

# Makine Öğrenme Teknikleriyle Hemşirelerin Stres Düzeylerinin Belirlenmesi: Hemşirelikte Yapay Zekâ Uygulamaları: Tanımlayıcı Araştırma

## Determining Stress Levels of Nurses with Machine Learning Techniques: Artificial Intelligence Applications in Nursing: Descriptive Research

<sup>ID</sup> Aysun BADEM<sup>a</sup>, <sup>ID</sup> Abdullah ÇALIŞKAN<sup>b</sup>

<sup>a</sup>Kahramanmaraş Sütçü İmam Üniversitesi Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü, Doğum ve Kadın Hastalıkları Hemşireliği AD, Kahramanmaraş, Türkiye

<sup>b</sup>Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Kahramanmaraş, Türkiye

**ÖZET Amaç:** Stres her meslek grubunun ve günümüzün en ciddi problemlerinden biridir. Hemşirelik en stresli meslek gruplarından biridir. Yapay zekânın sağladığı etkin sonuçlar hemşirelerin stres düzeylerinin belirlenmesinde çağdaş yöntem olarak öne çıkmaktadır. Bu çalışmada, hemşirelerin stres düzeylerinin yapay zekâ uygulamalarından makine öğrenme teknikleri ile en etkin şekilde sınıflandırılması amaçlanmıştır. Ayrıca bu çalışma ile hemşirelik alanında yapay zekânın kullanım alanları konusunda bakış açısının genişletilmesi amaçlanmaktadır. **Gereç ve Yöntemler:** Çalışmada, hemşirelerde strese neden olabilecek durumlar ve stres düzeylerinin yer aldığı açık erişimli bir veri seti kullanılmıştır. Açık veri setinde; aktif çalışan 15 hemşireye Empatica E4 bilekliği takılmıştır ve fizyolojik değişkenleri toplamda 1.250 saat izlenmiştir. Ayrıca hemşirelerden stres sırasındaki deneyimleri ile ilgili bir anket doldurmaları istenmiştir. Çalışmada hemşirelerin stres düzeylerinin belirlenmesinde makine öğrenme tekniklerinden En Yakın Komşu Algoritması [K-Nearest Neighbors (KNN)], Yapay Sinir Ağları [Neural Networks (NN)], Karar Ağacı [Decision Tree (DT)], Güçlendirilmiş Ağaç [Boosted trees (BT)], Destek Vektör Makineler [Support Vector Machines (SVM)] modelleri karşılaştırılmıştır. **Bulgular:** Modeller arasında yapılan karşılaştırmada stres düzeyini en iyi sınıflandırma performansına sahip makine öğrenme tekniğinin SVM olduğu belirlenmiştir. DT, NN ve BT yöntemlerinin de iyi performansa sahip olduğu belirlenmiştir. KNN'nin tutarsız ve düşük sınıflandırma performansı sergilediği belirlenmiştir. **Sonuç:** Hemşirelerin stres düzeylerinin belirlenmesinde makine öğrenme tekniği SVM kullanılabilir. Alternatif olarak DT, NN ve BT yöntemleri kullanılabilir. Çalışmamızda hemşirelerin stres düzeylerinin en iyi şekilde belirlenmesi, gerekli önlemlerin alınması açısından fayda sağlayacaktır.

**ABSTRACT Objective:** Stress is one of the most serious problems of every professional group and today. Nursing is the most stressful professions. The effective results provided by artificial intelligence stand out as a contemporary method in determining the stress levels of nurses. This study, aims to classify the stress levels of nurses in the most effective way with machine learning techniques from artificial intelligence applications. In addition, this study, aims to expand the perspective on the areas of use of artificial intelligence in the field of nursing. **Material and Methods:** An open access data set containing the situations to be cause stress in nurses and their stress levels was used in the study. In the open dataset; 15 active nurses were fitted with Empatica E4 bracelets and their physiological variables were monitored for a total of 1,250 hours. The nurses were also asked to fill out a questionnaire regarding their experiences during stress. In the study, K-Nearest Neighbors (KNN), Neural Networks (NN), Decision Tree (DT), Boosted trees (BT), Support Vector Machines (SVM) models from machine learning techniques were compared in determining the stress levels of nurses. **Results:** In the comparison between the models, it was determined that the machine learning technique with the best classification performance of the stress level was SVM. It was determined that DT, NN and BT methods also had good performance. It was determined that KNN exhibited inconsistent and low classification performance. **Conclusion:** The machine learning technique SVM can be used to determine the stress levels of nurses. Alternatively, DT, NN and BT methods can be used. In our study, determining the stress levels of nurses in the best way will be beneficial in terms of taking the necessary precautions.

**Anahtar Kelimeler:** Hemşirelik; stres; yapay zekâ

**Keywords:** Nursing; stress; artificial intelligence

**KAYNAK GÖSTERMEK İÇİN:**

Badem A, Çalışkan A. Makine öğrenme teknikleriyle hemşirelerin stres düzeylerinin belirlenmesi: Hemşirelikte yapay zekâ uygulamaları: Tanımlayıcı araştırma. Türkiye Klinikleri J Nurs Sci. 2025;17(1):69-78.

**Correspondence:** Aysun BADEM

Kahramanmaraş Sütçü İmam Üniversitesi Sağlık Bilimleri Fakültesi, Hemşirelik Bölümü,  
Doğum ve Kadın Hastalıkları Hemşireliği AD, Kahramanmaraş, Türkiye

**E-mail:** aysunbadem87@gmail.com



Peer review under responsibility of Türkiye Klinikleri Journal of Nursing Sciences.

