işçilerin konumu akıllı saat ve GPS ile (Johnson, 1998) vücut ısısı, nabız, kan basıncı gibi fizyolojik değerle ise sağlık sensörleriyle takip edilmektedir (Wang, 2006).
- Çevresel sensörlerle maden ocak havasında bulunan gürültü, zehirli gaz, toz ve bakteriler takip edilerek yangın, patlama kaynaklı İK'ları ile zehirlenme kaynaklı MH'ı önlenmektedir (Jones, 1995).
- Farklı tipte sensörler kullanan kablosuz kasklar, saatler, kameralar gibi giyilebilir cihazlar, hareket ve konumu izlemek, aşırı ortamları ölçmek ve çalışanların fizyolojik özelliklerini kaydetmek için kullanılmaktadır (Ghasem vd., 2012).
- Akıllı kask, gözlük ve giyilebilir yepek gibi cihazlarla hareketli sistemler ve çalışanlar takip edilebilmektedir.
- Akıllı kasklara, emniyet kemerlerine veya sırt çantasına takılan ve sensör içeren solunum tozu monitörleriyle zehirli toz ve bakteriler tespit edilebilmektedir.
- Güvenlik yepeği, akıllı gözlük ve kask ile akıllı saati birleştiren entegre yazılımları kullanmak mümkündür (Mardova, 2018).
- Tehlikeli yerlerde sigara içen işçinin anormal vücut hareketleri tespit edilebilmektedir (Parate vd., 2017).

4.4. Ulaşım Sektörü

Ulaştırımda kazalar ölümleri arttırmakta, ürüne zarar vermekte, lojistiği ve üretimi aksatmaktadır. Temel sebep yorgunluk olup belirtileri esneme, yavaş reaksiyon süresi, göz kapağının kapanması ve gevşek direksiyon tutuşudur. Literatürde genelde sürücü yorgunluğunu tespit eden çalışmalar bulunmaktadır. Ancak yorgunluğu ölçmede kullanılan Karolinska Uykululuk Ölçeği (Bekiaris vd.,2001) gibi standartlar yorgunluk algoritmalarıyla karıştırılmamalıdır. Göz kırpması süresi, kas gerginliği, tepki süresi gibi sürücü özellikleri (Körber vd., 2015) ile şerit ve hız takibi yapan hibrit algoritmalar kullanılarak önceden yorgunluk tespit edilebilmektedir.

- Biyolojik algoritmalar kalp, beyin ve kas aktivitesinden gelen verileri kullanmaktadır (Kaide vd., 2006).
- Foto Platisma Gram okumalarındaki değişiklikler yorgunluğu belirlemede kullanılmakta olup göz çevresinden elektrotlarla alınan veriler DzMO'de işlendiğinde, yanıt hatasının yorgunlukla artış anlamına geldiği belirtilmektedir (Li vd., 2013).
- Elektroensefalografi (EEG) ile alınan beyin dalgaları (Britton vd., 2016) ve elektromiyogramı (sEMG) ile tespit edilen kas aktivite seviyesinden de (De Lucca vd., 1984) yorgunluk tespit edilebilmektedir.
- Göz, ağız ve baş hareketleri gibi yüz ifadeleri, yorgunluğun en görünür belirtileridir. Göz, ağız, kafa-omuz, yüz hareketlerini aynı anda algılayıp analiz eden PERCLOS gibi ticari yazılımlar bulunmaktadır (Gengler,

2007). DMÖ ile yorgunluk tespit edildiği gibi yorulma sınıflandırılması da yapılabilmektedir (Dwivedi vd., 2014).

- Yüz algoritmalarını kullanan *Smart Eye*, *Anti Sleep* ve *OPTALERT* (Bretzner vd., 2005), göz kapağı ve göz bebeği aktivitesini kullanan *Sleep Diagnostics* ve gözbebeği ve kafa hareketini kullanan *Care Drive* gibi yazılımlarda DMÖ algoritmaları kullanılmaktadır.
- Yorgunluk sürücünün direksiyon açısı ve şerit sapması gibi durumları etkilemektedir. Araçta düzensiz pedal ve direksiyon kullanımından veya hareket sonucu basıncın şoför koltuğunda bir noktaya yoğunlaşmasından yorgunluk tespit edilebilmektedir (Altunkaya, 202).
- Sensörler direksiyon koluna, pedala ve koltuğa monte edilerek (Frugori vd., 2005) araç hızı, fren ve gaz pedalı ile öndeki araca olan mesafe ölçülerek yorgunluk tespit edilebilmektedir.
- Göz kapağı kapanması ile şerit konumu sapmasını takip eden sensörler araç ve sürücü özelliklerini aynı anda takip edebilmektedir (Cheng vd., 2012).

4.5. İnşaat Sektörü

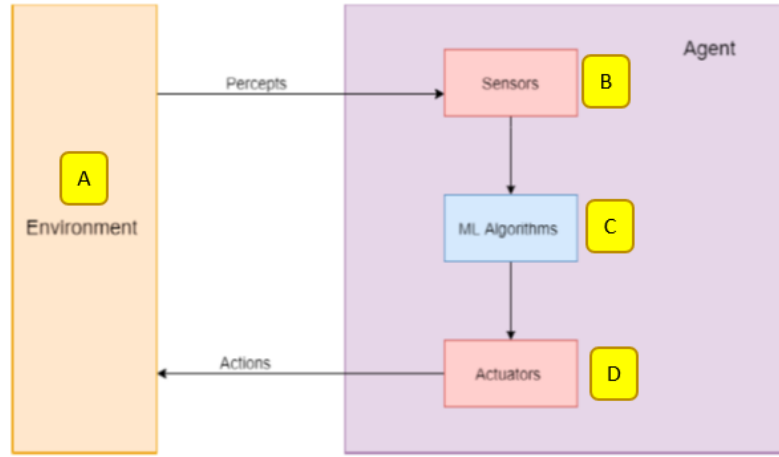
Şantiyelerde en büyük tehlike düşmedir. Giyilebilir cihazlardan, ortam ve kamera sensörlerinden (Khan vd., 2017) veya Bina Bilgi Modellemesinden (BBM) düşmeler tespit edilebilmektedir (Zhang vd., 2013). Sanayide ivmeölçer (Gibson vd., 2016) ve jiroskop (Jian vd., 2015) sensörleriyle desteklenmiş daha etkili düşme algılama sistemlerinin kullanımı mümkündür.

- Kamera sensörleriyle vücut hareketindeki şekil, duruş ve baş hareketindeki anormallikler tespit edilebilmektedir (Özcan vd., 2015).
- Basıncı, titreşim, kızılötesi gibi hareket sensörleri bireyi çevreleyen ortamdaki değişiklikler hakkında bilgi toplamaktadır (Alwan vd., 2006).
- Hareketlilik ve yürüyüş parametrelerinin doğru ölçümlerine göre anormallikler belirlenebilmektedir (Rimminen vd., 2010).
- Görüş tabanlı sensörler ise daha etkili sonuçlar vermektedir (Mubashir vd., 2013).
- Giyilebilir ve görüntü sensörlerini bir arada kullanan çalışmalar bulunmaktadır (Yu, 2008).
- Şantiyelerde düşme olaylarına dönüşebileceğinden dolayı ramak kala düşüşün tespiti çok önemlidir (Zhang vd., 2019).
- İnşaat yapılarında kullanılan iskelelerin çökmeden oluşabilecek tehlikelerin önlenmesi için iskele kolonlarından elde edilen metal gerinim değerlerinin takip edilmesi gerekmektedir (Sakharrma vd., 2019).
- Ses sensörleriyle elde edilen ses verileri DMÖ algoritmalarına beslendiğinde düşen işçinin bağırması çok farklı olacağından düşme tespit edilebilmektedir (Le vd., 2020).
- Adım ve adım mesafesi, ortalama hız ve maksimum ayak boşluğu gibi verilerle işçilerin anormal yürüyüş desenleri kontrol edilerek düştüğü veya yaralandığı anlaşılabilir (Yang vd., 2019).

4.6. İSG’de YZ Uygulamalarının İncelenmesine Yönelik Yeni Bir Çerçeve Yaklaşımı

YZ’nın tanımlarından biri ortamdaki veri alan, verileri analiz eden ve analize dayalı olarak bir eylem gerçekleştiren bir aracının çalışmasıdır. RKO dahil İK ve MH’nın önlenmesi ancak iş kazaları ve meslek hastalıklarına neden olan faktörlerin önceden tespit edilerek önlenmesi ile mümkündür. Süreç, kamera ve sensör cihazları tarafından ortamdaki verilerin toplanması ile başlamakta, verilerin DMÖ algoritmaları aracılığıyla analiz edilmesi ve son olarak aktüatörler tarafından eylemin gerçekleştirilmesi ile son bulmaktadır (Pishgar vd., 2021). Şekil 7’de süreci anlatan model görülmektedir.

Modelin işleyişine bakıldığında; çevreden (Şekil 7-A) sensörlerle (Şekil 7-B) alınan veriler bulunmaktadır. Veriler kamera verileri de (video ve fotoğraflar da) olabilmektedir. Söz konusu veriler İK’na neden olabilecek tehlikeli durum ve davranışlar ile MH’larına neden olabilecek işyeri çalışma ortamı havasındaki sıcaklık, basınç, konsantrasyon gibi verileri içermektedir. Toplanan veriler, öncelikle ilgili DMÖ algoritmalarında eğitilmekte (Şekil 7-C) ve çıkan sonuçlar hareket ettiriciler (Şekil 7-D) aracılığı ile tekrar çevreye (Şekil 7-A) belirli eylemleri gerçekleştirmesi için gönderilmektedir.

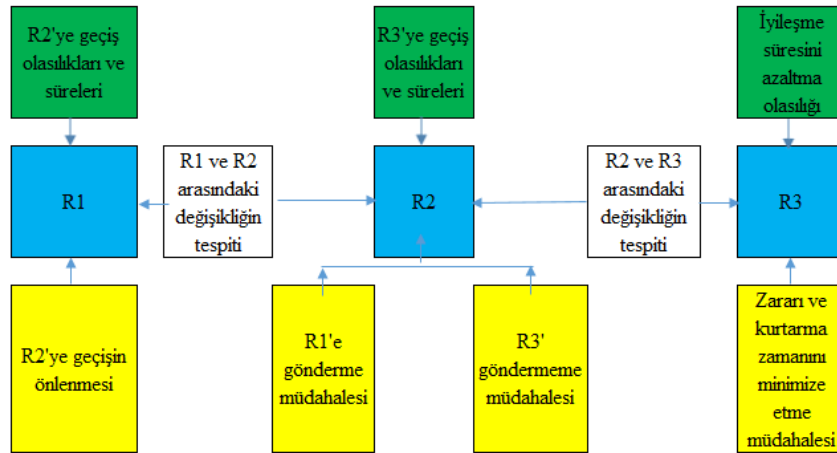


Şekil 7. Bir YZ sisteminin bileşenleri (Pishgar vd., 2021)

Şekil 7’de görüldüğü üzere çevreden (A) sensör ve kameralarla alınan veriler (B) önceden eğitilmiş MÖ algoritmalarında işlenmekte (C) ve sonuç bilgilere göre hareket ettiriciler (D) üzerinden tekrar çevreye (A) ilgili komut ve uyarılar iletilmektedir. Modelde süreç A,B, C ve D arasında sürekli bir döngüye sahiptir. Modelin çalışması aşağıdaki iki örnekle açıklanmıştır.

- Bir inşaat sahasında çalışan bir işçinin bot, baret ve emniyet kemeri takması zorunludur. İnşaat iskelesinde çalışan işçinin kamera görüntüleri, önceden eğitilmiş resimlerle karşılaştırıldığında işçinin bot, baret veya emniyet kemeri takıp takmadığı tespit edilerek saha yöneticilerine uyarı verilebilmektedir.
- Kargo taşıyan bir tır şoförünün anlık yüz görüntüleri önceden etiketlenen yorgun şoförün yüz görüntüleri ile karşılaştırılarak uyuklamaya geçebilecek şoföre mesaj gönderilmesi mümkündür.

Önerilen model (Pishgar vd., 2021) kapsamında İSG’de YZ uygulamalarını kategorize etmek için literatür dikkatlice gözden geçirilerek Şekil 8’deki çerçeve önerilmiştir ki önerilen çerçeve model, İK ve MH’nın nasıl meydana geldiğini tespit etmek için baskın bir paradigma olan İsviçre peynir modeline dayanmaktadır (Reason, 1990). Çerçeve model, bir işçinin tehlikelere maruz kalma riskini tahmin ve kontrol etmek için YZ teknolojilerinin ve yöntemlerinin nasıl kullanılabilirliğini sistemleştirmektedir.



Şekil 8. İK ve MH için Risk Gelişimi, Tespiti, Değerlendirilmesi ve Kontrolü Çerçevesi (Pishgar vd., 2021)

Şekil 8’de yeşil kutular, sonraki durumlara geçiş olasılığını tahmin edebilen teknolojileri gösterirken, beyaz kutular farklı güvenlik risk seviyeleri olan R1, R2 ve R3 durumları arasındaki geçişleri algılayabilen teknolojilerdir. Sarı kutular ise işçiyi güvende tutmak veya işle ilgili bir olayın etkisini azaltmak için müdahale stratejilerini göstermektedir. Bir çalışan, işinin doğası gereği herhangi bir zamanda farklı güvenlik risk seviyelerinde (R1, R2, R3) olabilmektedir (Şekil 8).