**Received:** 14 Jun 2024

**Received in revised form:** 17 Sep 2024

**Accepted:** 31 Oct 2024

**Available online:** 20 Nov 2024

2146-8893 / Copyright © 2025 by Türkiye Klinikleri. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

Hemşirelik, zihinsel ve bedensel süreçlerin sürekli aktif olması gereken çeşitli uyaranlarla karşılaşılan, stresli meslek gruplarından biridir. Dünyada ruh sağlığı sorunları sağlık çalışanları arasında giderek artmaktadır. Hemşireler çeşitli sebepler nedeniyle stres ve tükenmişlik konularında yüksek risk altındadır. Yapılan çalışmalar, hemşirelerin stres düzeyinin yüksek olduğunu göstermektedir.<sup>1-3</sup> Literatürde hemşirelerin stres durumları ile ilgili pek çok çalışma bulunmaktadır.<sup>4-7</sup> Bunlar; uzun, vardiyalı ve yoğun çalışma saatleri, hasta bireylerle bir arada olma, hızlı duygusal geçişler yaşama, çalışma ortamı, sürekli insanlarla iletişim hâlinde olma, riskli mesleki uygulamalar, güvenlik problemleri, sorumluluk alma, ekip uyumu, bilgi ve destek eksikliği hissetme, rol çatışmaları ve yetki problemleri, statü uyumsuzluğu, mesleki tanımlamaların yetersizliği, kurumda kültürel yapı gibi nedenlerdir.<sup>3,8,9</sup> Bunların yanı sıra hemşireler arasında stres faktörünü; aile ve sosyal yaşantıdaki stresler, deneyimler, stresle baş etme becerileri, kendi hastalıkları gibi bireysel faktörler de etkilemektedir.<sup>3</sup>

Hemşirelik, kadınların yoğunlukta olduğu bir meslek grubudur. Literatürde kadınlarda ruhsal bozukluklar ve depresyon yaşama olasılığının daha yüksek olduğu belirtilmektedir.<sup>10,11</sup> Hemşirelik alanında yapılan 429 yüksek lisans tezinin incelendiği çalışmada; genel olarak stres, depresyon ve koronavirüs hastalığı-2019 [coronavirus disease-2019 (COVID-19)] korkusunun kadınlarda yüksek olduğu, yoğun bakımda çalışan hemşirelerin olumsuz algı düzeylerinin daha yüksek olduğu belirlenmiştir.<sup>12</sup> Şiddetli strese maruz kalma, özellikle depresyon olmak üzere kişinin yaşam kalitesini etkileyen ruhsal bozukluklarla bağlantılı görülmektedir. Ayrıca pandemi, savaş, göç, depremler gibi kendileri ve ailelerinin de etkilediği durumlarda iş yüklerinin artarak devam etmesi hemşireleri daha da stresli bir iş yaşamına sürüklemektedir.<sup>8</sup> Stres iş doyumu, iş performansı ve işe bağlılık gibi durumları etkileyebilmektedir.<sup>13</sup> Hemşirelerde işe bağlı stres, düşük iş tatminiyle ve düşük iş yaşam kalitesiyle ilişkili bulunmuştur.<sup>14</sup> Chaabane ve ark.nın çalışmasında, hemşirelik öğrencilerinde de stres düzeylerinin yüksek olduğu belirtilmektedir.<sup>15</sup> Sağlık sisteminin sayıca büyük kısmını hemşirelerin oluşturduğu dikkate alınırsa, sağlık

bakım hizmetlerinin sistematik şekilde ilerlemesi açısından hemşirelerin stres düzeylerinin belirlenmesi ve buna yönelik önlemler alınması oldukça önemlidir.

Bilişim teknolojileri ve yapay zekânın hızlı gelişimi son yıllarda her alanda olduğu gibi sağlık alanı araştırmalarında da sıklıkla gözlenmektedir. Yapay zekâ, bilgisayar sistemlerinin insana benzer şekilde karar verebilme, belirleme, öğrenme, tahminlerde bulunma gibi zekâ ve yeteneklere sahip olduğu yeniliklerdir.<sup>16</sup> Yapay zekâ, derin öğrenme, makine öğrenimi ve doğal dil işleme gibi alanları içermektedir ve karmaşık verileri analiz etme yeteneğine sahiptir.<sup>17,18</sup> Tanyel'in çalışmasında, hemşirelerin stres düzeylerini belirlemek için makine öğrenmesi kullanılmıştır. Ölçeğin iki alt faktöründe yapay zekâ teknikleri kullanılarak test sonuçlarının yorumlanmasında ölçeğin doğruluğu sorgulanmış, maddelerin önem derecelerinin belirlenerek soruların öncelendirilmesi sağlanmıştır.<sup>19</sup> Yaşar'ın çalışmasında, çeşitli iş gruplarında çalışan insanların yüz görüntüleri derin öğrenme teknikleri ile Evrişimli Sinir Ağları (ESA) modeli kullanılarak FER2013 veri seti ile 7 farklı duygu tespiti ve yüz üzerindeki 68 noktadan göz, ağız, kaş aktiviteleri referans alınarak stres durum belirlenmesi yapılmıştır.<sup>20</sup> Öğrencilerin akademik başarısı ve stres arasındaki ilişkinin incelendiği başka bir çalışmada, 20 alt başlık bulunan stresle ilgili bir veri setinde "keşifsel veri analizi" kullanılmıştır. Aynı çalışmada makine öğrenme algoritmalarından; Rassal Orman, Karar Ağaçları, K-En yakın komşu ve Gaussian Naive Bayes algoritmaları karşılaştırılmış, en iyi öğrenim gösteren algoritmanın Gaussian Naive Bayes algoritması olduğu belirlenmiştir.<sup>21</sup> Giyilebilir sensörlü cihazlarla stres takibi için genelleştirilebilir makine öğrenimi kullanılan 33 çalışmanın incelendiği bir çalışmada; yüksek stres seviyelerinin çeşitli biyobelirteçlerin toplanabilmesi için müdahale içermeyen uygun yöntemler olduğu bildirilmiştir.<sup>22</sup> Stresin belirlenmesinde kullanılan biyobelirteçler; kalp atış hızı ve değişkenleri, elektrodermal aktivite, otonom sinir sistemi, bağışıklık sistemi gibi fizyolojik reaksiyonlardır. Vos ve ark.nın çalışmasında, bileğe takılan giyilebilir Empatica E4 (Empatica Inc., İtalya) cihazının iyi bir biyobelirteç olduğu ve makine öğrenmesi ile bu alanda daha çok çalışmalara ihtiyaç

duyulduğu belirtilmektedir.<sup>22</sup> Yapay zekâ ile stresin sürekli tespiti sağlanabilir, kişiye özel geri bildirimler yapılabilir. Böylece zamanında stres yönetimi sağlanabilir ve sağlık müdahaleleri geliştirilebilir. Yapay zekâ destekli çalışmaların artırılması stresin önlenmesi ve azaltılmasına da yardımcı olabilir.<sup>23</sup>

Yeni çağda teknolojik gelişim ve değişim faaliyetlerini reddetmek, yenilikleri öğrenmeye ve kullanmaya direnç göstermek imkânsızdır. Hemşirelerin son teknolojik cihazların sıklıkla güncellendiği ve neredeyse bazılarının ilk kullanım yeri olan hastanelerde teknolojik yeniliği kabullenme ve teknolojiyi etkin bir şekilde kullanmaları büyük öneme sahiptir. Bu nedenle bireylerin yeni teknolojileri kullanırken yaşadıkları stres anlamına gelen teknostres kavramı gündeme gelmiştir.<sup>24</sup> Sürekli değişen ve gelişen cihazlar, yazılımlar, barkod kayıt sistemi, ilaç/malzeme sayı takipleri, kalite sertifika beklentileri gibi stres kaynakları da göz ardı edilmemelidir. Yapay zekâ ile stres düzeyleri belirlenerek uzun stres maruziyetini engellemek için bu kliniklerle ilgili çözüm önerileri sunulabilir.

Hemşireler bakım, tedavi, toplumu bilgilendirme, eğitme ve yönlendirme görevleri ile aktif sürecin içerisinde yer almaktadır. Bu nedenle hemşirelerin stres düzeyleri, sağlık bakım hizmetlerinin devamını sağlamak ile yakından ilgilidir. Klinik araştırmalarda sıklıkla kullanılan ölçekler tek başına stresin belirlenmesinde yeterli olmayabilir. Çünkü herkesin stresi yansıtmaya ve belirtmeye isteği farklıdır. Yapay zekâ ile stres düzeylerinin belirlenmesi bu aşamada oldukça önemlidir. Ölçekle yapılan çalışmalarda anlık veriler elde edilmektedir, bu durumda farklı etkenler stres durumunu etkileyebileceğinden, gerçekleri yansıtmada kısıtlı kalabilmektedir. Gerçek stresin düzeyleri ve etkileyen faktörlerin belirlenmesinde somut ve uzun süreli yapay zekâ destekli biyolojik ölçümlerle daha güvenilir sonuçlar elde edilebilir. Bu çalışma ile makine öğrenme teknikleriyle hemşirelerin yaşadığı stres düzeylerinin belirlenmesi amaçlanmıştır.

## GEREÇ VE YÖNTEMLER

### ARAŞTIRMANIN TÜRÜ

Araştırma tanımlayıcı karşılaştırmalı tipte yapılmıştır.

### ARAŞTIRMANIN EVRENİ VE ÖRNEKLEMİ

Veriler, Hosseini ve ark.nın çalışmasında; “The University of Louisiana at Lafayette” hastanesinde çalışan yaşları 30-55 arasında değişen 15 kadın hemşireden elde edilmiştir. Çalışmada kullanılan veri seti açık erişimlidir.<sup>25</sup>

### VERİLERİN TOPLANMASI

Bu araştırmada, “Makine Öğrenimi Tabanlı Stres Tespit Modeli” kullanılmıştır.

### Makine Öğrenimi Tabanlı Stres Tespit Modeli Veri Seti

Bu araştırmada kullanılan açık veri setinde; COVID-19 salgını sırasında hastanede aktif çalışan 15 hemşireye stres sinyallerini ölçüp kayıt eden Empatica E4 (bileklik) baskın kolun bileğine takıldı. Bu stres sinyalleri; elektrodermal aktivitesi, kalp hızı ve cilt sıcaklığı gibi fizyolojik değişkenlerdi. Çalışmada hemşirenin çalışma vardiyası boyunca (genellikle 8 saat) sinyallerin sürekli olarak toplandığı 1.250 saatlik veri toplanmıştır. Stresin nedenini belirlemek için hemşirelerden, tespit edilen stres olayları sırasındaki deneyimleri hakkında bir anket doldurmaları istenmiştir. Hemşirelere stres tespitinden sonra anketleri tamamlamaları için aynı işleve sahip iki yol sunulmuştur. Bunlardan birisi özel bir mobil uygulama diğeri ise bir web uygulamasıdır. Uygulamanın uygulama mağazalarında mevcut olmaması ve telefona yüklenmesinin gerekmesi nedeniyle mobil uygulamanın telefona kurulumunun sakıncalı olduğu kararı verilmiştir. Bunun üzerine hemşireler anketi web uygulaması üzerinden doldurmuşlardır. Empatica E4 ile tespit edilen stres tepkisini doğrulamak için hemşirelerin vardiyadan sonra cep telefonlarından web uygulaması aracılığıyla anket sorularını cevaplamaları sağlanmıştır. Anket, stresi artırmamak için olay sırasında uygulanmamış, bunun yerine anket vardiyanın sonunda uygulanmıştır. Anket sırasında, (model tarafından) tespit edilen olayların listesi ve bu olayların meydana geldiği zaman yer almaktaydı. Ankette hemşirelerden modelin tespit ettiği stres olaylarını doğrulamaları ve model tarafından tespit edilemeyen stres olaylarını bildirmeleri istendi. Bu sinyaller ve hemşireler tarafından girilen tüm etiketler, makine öğrenimi tabanlı stres tespit modeline iletilmiştir. Makine öğrenimi tabanlı stres

tespit modeli, fizyolojik veriler üzerinde çalıştırılmıştır (her vardiyanın sonunda E4 bilekliklerinden toplandı). Model tarafından tespit edilen olaylar, anket aracının bir parçası olarak katılımcıya geri iletildi. Ayrıca, hemşirelerin stres yaşadıkları ek zaman dilimlerini, stres seviyesini ve strese katkıda bulunanları bildirme seçenekleri de mevcuttu. Gerçek zamanlı stres değerlendirme hemşirelere, stres altında oldukları durumları belirtmek için E4 düğmelerini kullanmaları talimatı verilirken, hemşirelerin hiçbiri bunları kullanmadı. Yanlış pozitifler, model tarafından algılanan stres olayı sırasında aslında stres altında olmadıklarını öne sürdükleri anketle belirlenmiştir. Çünkü stres anında gerçekleşen kalp atımının artması gibi fizyolojik değişiklikler, stres olmadan sadece fiziksel aktivitenin artmasından da kaynaklanabilmektedir. Çalışmada veriler, biyometrik sinyaller ve anket veri seti ile elde edilmiştir. Çalışmada stressiz, orta stresli ve yüksek stresli şeklinde etiketler yer almaktaydı. Bu çalışmada kullanılan veri seti hemşirelere uygulanan stres anketinden elde edilmiştir.<sup>25</sup>

## ARAŞTIRMANIN ETİĞİ

Bu çalışmada, Hosseini ve ark.nın çalışmasında hemşirelerden toplanan açık erişimli veriler kullanılmış ve sonuçlar makine öğrenme teknikleri ile bilgisayar ortamında sınıflandırılmıştır.<sup>25</sup> Bu nedenle ayrıca etik kurul izni alınmasına gerek duyulmamıştır.