- R1 bir çalışanın tehlikeye maruz kalma riskinin minimum düzeyde olduğu veya hiç olmadığı ideal durumdur. Yöneticilerin ve İSG profesyonellerinin görevi işçiyi bu durumda tutmaktır. Ancak iş gereksinimleri ve mevcut teknolojiler ile çevresel faktörler sürekli olarak entropiyi artırarak ramak kala İK koşullarını ve MH'na neden olan çalışma havası ortamlarını oluşturmaktadır.
- R2'de çalışanlar işle ilgili riskler altındadır ancak yaralanma, ölüm, üretim araçları ve çevre zararı gibi zararlı bir olay yaşamamıştır. R2 tehlikeye maruz kalma ve artan yaralanma riskini göstermektedir. R2'de yaşanan İK'ları ramak kala olaylar olarak değerlendirilmektedir.
- R3 çalışanın sağlığını ve güvenliğini etkileyen işle ilgili zararlı bir olayın meydana geldiği ve neticede İK'nın yaşandığı ve/veya MH'nın oluştuğu durumdur.

Literatürdeki çalışmalar işçileri R1'de diğer bir ifadeyle riskin minimum düzeyde veya hiç olmadığı iş koşullarında tutacak YZ teknolojilerine yoğunlaşmıştır ve çalışanların risk durumunu R3'den R2'ye, R2'den R1'e düşürülmesini sağlayan YZ temelli çalışmalar literatürde çok fazla bulunmamaktadır (Şekil 8 sarı kutular). Diğer taraftan R1, R2 ve R3 konularına geçiş olasılıkları ve sürelerini belirleyen çalışmalar (Şekil 8 yeşil kutular) ile R1, R2 ve R3 konuları arasında değişiklikleri tespit eden çalışmalara (Şekil 8 beyaz kutular) literatürde çok az bulunmaktadır (Pishgar vd., 2021).

5. Sonuçlar ve Tartışma

Artan nüfus ve üretimle İK ve MH kaynaklı maliyetler büyümektedir (Yokoyama vd., 2013). Avrupa İş Sağlığı ve Güvenliği Ajansı söz konusu maliyetleri küresel hasılanan %3,9'u ve Avrupa hasılasının %3,3'ü olarak (EU-OSHA, 2017) belirtirken ILO ise küresel hasılanan %4'ü olarak tahmin etmektedir (Dorman, 2012). İK ve MH kaynaklı maliyetlerin ülke hasılasına % olarak oranlarını (Polonya %10,4 - İtalya %6,7 - Hollanda %3,6 - Almanya %3,3 ve Finlandiya %2,7) ve İK başı maliyetlerini (Hollanda 75.342 Avro, İtalya 58.411 Avro, Almanya 44.919 Avro, Finlandiya 43.069 Avro ve Polonya 38.918 Avro) veren çalışma (Tomba vd., 2021) incelendiğinde İK ve MH maliyetinin ülke hasılasına oranının ortalama %5,3 ve İK başına ortalama giderin 52.000 Euro olduğu görülmektedir.

Akademi ve endüstride karar verme, çevresel izleme, operasyonel maliyetleri düşürme ve üretkenliği artırma gibi sorunları çözmek için genelde MÖ'ni özelde DMÖ'ni kullanmaktadır. Robotla çalışan bir insanın İK riskinin 2 kat daha az olduğu belirlenmiştir (Freitas vd., 2012). İK'ni önleme açısından robotların gördüklerini doğru bir şekilde tanıma yetenekleri %90'a kadar artmıştır (Tkach vd., 2011). ABD tarım sektöründe MÖ uygulamalarının tarımsal iş robotlarında kullanımı ile ölümcül olayların sayısı 1990'ların başında yaklaşık 1000 vakadan 2019'da 600 vakanın altına düşmüştür (Issa vd., 2019). ABD madencilik sektöründe daha yüksek olan ölüm oranı YZ destekli MÖ uygulamalarıyla 2018 yılında 100.000 çalışan başına 10,4'e düşürülmüştür (NIOSH, 2019).

Robotik sistemlerin DMÖ ile eğitilerek optimize edebileceği görevler arasında (i) ağır, zor ve tehlikeli işlerin makinelere yaptırılması, (ii) personel ve araçların konum takibi ile tehlikeli alanlara yaklaşımlarının önlenmesi, (iii) LIDAR ve DRONE gibi cihazların kullanımı ile işçilerin tehlikeli alanlarda çalıştırılmasının önlenmesi (iv) biyolojik sensörlerle çalışan sağlığının takip edilmesi ve uyku tespitinin yapılması (v) ortam sensörleri ile MH'na neden olabilecek etkenlerin tespit edilmesi ve daha ergonomik bir çalışma ortamının sağlanması yer almaktadır (Pishgar vd., 2021).

İş dünyası ve hükümetlerin İK ve MH kaynaklı maliyetleri azaltmak için anlık veri takibi ve değerlendirmesine imkan tanıyan DMÖ teknolojilerini kullanması faydalı olacaktır. Sanayi, tarım ve hizmet işletmelerinde sahadan kameralar ve sensörlerle toplanacak verilerin etiketlenerek (sisteme işlenerek/işaretlenerek) ilgili DMÖ algoritmalarına gönderilmesiyle, İK ve MH'na neden olacak tehlikeli durum ve davranışlar ile MH'na neden olan etkenler proaktif şekilde önlenirken üretim ve iş araçları ile çevre zararları da engellenmiş olacaktır.

Stanford Üniversitesinin 2022 YZ indeks raporuna göre 2021 yılında YZ konulu 364 bin yayının sadece %2,5'i DMÖ'ni içeren kontrol teorileri ile ilgilidir. Literatürde ve sanayide İK ve MH'nın önlenmesi kapsamında genelde MÖ özelde DMÖ'nin kullanımı ile ilgili geniş bir çalışma alanı bulunmaktadır. Bu tespitler kapsamında ABD'de bulunan Mesleki Robotik Araştırma Merkezi (CORR) ile Avrupa İSG Ajansı (EU-OSHA) çalışmalar yapmaktadır. ABD'de (i) tarım sektöründeki işlerde dron ve biyolojik sensörlerin, (ii) petrol ve gaz endüstrisinde zorlu ve tehlikeli işlerde akıllı robotların, (iii) maden sektöründe akıllı saat ve baretlerin, (iv) ulaşım sektöründe sürücü yorgunluğu tespit sistemlerinin ve (v) inşaat sektöründe düşme algılama sistemlerinin kullanılması ile İK ve MH'nın önlenmesine yönelik çalışmalar bulunmaktadır (Pishgar vd., 2021). AB'de ise İSG kapsamında akıllı dijital izleme sistemleri ile ilgili çalışmalar yapılmaktadır (EU-OSHA, 2023).