## ARAŞTIRMANIN İSTATİSTİKSEL ANALİZİ

Verilerin istatistiksel analizinde; makine öğrenme modelleri sınıflandırıcılarının performans göstergelerinde “minimum-maksimum” değerleri ve “ortalama- standart sapma” değerleri kullanılmıştır. Makine öğrenme tekniklerinin karşılaştırmalı istatistiksel sonuçları non-parametrik testlerden Mann-Whitney U testi ile belirlenmiştir.

## BULGULAR

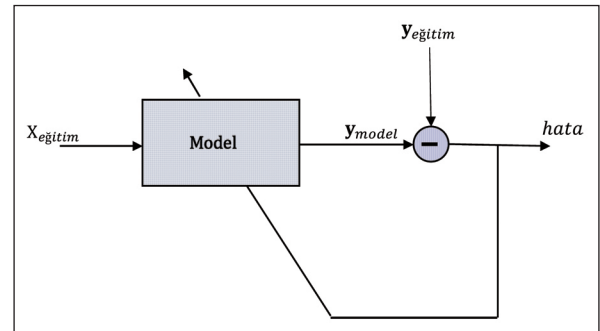
Bu çalışmada, hemşirelerin stres kaynaklarının en iyi yapay zekâ modeli ile sınıflandırılması amaçlanmıştır. Bu amaçla öncelikle uygun modelin seçimi yapılmıştır. Karşılaştırılma yapılması için uygun makine öğrenme modeli seçimi aşağıda açıklanmıştır. Bu çalışmada, optimum stres düzeyini sınıflan-

dırmak için 5 makine öğrenimi modeli karşılaştırılmıştır. Bunlar; En Yakın Komşu Algoritması [K-Nearest Neighbors (KNN)], Yapay Sinir Ağları [Neural Networks (NN)], Karar Ağacı [Decision Tree (DT)], Güçlendirilmiş Ağaç [Boosted trees (BT)], Destek Vektör Makineleridir [Support Vector Machines (SVM)].


## MODEL SEÇİMİ

Hemşirelerin stres düzeylerinin sınıflandırmasını optimum düzeyde sağlayacak makine öğrenme tabanlı modelin seçimi aşağıda açıklanmıştır. Önerilen makine öğrenme tabanlı model Şekil 1 ve Şekil 2’de gösterilmiştir. Bu modelin amacı en optimum sınıflandırıcıyı belirlemektir. Tipik bir sınıflandırıcı öncelikle bir veri setiyle eğitilir. Bu eğitim işleminden kasıt her sınıflandırıcının iç parametrelerinin optimum bir noktaya getirilmesidir.

Veri setinde bulunan anketteki sorular, hastane ortamında hemşirelerin üzerindeki stresi inceleyen literatür taramasına ve hemşirelerle yapılan görüşmelere dayanarak seçilmiştir.<sup>25-27</sup> Ankette yer alan soruların listesi aşağıda sunulmaktadır. Bu ankete göre hemşirelerin maruz kaldığı 14 farklı durum üzerinden hemşirelerdeki stres varlığı tespit edilmeye çalışılmıştır. Çalışmada elde edilen 171 saatlik verinin stresli olduğu tespit edilmiştir.<sup>25</sup>



ŞEKİL 1: Modelin eğitilmesi.



ŞEKİL 2: Modelin test edilmesi.

Veri seti aşağıdaki şekilde düzenlenmiştir:

### Çıkış verisi:

**Y:** Stres düzeyi (hemşire tarafından bildirilen stres düzeyi)

**Giriş verileri:** Hemşirelerin stresin doğasına ilişkin yanıtları

- **X1:** COVID ile ilgili
- **X2:** Bir COVID hastasını tedavi etmek
- **X3:** Krizdeki hasta
- **X4:** Hasta veya hastanın ailesi
- **X5:** Doktorlar veya meslektaşlar
- **X6:** İdare, laboratuvar, eczane, radyoloji veya diğer yardımcı hizmetler
- **X7:** Artan iş yükü
- **X8:** Teknolojiye bağlı stres
- **X9:** Sarf (a) malzemesi eksikliği
- **X10:** Dokümantasyon
- **X11:** Güvenlik (fiziksel veya fizyolojik tehditler)
- **X12:** Sarf (b) malzemesi eksikliği
- **X13:** Fiziksel çalışma veya diğerleri: iş süreçleri veya prosedürleri
- **X14:** Açıklama

Genel olarak bir sınıflandırıcı *model*  $(\theta, \mathbf{x})=y$  olarak tasarlanır. Modelin iç parametreleri  $\theta$  vektörüdür. Modelin  $\mathbf{x}$  bileşeni giriş vektörüdür,  $y$  ise çıkış olarak tanımlanır. Genel olarak bir modelin arzu edilen işlemi yapabilmesi için optimum  $\theta$  değerlerine sahip olması gerekmektedir. Optimum  $\theta$  değerlerini elde etmek için bir veri setine ihtiyaç vardır. Veri seti çözülmeye çalışılan problemde elde edilen öznitelikleri barındıran  $\mathbf{x}=[x_1 \ x_2 \dots x_n]$  vektörüne karşılık bir etikete, başka bir ifadeyle  $y$  değerine sahip olmalıdır. Bu etiket ilgili özniteliklerden elde edilen durumun sınılanması için kullanılır. Örneğin tıbbi bir veri setindeki öznitelikler hastadan alınan kan değerleri, elde edilen fizyolojik sinyaller, tıbbi görüntüler, patolojik bulgular ve hastanın bir takım fiziksel özelliklerinden yola çıkılarak oluşturulur. Normal koşullarda bir insan bir konuda birkaç öznitelik kullanarak sonuca varabilir. Bundan dolayı insan tarafından yapılan ana-

lizlerin sınırlı kalması söz konusudur. Ancak bir sınıflandırıcı onlarca, yüzlerce hatta günümüzde derin sinir ağları gibi çok gelişmiş ve kompleks modeller yüksek çözünürlüklü imgelerin her bir pikselini öznitelik olarak kullandığı için giriş vektörünün boyutu binlerle ifade edilmektedir. Dolayısıyla yapılan çalışmalarda verinin öznitelik sayısı ve örnek sayısı model seçiminde önem arz etmektedir. Bu çalışmada uygun modelin nasıl belirlendiği üzerinde ayrıca durulmuştur.

Giriş ve çıkış parametrelerinin birbirleriyle arasındaki uyumu sağlayan optimum  $\theta$  değerini bulmak için veri seti iki parçaya bölünür. Birinci parça  $\mathbf{xa}^{(i)}=[xa_1^{(i)} \ xa_2^{(i)} \dots xa_n^{(i)}]$  ve  $ya^{(i)}$  değerlerinden oluşur ve bu parçaya eğitim seti denir. İkinci parça ise  $\mathbf{xb}^{(i)}=[xb_1^{(i)} \ xb_2^{(i)} \dots xb_n^{(i)}]$  ve  $yb^{(i)}$  değerlerinden oluşur ve bu ikinci parçaya ise test seti denir. Burada belirtilen  $n$  öznitelik sayısı,  $i$  eğitim setindeki örnek sayısı,  $j$  ise test setindeki örnek sayısıdır. Genel olarak veri setinin yüzde 30'luk kısmı test verisi olarak geri kalan kısmı ise eğitim verisi olarak kullanılır. Bu çalışmada kullanılan makine öğrenimi sınıflandırma algoritmaları aşağıda açıklanmıştır.

### 1. KNN

KNN denetimli bir sınıflandırma algoritmasıdır.<sup>17,18</sup> Bu algortmada eldeki verideki her bir örneğin sınıfı belirlenirken ilgili örneğin en yakın  $k$  komşusuna bakılır. Bu algortmanın en büyük avantajı eğitim işlemine gerek duyulmamasıdır. Ancak eğitim verisi test verisinin sınılanması için tanımlanmış ve belirlenmiş olmasını gerektirir. Yeni bir noktanın sınıfı belirlenirken, bu noktanın tüm veri setindeki noktalara olan uzaklığı bir denklem yardımıyla bulunur. Bu noktaya en yakın  $k$ -komşu bulunur. Bu  $k$ -komşunun hangi sınıfa ait olduğuna göre yeni noktanın sınıfı belirlenir. Mesafe ölçütü olarak genellikle aşağıdaki denklemde olduğu gibi öklidyen mesafe kullanılır.

$$dist(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

Bu denklemde yer alan  $x$  ve  $y$  veri noktaları  $n$  ise öznitelik sayısını temsil eder. KNN algortmasının en önemli parametresi  $k$  değeridir. Küçük bir  $k$  değeri modelin gürültüye karşı daha hassas olmasına neden



olurken büyük bir  $k$  değeri sınıflar arasındaki ayrımın kaybedilmesine sebep olur. Teknik olarak  $k$  değeri örnek sayısına kadar artabilir. Bu koşullarda tüm veri seti aynı sınıfa sahip olur. Bazı özel durumlarda ağırlıklandırma parametresi kullanılır.

## 2. NN

NN, adından anlaşılacağı üzere canlıların sinir sistemlerinden esinlenilerek oluşturulmuş matematiksel bir makine öğrenmesi modelidir.<sup>17,18</sup> Bu ağlar karmaşık veri ilişkilerinin öğrenilmesi, tanımlanması ve sınıflandırılmasında sıklıkla kullanılmaktadır. Bir yapay sinir ağı temel olarak nöronlardan (düğüm) oluşur. Her bir nörona bir ağırlık ve bir bias değeri giriş olarak verilir. Bu girişlere Sigmoid, ReLU ve Tanh gibi aktivasyon fonksiyonları uygulanır ve sonuçlar bir sonraki katmandaki nöronlara iletilir. Tipik bir NN giriş katmanı, gizli katmanlar ve çıkış katmanı olmak üzere üç temel katmana sahiptir. Giriş katmanı verilerin beslendiği ilk nöron grubuna sahiptir. Gizli katman giriş katmanı ve giriş katmanları arasında olur. Bu katman birden fazla katmana da sahip olabilir. Verinin karmaşıklığına, boyutuna göre katman sayısı güncellenir ve yapay sinir ağının kapasitesi ve verimliliği artırılır. Çıkış katmanı ise son katmandır bu katmandaki nöron sayısı uğraşılacak problemdeki sınıf sayısı kadardır. Yapay sinir ağının girişine gönderilen veriler ileri doğru yayılır. Böylece ilgili giriş bir çıktı üretir. Başlangıçta bu çıktı arzu edilen çıkıştan çok farklıdır. Eğitim işlemiyle birlikte ağırlık çıkışı arzu edilen çıkışa yakınsar. Eğitim işleminde geri yayılım algoritması kullanılır. Bu algoritmanın amacı, ileri yayılımla oluşturulan çıktıların gerçek değerlerle karşılaştırılarak üretilen hata değerinin minimuma indirilmesidir. Bu hata zincir kuralı kullanılarak her bir parametreye (ağırlık ve bias) göre türevlenir. Hata sinyalleri geriye doğru yayılır, ağırlıklar ve bias hatayı azaltacak şekilde güncellenir. Bu hata azaltma işlemi bir optimizasyon yöntemiyle yapılır. Bu yöntem genellikle gradyan iniş algoritmasıyla yapılır.

## 3. DT

DT sınıflandırma ve regresyon problemlerinde yaygın biçimde kullanılır.<sup>17,18</sup> Bu algoritma veri setinden yola çıkarak ağaca benzer bir makine öğrenme yöntemi önerir. DT algoritması temel olarak dört bile-

şene sahiptir. Bunlar kök düğüm, dahili düğümler, yaprak düğümler ve dallardan oluşur. Kök düğüm ağacın en üstünü oluşturur ve veri kümesini temsil eder ilk bölünme işlemi bu kısımda gerçekleşir. Dahili düğümler kök düğümden sonra gelen alt dallara ayrılan düğümlerdir. Her bir düğüm bir öznelik kullanılarak veri kümesinin bölünmesini sağlar. Yaprak düğümler en son kısımda yer alıp etiket değerlerini ifade eder. Dalları ise düğümler arasındaki bağları temsil ederken veri kümesinin bir özneliğe göre ayrılan veri noktalarını gösterir. DT algoritmasında veri kümesini bölmek için entropi bazlı bir ölçüm olan bilgi kazancı veya verinin saflığını belirleyen gini indeksi kriteri kullanılır. Kök düğümden başlayarak ağaç en iyi bölünme kriterine göre veriyi bölmeye devam eder. Bu işlem maksimum derinlik, her yaprak için minimum örnek sayısı vb. gibi belli bir durdurma kriterine ulaşılan kadar devam eder. Aşırı öğrenmeyi engellemek için ön budama veya sonra budama işlemi yapılır.