Literatür ve sanayi uygulamaları incelendiğinde, İK ve MH'na neden olan etkenlerin önlenmesinde DMÖ algoritmalarına yoğunlaştığı görülmektedir. Çalışan, çalışma ortamı ve iş araçları ile ekipmanlarında kullanılan sensörler tarafından anlık olarak toplanan veriler nesnelerin interneti üzerinden bulut bilişimde saklanarak DMÖ algoritmalarına beslenip riskli durumlar önceden tespit edilebilmektedir. Ses, titreşim, hareket, darbe, sıcaklık, toz, gaz, bakteri, bakım, görüntü, mesafe, yorgunluk gibi bir çok senör tipi olup bu sensörler kask, gözlük, saat, yelek, bot, eldiven gibi kişisel koruyucu donanımlara, iş araçlarına, çalışma ortamına ve ayrıca GPRS, Drone, LIDAR, kamera gibi cihazlara monte edilerek kullanılmaktadır.

Sensörlerden gelen veriler önceden eğitilen DMÖ algoritmalarında işlenerek örneğin devrilen kimyasal varil, yaralı işçinin yürüme şekli, boru hattı etrafındaki sızıntı gibi anormal durumlar tespit edilebilmektedir. Forklift gibi araçlarda kullanılan mesafe sensörleri ile işçi-ekipman mesafe takibinde kullanılan çoklu nesne izleme yazılımları ile tehlikeli alana girmesi durumunda işçi uyarılmaktadır. Tehlikeli alanlarda yapılacak işler, çalışanlara değil Drone, LIDAR gibi sensör kullanan cihazlara yaptırılmaktadır.

Sanayide genellikle yapılandırılmış veri içeren DMÖ teknolojileri kullanılırken, DzmÖ ve DÖ algoritmaları daha az kullanılmaktadır. Literatür araştırmalarının DMÖ'nde yoğunlaştığı görülmektedir.

İşletmeler İK ve MH'na neden olan etkenleri, işçi, ekipman ve ortama monte edecekleri ses, görüntü, hareket gibi sensörlerle gerçek zamanlı takip etmelidir. Toplanan veriler önceden eğitilen DMÖ algoritmalarında değerlendirilerek İK ve MH'na neden olan etkenler önceden tespit edilebilecektir.

DMÖ algoritmalarını içeren YZ teknolojilerini kullanacak işverenler kısa vadede uygulama engelleriyle karşılaşsalar da uzun vadede avatjaları daha fazla olacaktır.

- İK ve MH'nı önlemek için kurulacak dijital sistemlerin maliyeti ilk engel olacaktır. Denetimli makine algoritmalarını kuracak ve işletecek yazılımcı ve veri bilimciler ile dijital ekipmanları kullanacak işçilerin eğitimi bu süreçte aşılması gereken ikinci engel olacaktır.
- Bu temel engellerin aşılmasıyla veri korunması ve güvenlik prosedürleri gibi teknik engellerin de aşılması gerekecektir.
- Kurulacak DMÖ sistemleriyle İK ve MH verilerinin sistemde birikmesi sağlanacak ve yapılacak risk analizlerinde kullanımı sağlanmış olacaktır.
- İK ve MH azalacağından verimlilik artacak, mesleki kaza ve hastalık kaynaklı tazminatlar azalacak ve elde edilen kârlar ile yeni yatırımlar yapılabilecektir.

İşverenler, sanayide kullanılan üretim ve iş robotlarını içerecek şekilde genelde MÖ özelde DMÖ konusunda yasal düzenlemeler ve vergi kolaylıkları talep etmelidir. Bu kolaylıklar sayesinde temin edecekleri kredilerle gelecek için DMÖ kapsamında ARGE çalışmalarına yönelmeleri uzun vadeli bir stratejik karar olacaktır.

İşletmelerde İK ve MH'nı azaltmak için YZ algoritmalarını kullanan yazılım, makine ve robot gibi otonom sistemlerin kullanımı için hükümetler Enüdtü 4.0 ile uyumlu olacak şekilde yasal mevzuatları, sektörlerin görüşlerini dikkate alarak hazırlamalıdır.

Araştırmacıların Katkısı

Bu araştırmada; Adnan Karabulut, makalenin giriş ve literatür taraması ile sonuçlar ve tartışma kısmına, Mehmet Baran ve Ergün Eraslan araştırma sürecinin izlenmesi ve kontrolü, literatür taraması ile sonuçlar ve tartışma kısmına katkı yapmışlardır.

Çıkar Çatışması

Yazar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

Kaynaklar

Aki, Koray & Dirik, A. E. Derin Öğrenme Tabanlı Ve Pıd Kontrol Tabanlı Sürücüsüz Araç Sistemleri. Mühendislik Bilimleri Ve Tasarım Dergisi, 8(5), 306-316, 2020. Erişim adresi: <https://dergipark.org.tr/en/download/article-file/1409300>

Akşehir, Z. D., Pekel, E., Akleylek, S., Kılıç, E., & Yalçın, Oruç, İş Sağlığı Ve Güvenliği Sektöründe Bayes Ağları Uygulaması. Türkiye Bilişim Vakfı Bilgisayar Bilimleri Ve Mühendisliği Dergisi, 12(1), 47-59. Erişim adresi: <https://dergipark.org.tr/en/download/article-file/697396>

Altunkaya, C. (2022). Sürücü davranışlarını tespit eden ve tanımlayan yeni bir algoritma ile akıllı takograf geliştirilmesi= Development of smart tachograph with a novel algorithm detecting and recognition of driver behaviour. Erişim adresi: <https://acikerisim.sakarya.edu.tr/handle/20.500.12619/98431>

Alwan, M.; Rajendran, P.J.; Kell, S.; Mack, D.; Dalal, S.; Wolfe, M.; Felder, R. A smart and passive floor-vibration based fall detector for elderly. In Proceedings of the 2006 2nd International Conference on Information & Communication Technologies, Damascus, Syria, 24–28 April 2006; pp. 1003–1007. Erişim adresi: <https://c85689232ea394a8dc08a512c1f46793a2397178.vetisonline.com/stamp/stamp.jsp?tp=&arnumber=1684511>

Advancedsciencenews, Artificial neural networks that mimic the flexibility and computing power of the brain. Erişim adresi: <https://www.advancedsciencenews.com/artificial-neural-networks-that-mimic-the-flexibility-and-computing-power-of-the-brain/>

Bilgin, M. (2017). Gerçek veri setlerinde klasik makine öğrenmesi yöntemlerinin performans analizi. Breast, 2(9), 683. Erişim adresi: <https://ab.org.tr/ab17/bildiri/101.pdf>

Bhavsar, H., & Ganatra, A. (2012). A comparative study of training algorithms for supervised machine learning. International Journal of Soft Computing and Engineering (IJSCE), 2(4), 2231-2307. Erişim adresi: <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=18ca69ec35a0ab52922cb8a81d5041ac99005f3a>