## 4. BT

BT zayıf tahmin edici modellerin güçlerinin birleştirilmesiyle güçlü sınıflandırıcı modeli oluşturulması için kullanılır.<sup>17,18</sup> Bu yöntem güçlü bir makine öğrenmesi tekniği olarak regresyon ve sınıflandırma problemlerinde aktif biçimde kullanılmaktadır. En yaygın algoritmalar AdaBoost, Gradient Boosting ve XGBoost'tur. Boosting genellikle DT yapısında olan zayıf öğrenicilerden oluşan ensemble yöntemidir. Amaç her bir öğreticinin kendinden bir önceki öğreticinin sınıflandırma performansının artırılması ve hata oranının azaltılmasıdır. Algoritma işleyiş mekanizması beş temel adımda incelenmektedir. Bu adımlar: başlangıç modeli, hata hesaplanması, ağırlıkların güncellenmesi, yeni modelin eğitilmesi, model birleştirme işlemleridir. Başlangıç modelinde ilk olarak zayıf bir DT kullanılarak eğitim işlemi yapılır. Bu işlemden sonra hata hesabı yapılır. Sonrasında ise ağırlık güncellenmesi işlemine geçilir. Daha fazla hatanın olduğu veri noktalarına daha yüksek ağırlıklar verilir. Sonrasında tekrar birinci adıma dönülerek zayıf model ağırlıklandırılmış versiyonla bir kez daha eğitilir. Yani model optimize edilir, eğitim işlemi arzu edilen kritere ulaşılan kadar devam ettirilerek model birleştirme aşaması tamamlanmış olur.

## 5. SVM

SVM karmaşık veri setlerinin sınıflandırılmasında kullanılan veri noktalarını ayıran sınırın bulunması için kullanılan güçlü bir makine öğrenme algoritmasıdır.<sup>17,18</sup> SVM iki sınıfı en iyi biçimde ayıran hiperdüzlemin bulunması için kullanılır. Bu hiperdüzlem verileri sınıflara ayıracak en geniş marjini bulacak şekilde ayırır. Marjin sınıflar arasındaki farkı belirleyen destek vektörlerinin hiperdüzleme olan mesafeleridir. SVM algoritmasında ilk aşama olarak aşağıda verilen hiperdüzlem tanımlanmıştır.

$$wx+b=0$$

Denklemden verilen  $w$  ağırlıkları  $b$  ise bias olarak tanımlanır.

Sonraki aşamada hiperdüzleme en yakın destek vektörleri ile en yakın veri noktaları arasındaki mesafe maksimize edilir. Marjin  $\frac{2}{\|w\|}$  ile bulunur. SVM

üçüncü aşamada bir optimizasyon problemine dönüşür. Bu optimizasyon problemi aşağıdaki gibi tanımlanır.

$$\text{Min } \frac{1}{2} \|w\|^2$$

$$\text{Subject to } y_i(wx_i + b) \geq 1 \quad \forall i$$

Burada verilen  $y_i$  sınıf etiketleri (1 veya -1) ve ise  $x_i$  öznelikleri temsil eder. SVM algoritmasında doğrusal olmayan veriler için lineer, polinomik, radial basis gibi çekirdekler kullanılarak sınıflandırma performansı artırılır. Nihai modelin oluşmasında rol oynayan destek vektörleri bir başka ifadeyle karar sınırını belirleyen ve marjini oluşturan veri noktaları belirlendiğinde algoritma sonlanmış olur.

Hemşirelerin stres düzeylerinin yukarıda belirtilen model üzerinden makine öğrenimi tabanlı sınıflandırıcıların performansları ölçülmüştür. Sonuçlar Tablo 1’de yer almaktadır.

Tablo 1’de KNN algoritmasının sınıflandırma performansı ortalama 59,56, minimum 42,62 maksimum 80,33, standart sapma 7,68 olarak bulunmuştur. KNN algoritmasının ortalamada düşük ve yüksek standart sapma değerine sahip olması algoritmanın tutarsız sonuçlar verdiğini gösterir. NN algoritmasının sınıflandırma performansı ortalama 76,94, mini-

**TABLO 1:** Sınıflandırıcıların performansları.

Model	Minimum-Maksimum	$\bar{X} \pm SS$
KNN	42,62-80,33	59,56±7,68
NN	68,85-81,97	76,94±3,57
DT	70,49-81,97	79,07±3,03
BT	70,49-81,97	77,6±3,40
SVM	73,77-81,97	80,33±1,97

SS: Standart sapma; KNN: En Yakın Komşu Algoritması; NN: Yapay Sinir Ağları; DT: Karar Ağacı; BT: Güçlendirilmiş Ağaç; SVM: Destek Vektör Makineler.

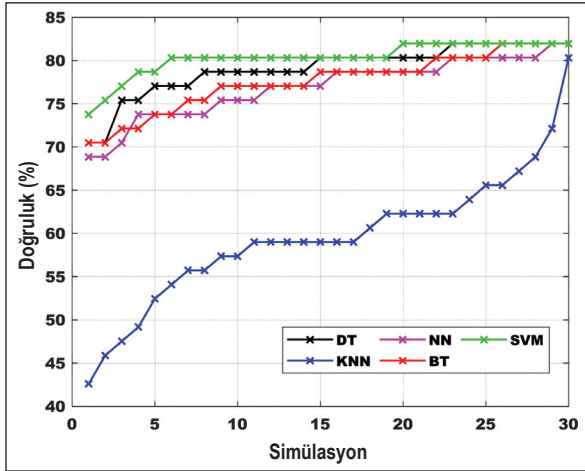
mum 68,85 maksimum 81,97, standart sapma 3,57 olarak bulunmuştur. DT algoritmasının sınıflandırma performansı ortalama 79,07, minimum 70,49 maksimum 81,97, standart sapma 3,03 olarak bulunmuştur. DT algoritması yüksek bir sınıflandırma başarımı göstermiştir. BT algoritmasının sınıflandırma performansı ortalama 77,6, minimum 70,49 maksimum 81,97, standart sapma 3,4 olarak bulunmuştur. Bu algoritma, yüksek doğruluk oranı ve düşük standart sapma değeriyle iyi bir sınıflandırma performansına sahiptir. SVM algoritmasının sınıflandırma performansı ortalama 80,33, minimum 73,77 maksimum 81,97, standart sapma 1,97 olarak bulunmuştur. SVM’nin en yüksek doğruluk yüzdesine sahip olduğu ve en düşük standart sapma değerine sahip olduğu belirlenmiştir.

Tablo 2’de algoritmalar Mann-Whitney U testi kullanılarak istatistiksel olarak da karşılaştırılmıştır. DT-KNN, DT-NN, KNN-NN, KNN-BT, KNN-SVM, NN-SVM ve BT-SVM arasındaki perfor-

**TABLO 2:** Makine öğrenme tekniklerinin karşılaştırmalı istatistiksel sonuçlar.

Metot		z değeri	p değeri	Sig*
DT	KNN	6,3806	0	1
DT	NN	2,6156	0,0089	1
DT	BT	1,8809	0,06	0
DT	SVM	-1,8389	0,0659	0
KNN	NN	-6,2368	0	1
KNN	BT	-6,2802	0	1
KNN	SVM	-6,5469	0	1
NN	BT	-0,644	0,5195	0
NN	SVM	-4,3053	0	1
BT	SVM	-3,5209	0,0004	1

\*Mann-Whitney-U testi; KNN: En Yakın Komşu Algoritması; NN: Yapay Sinir Ağları; DT: Karar Ağacı; BT: Güçlendirilmiş Ağaç; SVM: Destek Vektör Makineler.



ŞEKİL 3: Simülasyon sonuçları.

KNN: En Yakın Komşu Algoritması; NN: Yapay Sinir Ağları; DT: Karar Ağacı; BT: Güçlendirilmiş Ağaç; SVM: Destek Vektör Makineler.

mansların farkı istatistiksel olarak anlamlıdır ( $p < 0,05$ ). Bunun yanında DT-BT, DT-SVM ve NN-BT arasındaki performansların farkı istatistiksel olarak anlamlı değildir ( $p > 0,05$ ). SVM'nin sınıflandırma performansı, KNN, NN ve BT'ye göre anlamlı derecede yüksektir. DT iyi bir sınıflandırma başarımı göstermesine karşılık, DT'nin performansı SVM'ye karşı istatistiksel olarak anlamlı bir fark göstermemektedir. Modellerin simülasyon performansları Şekil 3'te yer almaktadır.

## TARTIŞMA

Çalışmada kullanılan veri seti açık erişimlidir.<sup>25</sup> Çalışmada kullanılan veri seti bir uygulama ile hemşirelerin anket yanıtlarını toplamak için tasarlanmıştır. Deney 358 örnekten oluşmaktadır. Veri seti %70 eğitim %30 eğitim verisi olarak ayrılmıştır. Yaklaşık olarak  $358 \times 0,7 \approx 250$  örnek eğitim için  $358 \times 0,3 \approx 108$  örnek test için kullanılmıştır. Deneyler 30 kere tekrar edilerek istatistiksel olarak adil ve güvenilir bir karşılaştırma yapılması sağlanmıştır.

KNN algoritmasının ortalamada düşük ve yüksek standart sapma değerine sahip olması algoritmanın tutarsız sonuçlar verdiğini gösterir. Her ne kadar KNN basit ve az sayıda parametreye sahip olsa da düşük sınıflandırma performansından dolayı bu algoritmanın bu veri setinde kullanılması mümkün değildir. NN algoritma genel anlamda iyi bir

performansa sahiptir. NN karmaşık ve yoğun örüntülerin olduğu veri setlerinde başarılı sonuçlar üretir. Bu veri setinde iyi bir sınıflandırma performansı göstermiştir. DT algoritması yüksek bir sınıflandırma başarımı göstermiştir. DT algoritmasının standart sapmasının düşük olması ile stabil bir performans gösterdiği, minimum performansının düşük olması ile veri setine bağlı olarak bazen algoritmanın performansında düşüş yaşandığı yorumu yapılabilir. BT algoritması sınıflandırma performansında yüksek doğruluk oranı ve düşük standart sapma değeriyle iyi bir sınıflandırma performansına sahiptir. BT, DT ile benzer performanslara sahiptir. Ancak DT, BT'den daha iyi bir performans sergilemiştir. Bunun nedeninin BT'nin karmaşıklığının verinin karmaşıklığıyla örtüşmemesinden kaynaklandığı yorumu yapılabilir. SVM algoritmasının sınıflandırma performansında en yüksek doğruluk yüzdesine ve en düşük standart sapma değerine sahip olması en güvenilir yöntem olduğunu göstermektedir. Bu nedenle hemşirelerin stres düzeylerinin belirlenmesinde yapay zekâ modellemesinde kullanılması tavsiye edilebilir. Bunun yanında DT, NN ve BT'nin sınıflandırma performansları da tutarlılık ve güvenilirlik açısından avantajlara sahiptir. Ancak KNN en düşük sınıflandırma performansına sahiptir. Bu açıdan böyle bir işlem için kullanılması tavsiye edilemez (Tablo 1).

Çalışmamızda, DT-KNN, DT-NN, KNN-NN, KNN-BT, KNN-SVM, NN-SVM ve BT-SVM arasındaki performansların farkı istatistiksel olarak anlamlıdır ( $p < 0,05$ ). DT-BT, DT-SVM ve NN-BT performansları arasında istatistiksel olarak anlamlı farkı bulunamamıştır ( $p > 0,05$ ). SVM'nin sınıflandırma performansı, KNN, NN ve BT'ye göre anlamlı derecede yüksektir ( $p < 0,05$ ). DT iyi bir sınıflandırma başarımı göstermesine karşılık, DT'nin performansı SVM'ye karşı istatistiksel olarak anlamlı bir fark göstermemektedir (Tablo 2). Bu analizler doğrultusunda SVM'nin en iyi sınıflandırma performansına sahip olduğu yorumu yapılabilir.

Literatürde SVM ile ilgili çalışmalar incelenmiş; makine öğrenmesine dayalı akut stresi nesnel olarak tahmin etmek amacıyla fizyolojik sensör verilerinin kullanıldığı bir çalışmada SVM en iyi yöntem olarak tespit edilmiştir.<sup>26</sup> SVM'nin sınıflandırıcı olarak kullanıldığı bir diğer çalışmada stresi sınıflandırabilen



ve pasif olarak azaltabilen gerçek zamanlı bir sistem geliştirilmiştir.<sup>27</sup> Başka bir çalışmada konuşma kayıtları üzerinden stres düzey tespitinin farklı sınıflandırıcıların karşılaştırılması yapılmış ve SVM'nin en iyi sınıflandırıcı olduğu belirtilmektedir.<sup>28</sup> Makine öğrenme tabanlı yöntemler kullanılarak biyosinyallerden zihinsel stres tespiti yapılan çalışmada SVM en iyi yöntem olarak belirlenmiştir.<sup>29</sup> Çalışma sonuçlarımızın literatürdeki diğer çalışmalarla uyumlu olduğu görülmektedir. Bu çalışmada ve diğer çalışmalarda stres düzeyinin belirlenmesinde en başarılı yöntem olarak SVM öne çıkmaktadır.