Brynjolfsson, Erik, Tom Mitchell, and Daniel Rock. 2018. "What Can Machines Learn, and What Does It Mean for Occupations and the Economy?" AEA Papers and Proceedings, 108: 43-47. Erişim adresi: <https://www.aeaweb.org/articles/pdf/doi/10.1257/pandp.20181019>

Bagnell, J. A. (2005, July). Robust supervised learning. In AAAI (pp. 714-719). Erişim adresi: <https://cdn.aaai.org/AAAI/2005/AAAI05-112.pdf>

Botao Zhong, Xing Pan, Peter E.D. Love, Lieyun Ding, Weili Fang, Deep learning and network analysis: Classifying and visualizing accident narratives in construction, Automation in Construction, Volume 113, 2020, 103089,ISSN 0926-5805. doi: <https://doi.org/10.1016/j.autcon.2020.103089>

Barani, R.; Lakshmi, V.J. Oil well monitoring and control based on wireless sensor networks using Atmega 2560 controller. Int. J. Comput. Sci. Commun. Netw. 2013, 3, 341. Erişim adresi: <https://www.semanticscholar.org/paper/Oil-Well-Monitoring-and-Control-Based-on-Wireless-Barani-lakshmi/6dab898aecc3a91908202c08faa12b7f7866bc82>

Bekiaris, E.; Amditis, A.; Wevers, K. Advanced driver monitoring-the awake project. In Proceedings of the 8th World Congress on ITS, Sydney, Australia, 30 September–4 October 2001. Erişim adresi: <https://trid.trb.org/View/742734>

Britton, J.W.; Frey, L.C.; Hopp, J.L.; Korb, P.; Koubeissi, M.Z.; Lievens, W.E.; Pestana-Knight, E.M.; St. Louis, E.K. Electroencephalography (EEG): An Introductory Text. and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants; American Epilepsy Society: Chicago, IL, USA, 2016. Erişim adresi: <https://europemc.org/article/nbk/nbk390354>

Bretzner, L.; Krantz, M. Towards low-cost systems for measuring visual cues of driver fatigue and inattention in automotive applications. In Proceedings of the IEEE International Conference on Vehicular Electronics and Safety, Xi'an, Shaan'xi, China, 14–16 October 2005; pp. 161–164. Erişim adresi: <https://c85689232ea394a8dc08a512c1f46793a2397178.vetisonline.com/stamp/stamp.jsp?tp=&arnumber=1563634>

Çelik, N. (2019). Sanayinin geleceği Endüstri 4.0 ve iş sağlığı ve güvenliği. Doktora tezi. İstanbul Medeniyet Üniversitesi, Lisansüstü Eğitim Enstitüsü, İş Sağlığı Ve Güvenliği Anabilim Dalı. İstanbul, Türkiye. Erişim adresi: https://acikbilim.yok.gov.tr/bitstream/handle/20.500.12812/116492/yokAcikBilim_10269958.pdf?sequence=1&isAllowed=y

Chao, W. L. , 2011. Machine Learning Tutorial. Erişim adresi: <https://cdn.geccacademy.cn/oa/upload/2021-09-28%2011-54-57-Machine%20Learning%20Tutorial.pdf>

Choudhary, R., & Gianey, H. K. (2017, December). Comprehensive review on supervised machine learning algorithms. In 2017 International Conference on Machine Learning and Data Science (MLDS) (pp. 37-43). IEEE. Erişim adresi: <https://c85689232ea394a8dc08a512c1f46793a2397178.vetisonline.com/stamp/stamp.jsp?tp=&arnumber=8320256>

Ciortuz, L. Support Vector Machines for MicroRNA Identification, 2008. Erişim adresi: <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=01652570befe1ef844cc60ec50a64ebd32dd62d1>

Calvo, A.; Romano, E.; Preti, C.; Schillaci, G.; Debolli, R. Upper limb disorders and hand-arm vibration risks with hand-held olive beaters. *Int. J. Ind. Ergon.* 2018, 65, 36–45. doi: <https://doi.org/10.1016/j.ergon.2018.01.018>

Cheng, B.; Zhang, W.; Lin, Y.; Feng, R.; Zhang, X. Driver drowsiness detection based on multisource information. *Hum. Factors Ergon. Manuf. Serv. Ind.* 2012, 22, 450–467. doi: <https://doi.org/10.1002/hfm.20395>

Doğan, F., & Türkoğlu, İ. (2018). Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının Karşılaştırılması. *Sakarya University Journal Of Computer And Information Sciences*, 1(1), 10-21. Erişim adresi: <http://saucis.sakarya.edu.tr/en/download/article-file/479189>

De Luca, C.J. Myoelectrical manifestations of localized muscular fatigue in humans. *Crit. Rev. Biomed. Eng.* 1984, 11, 251–279. Erişim adresi: <https://europepmc.org/article/med/6391814>

Dwivedi, K.; Biswaranjan, K.; Sethi, A. Drowsy driver detection using representation learning. In *Proceedings of the 2014 IEEE International Advance Computing Conference (IACC)*, Gurgaon, New Delhi, India, 21–22 February 2014; pp. 995–999. Erişim tarihi: <https://c85689232ea394a8dc08a512c1f46793a2397178.vetisonline.com/stamp/stamp.jsp?tp=&arnumber=6779459>

Dorman P. Estimating the economic costs of occupational injuries and diseases in developing countries: essential information for decision makers. Geneva: International Labor Organization; 2012. Erişim adresi: https://www.ilo.org/wcmsp5/groups/public/---ed_protect/---protrav/---safework/documents/publication/wcms_207690.pdf

EU OSHA (European Occupational Health and Safety Agency). An international comparison of the costs of occupational accidents and sickness. 2017. Erişim adresi: https://osha.europa.eu/sites/default/files/2021-11/international_comparison-of_costs_work_related_accidents.pdf

EU-OSHA, Smart Digital Monitoring Systems For Occupational Safety And Health: Optimising The Uptake. Erişim adresi: https://osha.europa.eu/sites/default/files/Smart-digital-monitoring-systems-Optimising-the-uptake_en.pdf

Freitas, G.; Zhang, J.; Hamner, B.; Bergerman, M.; Kantor, G. A low-cost, practical localization system for agricultural vehicles. In *Proceedings of the International Conference on Intelligent Robotics and Applications*, Montreal, QC, Canada, 3–5 October 2012; pp. 365–375. Erişim tarihi: https://link.springer.com/chapter/10.1007/978-3-642-33503-7_36

Furugori, S.; Yoshizawa, N.; Iname, C.; Miura, Y. Estimation of driver fatigue by pressure distribution on seat in long term driving. *Rev. Automot. Eng.* 2005, 26, 53–58. Erişim adresi: https://www.researchgate.net/publication/294656833_Estimation_of_driver_fatigue_by_pressure_distribution_on_seat_in_long_term_driving

Freitas, G.; Zhang, J.; Hamner, B.; Bergerman, M.; Kantor, G. A low-cost, practical localization system for agricultural vehicles. In *Proceedings of the International Conference on Intelligent Robotics and Applications*, Montreal, QC, Canada, 3–5 October 2012; pp. 365–375. Erişim adresi: https://link.springer.com/chapter/10.1007/978-3-642-33503-7_36

Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1). Cambridge: MIT press.

Ghasemi, E.; Ataei, M.; Shahriar, K.; Sereshki, F.; Jalali, S.E.; Ramazanzadeh, A. Assessment of roof fall risk during retreat mining in room and pillar coal mines. *Int. J. Rock Mech. Min. Sci.* 2012, 54, 80–89. doi: <https://doi.org/10.1016/j.ijrmms.2012.05.025>

Gengler, A. Are you on Track? *Money* 2007. p. 114. Available online. Erişim adresi: https://money.cnn.com/magazines/moneymag/moneymag_archive/2007/01/01/8397408/index.htm

Gibson, R.M.; Amira, A.; Ramzan, N.; Casaseca-de-la-Higuera, P.; Pervez, Z. Multiple comparator classifier framework for accelerometer-based fall detection and diagnostic. *Appl. Soft Comput.* 2016, 39, 94–103. doi: <https://doi.org/10.1016/j.asoc.2015.10.062>

Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554. doi: <https://doi.org/10.1162/neco.2006.18.7.1527>

Hernán M.A., J. Hsu, B. Healy A second chance to get causal inference right: A classification of data science tasks *Chance*, 32 (1) (2019), pp. 42-49. doi: <https://doi.org/10.1080/09332480.2019.1579578>

ILO, World Statistic. Erişim adresi: https://www.ilo.org/moscow/areas-of-work/occupational-safety-and-health/WCMS_249278/lang--en/index.htm

Ingram, R. (2014). DoC Professor disputes whether computer ‘Eugene Goostman’ passed Turing Test. Imperial College London.

Issa, S.F.; Patrick, K.; Thomson, S.; Rein, B. Estimating the Number of Agricultural Fatal Injuries Prevented by Agricultural Engineering Developments in the United States. *Safety* 2019, 5, 63. Erişim adresi: <https://www.mdpi.com/2313-576X/5/4/63>

J. Wu, J. He ve Y. Todo, " Dendritic neuron model is a universal predictor ", 2019 6. Uluslararası Sistemler ve Bilişim Konferansı (ICSAI) , 2019, s. 589-594. Erişim adresi: https://www.researchgate.net/publication/339556596_The_dendritic_neuron_model_is_a_universal_approximator

J. Alzubi, A. Nayyar, A. Kumar, *Journal of Physics: Conference Series* , Volume 1142 , Second National Conference on Computational Intelligence (NCCI 2018), IOP Publishing Ltd. Erişim adresi: <https://iopscience.iop.org/article/10.1088/1742-6596/1142/1/012012/pdf>

Javapoint , Artificial Neural Network Tutorial. Erişim adresi: <https://www.javatpoint.com/artificial-neural-network>

Jiang T., Jaimie L. Gradus, Anthony J. Rosellini, *Supervised Machine Learning: A Brief Primer*, Behavior Therapy, Volume 51, Issue 5, 2020, Pages 675-687, ISSN 0005-7894. Erişim adresi: <https://pubmed.ncbi.nlm.nih.gov/32800297/>

Jung, J.; Song, B. The possibility of wireless sensor networks for industrial pipe rack safety monitoring. In Proceedings of the 2014 47th Hawaii International Conference on System Sciences, Waikoloa, HI, USA, 6–9 January 2014; pp. 5129–5134.

Johnson, L. GPS in mining. *Mining Magazine*, 7 August 1998; 387–389.

Jones, K.W. Environmental Sensors. In *Sensors: Micro- and Nanosensor Technology-Trends in Sensor Markets*; Meixner, H., Jones, R., Eds.; Wiley-VCH: Weinheim, Germany, 1995; pp. 451–489.

Jian, H.; Chen, H. A portable fall detection and alerting system based on k-NN algorithm and remote medicine. *China Commun.* 2015, 12, 23–31. Erişim adresi: https://www.researchgate.net/publication/277562142_A_Portable_Fall_Detection_and_Alerting_System_Based_on_k-NN_Algorithm_and_Remote_Medicine

Körber, M.; Cingel, A.; Zimmermann, M.; Bengler, K. Vigilance decrement and passive fatigue caused by monotony in automated driving. *Procedia Manuf.* 2015, 3, 2403–2409. doi: <https://doi.org/10.1016/j.promfg.2015.07.499>

Kaida, K.; Takahashi, M.; Åkerstedt, T.; Nakata, A.; Otsuka, Y.; Haratani, T.; Fukasawa, K. Validation of the Karolinska sleepiness scale against performance and EEG variables. *Clin. Neurophysiol.* 2006, 117, 1574–1581. doi: <https://doi.org/10.1016/j.clinph.2006.03.011>

Khan, S.S.; Hoey, J. Review of fall detection techniques: A data availability perspective. *Med. Eng. Phys.* 2017, 39, 12–22. doi: <https://doi.org/10.1016/j.medengphy.2016.10.014>

Kaynar, O., Görmez, Y., Yıldız, M., & Albayrak, A. (2016, September). Makine öğrenmesi yöntemleri ile Duygu Analizi. In *International Artificial Intelligence and Data Processing Symposium (IDAP'16)* (Vol. 17, No. 18, pp. 17-18). Erişim adresi: https://www.researchgate.net/profile/Yasin-Goermez/publication/311136507_Makine_Ogrenmesi_Yontemleri_ile_Duygu_Analizi_-_Sentiment_Analysis_with_Machine_Learning_Techniques/links/583eaaac08ae8e63e617b96c/Makine-Oegrenmesi-Yoentemleri-ile-Duygu-Analizi-Sentiment-Analysis-with-Machine-Learning-Techniques.pdf

Leigh, J., Macaskill, P., Kuosma, E., & Mandryk, J. (1999). Global burden of disease and injury due to occupational factors. *Epidemiology*, 626-631. Erişim adresi: https://journals.lww.com/epidem/abstract/1999/09000/global_burden_of_disease_and_injury_due_to.32.aspx

Li, G.; Chung, W.-Y. Detection of Driver Drowsiness Using Wavelet Analysis of Heart Rate Variability and a Support Vector Machine Classifier. *Sensors* 2013, 13, 16494–16511. doi: <https://doi.org/10.3390/s131216494>

Lee, Y.-C.; Shariatfar, M.; Rashidi, A.; Lee, H.W. Evidence-driven sound detection for prenotification and identification of construction safety hazards and accidents. *Autom. Constr.* 2020, 113, 103127. doi: <https://doi.org/10.1016/j.autcon.2020.103127>

Lyons PG, Arora VM, Farnan JM. Adverse events and near-misses relating to intensive care unit–ward transfer: a qualitative analysis of resident perceptions. *Ann Am Thorac Soc.* 2016;13:570–572. doi: <https://doi.org/10.1513/AnnalsATS.201512-789LE>

Lilley R, Feyer AM, Kirk P, et al. A survey of forest workers in New Zealand: do hours of work, rest, and recovery play a role in accidents and injury? *J Safety Res.* 2002;33:53–71. doi: [https://doi.org/10.1016/S0022-4375\(02\)00003-8](https://doi.org/10.1016/S0022-4375(02)00003-8)

Lundqvist P, Gustafsson B. Accidents and accident prevention in agriculture a review of selected studies. *Int J Ind Ergonom.* 1992;10:311–319. doi: [https://doi.org/10.1016/0169-8141\(92\)90098-K](https://doi.org/10.1016/0169-8141(92)90098-K)

Muhammad, L. J., Algehyne, E. A., Usman, S. S., Ahmad, A., Chakraborty, C., & Mohammed, I. A. (2021). Supervised machine learning models for prediction of COVID-19 infection using epidemiology dataset. *SN computer science*, 2(1), 1-13. Erişim adresi: https://link.springer.com/article/10.1007/s42979-020-00394-7%23auth-L_J_-Muhammad

Muhammad, S., Petridis, A., Cornelius, J. F., & Hänggi, D. (2020). Letter to editor: Severe brain haemorrhage and concomitant COVID-19 Infection: A neurovascular complication of COVID-19. *Brain, behavior, and immunity*, 87, 150. Erişim adresi: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7199686/>

Moor, James. *AI MAGAZINE*; WIN 2006; 27; 4; p87-p91.

Mardonova, M.; Choi, Y. Review of Wearable Device Technology and Its Applications to the Mining Industry. *Energies* 2018, 11, 547 doi: <https://doi.org/10.3390/en11030547>

Mubashir, M.; Shao, L.; Seed, L. A survey on fall detection: Principles and approaches. *Neurocomputing* 2013, 100, 144–152. doi: <https://doi.org/10.1016/j.neucom.2011.09.037>

Marsh P, Kendrick D. Near miss and minor injury information - can it be used to plan and evaluate injury prevention programmes? *Accident Anal Prev.* 2000;32:345–354. doi: [https://doi.org/10.1016/S0001-4575\(99\)00054-8](https://doi.org/10.1016/S0001-4575(99)00054-8)

Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons. b*, 4, 51-62. Erişim adresi: https://www.researchgate.net/profile/Vladimir-Nasteski/publication/328146111_An_overview_of_the_supervised_machine_learning_methods/links/5c1025194585157ac1bba147/An-overview-of-the-supervised-machine-learning-methods.pdf

Number and Rate of Occupational Mining Fatalities by Year, 1983–2019. Erişim adresi: <https://www.cdc.gov/NIOSHMining/MMWC/Fatality/NumberAndRate>

Osisanwo, F. Y., Akinsola, J. E. T., Awodele, O., Hinmikaiye, J. O., Olakanmi, O., & Akinjobi, J. (2017). Supervised machine learning algorithms: classification and comparison. *International Journal of Computer Trends and Technology (IJCTT)*, 48(3), 128-138. Erişim adresi: https://www.researchgate.net/profile/J-E-T-Akinsola/publication/318338750_Supervised_Machine_Learning_Algorithms_Classification_and_Comparison/links/596481dd0f7e9b819497e265/Supervised-Machine-Learning-Algorithms-Classification-and-Comparison.pdf

Ozigis, M.S.; Kaduk, J.D.; Jarvis, C.H. Mapping terrestrial oil spill impact using machine learning random forest and Landsat 8 OLI imagery: A case site within the Niger Delta region of Nigeria. *Environ. Sci. Pollut. Res. Int.* 2019, 26, 3621–3635. Erişim adresi: <https://link.springer.com/article/10.1007/s11356-018-3824-y>

Ozcan, K.; Velipasalar, S. Wearable camera-and accelerometer-based fall detection on portable devices. *IEEE Embed. Syst. Lett.* 2015, 8, 6–9. Erişim adresi: <https://c85689232ea394a8dc08a512c1f46793a2397178.vetisonline.com/stamp/stamp.jsp?tp=&arnumber=7289390>

Özgür, A. , 2004. Supervised and unsupervised machine learning techniques for text document categorization, Doktora Tezi-Bogaziçi Üniversitesi.

Özden, C., & Çiğdem, A. C. I. (2018). Makine öğrenmesi yöntemleri ile yaralanmalı trafik kazalarının analizi: Adana örneği. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(2), 266-275. Erişim adresi: <https://dergipark.org.tr/en/download/article-file/465768>

Peres R.S., X. Jia, J. Lee, K. Sun, AW Colombo ve J. Barata, "Industrial artificial intelligence in Industry 4.0 - Systematic Review, Challenges and Outlook", *IEEE Access* , cilt. 8, s. 220121-220139, 2020, Erişim adresi: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9285283>

Pishgar, M., Issa, S. F., Sietsema, M., Pratap, P., & Darabi, H. (2021). REDECA: a novel framework to review artificial intelligence and its applications in occupational safety and health. *International journal of environmental research and public health*, 18(13), 6705. Erişim adresi: <https://www.mdpi.com/1660-4601/18/13/6705>

Priyadarshy, S. IoT revolution in oil and gas industry. In *Internet of Things and Data Analytics Handbook*; Wiley Telecom: New York, NY, USA, 2017; pp. 513–520. doi: <https://doi.org/10.1002/9781119173601.ch31>

Parate, A.; Ganesan, D. Detecting Eating and Smoking Behaviors Using Smartwatches. In *Mobile Health*; Springer: Berlin/Heidelberg, Germany, 2017; pp. 175–201. Erişim adresi: <https://people.cs.umass.edu/~dganesan/papers/mHealthBook-Parate17.pdf>

Phimister JR, Oktem U, Kleindorfer PR, et al. Near-miss system analysis: phase I. Philadelphia (PA): Wharton School, Center for Risk Management and Decision Processes; 2000. doi: <https://doi.org/10.1111/1539-6924.00326>

Rimminen, H.; Lindström, J.; Linnavuo, M.; Sepponen, R. Detection of falls among the elderly by a floor sensor using the electric near field. *IEEE Trans. Inf. Technol. Biomed.* 2010, 14, 1475–1476. Erişim adresi: <https://c85689232ea394a8dc08a512c1f46793a2397178.vetisonline.com/stamp/stamp.jsp?tp=&arnumber=5477180>

Reason JT. *Managing the risks of organizational accidents*. Aldershot: Ashgate; 1997.

Reason, J. The Contribution of Latent Human Failures to the Breakdown of Complex Systems. *Philos. Trans. R. Soc. Lond. Ser. B* 1990, 327, 475–484. Erişim adresi: <https://royalsocietypublishing.org/doi/epdf/10.1098/rstb.1990.0090>

Raviv, G., Fishbain, B., & Shapira, A. (2017). Analyzing risk factors in crane-related near-miss and accident reports. *Safety science*, 91, 192-205. doi: <https://doi.org/10.1016/j.ssci.2016.08.022>

Singh A., N. Thakur and A. Sharma, "A review of supervised machine learning algorithms," 2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom), 2016, pp. 1310-1315. Erişim adresi: <https://c85689232ea394a8dc08a512c1f46793a2397178.vetisonline.com/stamp/stamp.jsp?tp=&arnumber=7727382>

Suthaharan, S. (2016). *Supervised learning algorithms*. In *Machine learning models and algorithms for big data classification* (pp. 183-206). Springer, Boston, MA.

Shetty, S. H., Shetty, S., Singh, C., & Rao, A. (2022). *Supervised Machine Learning: Algorithms and Applications. Fundamentals and Methods of Machine and Deep Learning: Algorithms, Tools and Applications*, 1-16. doi: <https://doi.org/10.1002/9781119821908.ch1>

Sakhakarmi, S.; Park, J.; Cho, C. Enhanced machine learning classification accuracy for scaffolding safety using increased features. *J. Constr. Eng. Manag.* 2019, 145, 04018133. doi: [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0001601](https://doi.org/10.1061/(ASCE)CO.1943-7862.0001601)

Takala J., Päivi Hämäläinen, Kaija Leena Saarela, Loke Yoke Yun, Kathiresan Manickam, Tan Wee Jin, Peggy Heng, Caleb Tjong, Lim Guan Kheng, Samuel Lim & Gan Siok Lin (2014) Global Estimates of the Burden of Injury and Illness at Work in 2012, *Journal of Occupational and Environmental Hygiene*, 11:5, 326-337. doi: <https://doi.org/10.1080/15459624.2013.863131>

Tkach, I.; Bechar, A.; Edan, Y. Switching between collaboration levels in a human–robot target recognition system. *IEEE Trans. Syst. Man Cybern. Part C (Appl. Rev.)* 2011, 41, 955–967. Erişim adresi: <https://c85689232ea394a8dc08a512c1f46793a2397178.vetisonline.com/stamp/stamp.jsp?tp=&arnumber=5740373>

Tompa, E., Mofidi, A., van den Heuvel, S. ve ark. İş yaralanmaları ve hastalıklarının ekonomik yükü: beş Avrupa Birliği ülkesinde bir çerçeve ve uygulama. BMC Halk Sağlığı 21, 49 (2021). Erişim adresi: <https://745e9234ede24d509e2ae15e4d48ef6be2b3b85c.vetisonline.com/article/10.1186/s12889-020-10050-7>

Turhost, Makine Öğrenmesi. Erişim adresi: <https://www.turhost.com/blog/makine-ogrenmesi-machine-learning-nedir/>

Towardsdatascience, Understanding Confusion Matrix. Erişim adresi: <https://towardsdatascience.com/understanding-confusion-matrix-a9ad42dcfd62>

Uth HJ, Wiese N. Central collecting and evaluating of major accidents and near-miss-events in the Federal Republic of Germany - results, experiences, perspectives. J Hazard Mater. 2004;111:139–145. Erişim adresi: <https://doi.org/10.1016/j.jhazmat.2004.02.022>

V7labs, Görüntü Tanıma Tanımı, Algoritmaları ve Kullanımları. Erişim adresi: <https://www.v7labs.com/blog/image-recognition-guide>

Wang, J. Electrochemical biosensors: Towards point-of-care cancer diagnostics. Biosens. Bioelectron. 2006, 21, 1887–1892. doi: <https://doi.org/10.1016/j.bios.2005.10.027>

Wright L, Schaaf T. Accident versus near miss causation: a critical review of the literature, an empirical test in the UK railway domain, and their implications for other sectors. J Hazard Mater. 2004;111:105–110. doi: <https://doi.org/10.1016/j.jhazmat.2004.02.049>

Wu W, Gibb AG, Li Q. Accident precursors and near misses on construction sites: an investigative tool to derive information from accident databases. Safety Sci. 2010;48:845–858. doi: <https://doi.org/10.1016/j.ssci.2010.04.009>

Wu, W., Yang, H., Chew, D. A., Yang, S. H., Gibb, A. G., & Li, Q. (2010). Towards an autonomous real-time tracking system of near-miss accidents on construction sites. Automation in Construction, 19(2), 134-141. doi: <https://doi.org/10.1016/j.autcon.2009.11.017>

Webtekno. Erişim adresi: <https://www.webtekno.com/turing-testi-gelisen-robotik-bilimi-nedeniyle-guncelleniyor-h73504.html>

Xin Zhang, Wang Dahu, Application of artificial intelligence algorithms in image processing, Journal of Visual Communication and Image Representation, Volume 61, 2019, Pages 42-49, ISSN 1047-3203. doi: <https://doi.org/10.1016/j.jvcir.2019.03.004>

Yu, H.; Guo, M. An efficient oil and gas pipeline monitoring systems based on wireless sensor networks. In Proceedings of the 2012 International Conference on Information Security and Intelligent Control, Yunlin, Taiwan, 14–16 August 2012; pp. 178–181. Erişim adresi: <https://c85689232ea394a8dc08a512c1f46793a2397178.vetisonline.com/stamp/stamp.jsp?tp=&arnumber=6449735>

Yu, X. Approaches and principles of fall detection for elderly and patient. In Proceedings of the HealthCom 2008-10th International Conference on E-health Networking, Applications and Services, Singapore, 7–9 July 2008; pp. 42–47. Erişim adresi: <https://c85689232ea394a8dc08a512c1f46793a2397178.vetisonline.com/stamp/stamp.jsp?tp=&arnumber=4600107>

Yang, K.; Ahn, C.R.; Kim, H. Validating ambulatory gait assessment technique for hazard sensing in construction environments. Autom. Constr. 2019, 98, 302–309. doi: <https://doi.org/10.1016/j.autcon.2018.09.017>

Yokoyama, K., Iijima, S., Ito, H., & Kan, M. (2013). The socio-economic impact of occupational diseases and injuries. Industrial health, 51(5), 459–461. Erişim adresi: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4202730/>

Zhang, S.; Teizer, J.; Lee, J.-K.; Eastman, C.M.; Venugopal, M. Building Information Modeling (BIM) and Safety: Automatic Safety Checking of Construction Models and Schedules. *Autom. Constr.* 2013, 29, 183–195. doi: <https://doi.org/10.1016/j.autcon.2012.05.006>

Zhang, M.; Cao, T.; Zhao, X. Using Smartphones to Detect and Identify Construction Workers' Near-Miss Falls Based on ANN. *J. Constr. Eng. Manag.* 2019, 145, 04018120. doi: [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0001582](https://doi.org/10.1061/(ASCE)CO.1943-7862.0001582)