## SONUÇ

Bu çalışmada, hemşirelerin stres düzeylerinin belirlenmesinde en iyi sınıflandırma performansına sahip makine öğrenme tekniğinin SVM olduğu sonucuna varılmıştır. SVM ortalama değer açısından en başarılı sınıflandırıcı olmasının yanında en düşük standart sapma değeriyle en güvenilir ve stabil yöntem olarak belirlenmiştir. Bunun yanında SVM'nin istatistiksel açıdan da en değerli sınıflandırıcı olduğu sonucuna varılmıştır. SVM'ye alternatif olarak DT, NN ve BT yöntemleri de iyi performansa sahiptir. Ancak KNN tutarsız ve düşük sınıflandırma performansı sergilediği için hemşirelerin stres düzeylerinin yapay zekâ ile belirlenmesi çalışmalarında kullanılması önerilmemektedir. Bu sonuçlar, hemşirelerin stres düzeylerinin doğru bir şekilde sınıflandırılmasına yardımcı olabilir.

## ÖNERİLER

Hemşirelerin yapay zekâ modelleri ile gerçek stres düzeyleri belirlenerek nedenleri daha kolay araştırılabilir, stres düzeylerini azaltıcı etkenler belirlenebilir ve çalışma performansları artırılabilir. Bu kapsamda günümüz teknolojisini yakalamak ve klinikte/araştırmalarda kullanabilmek için hemşirelerle ilgili ve hemşirelik bakımlarına yönelik yapay zeka ile ilgili daha çok çalışma yapılması önerilmektedir.

### Finansal Kaynak

*Bu çalışma sırasında, yapılan araştırma konusu ile ilgili doğrudan bağlantısı bulunan herhangi bir ilaç firmasından, tıbbi alet, gereç ve malzeme sağlayan ve/veya üreten bir firma veya herhangi bir ticari firmadan, çalışmanın değerlendirme sürecinde, çalışma ile ilgili verilecek kararı olumsuz etkileyebilecek maddi ve/veya manevi herhangi bir destek alınmamıştır.*

### Çıkar Çatışması

*Bu çalışma ile ilgili olarak yazarların ve/veya aile bireylerinin çıkar çatışması potansiyeli olabilecek bilimsel ve tıbbi komite üyeliği veya üyeleri ile ilişkisi, danışmanlık, bilirkişilik, herhangi bir firmada çalışma durumu, hissedarlık ve benzer durumları yoktur.*

### Yazar Katkıları

**Fikir/Kavram:** Aysun Badem, Abdullah Çalışkan; **Tasarım:** Abdullah Çalışkan; **Denetleme/Danışmanlık:** Aysun Badem; **Veri Toplama ve/veya İşleme:** Abdullah Çalışkan; **Analiz ve/veya Yorum:** Aysun Badem, Abdullah Çalışkan; **Kaynak Taraması:** Aysun Badem; **Makalenin Yazımı:** Aysun Badem, Abdullah Çalışkan; **Eleştirel İnceleme:** Aysun Badem, Abdullah Çalışkan.

## KAYNAKLAR

1. Kshetrimayum N, Bennadi D, Siluvai S. Stress among staff nurses: a hospital-based study. *Journal of Nature and Science of Medicine*. 2019;2(2):95-100. [Crossref]
2. Cui S, Jiang Y, Shi Q, Zhang L, Kong D, Qian M, et al. Impact of COVID-19 on anxiety, stress, and coping styles in nurses in emergency departments and fever clinics: a cross-sectional survey. *Risk Manag Healthc Policy*. 2021;14:585-94. [Crossref] [PubMed] [PMC]
3. Şanlıtürk D, Ardiç M. Hemşirelerin algılanan stres düzeyleri ile genel erteleme eğilimleri arasındaki ilişki: kesitsel çalışma [The relationship between perceived stress levels of nurses and their general procrastination: cross-sectional study]. *Türkiye Klinikleri Journal of Nursing Sciences*. 2023;15(1):196-208. [Crossref]
4. Masa'Deh R, Alhalaiqa F, AbuRuz ME, Al-Dweik G, Al-Akash H. Perceived stress in nurses: a comparative study. *Global Journal of Health Science*. 2016;9(6):195. [Crossref]
5. Çolak R, Bülbüloğlu S. Yenidoğan yoğun bakım hemşirelerinin stres düzeyleri ve kaynaklarının incelenmesi [Review of stress levels and sources in newborn intensive care nurses]. *JGON*. 2020;17(4):585-91. [Crossref]
6. Badu E, O'Brien AP, Mitchell R, Rubin M, James C, McNeil K, et al. Workplace stress and resilience in the Australian nursing workforce: a comprehensive integrative review. *Int J Ment Health Nurs*. 2020;29(1):5-34. [Crossref] [PubMed]
7. Clayton M, Marczak M. Palliative care nurses' experiences of stress, anxiety, and burnout: a thematic synthesis. *Palliat Support Care*. 2023;21(3):498-514. [Crossref] [PubMed]
8. Awosika A, Adeniyi MJ. Occupation-related stress and stress-related risk factors among nurses in West Africa. *Middle East Research Journal of Medical Sciences*. 2023;3(1):9-16. [Crossref]
9. Demirci Ş, Çilhoroz Y. Şiddet ve şiddet yönetim. Durmuş A, Amarat M, editörler. *Olağan Dışı Durumlarda Sağlık Yönetimi*. 1. Baskı. İstanbul: Efe Akademi Yayınları; 2023. p.207-46.

10. Shi J, Han X, Liao Y, Zhao H, Fan B, Zhang H, et al. Associations of stressful life events with subthreshold depressive symptoms and major depressive disorder: the moderating role of gender. *J Affect Disord.* 2023;325:588-95. [Crossref] [PubMed]
11. Helpman L. On the stress of being a woman: The synergistic contribution of sex as a biological variable and gender as a psychosocial one to risk of stress-related disorders. *Neurosci Biobehav Rev.* 2023;150:105211. [Crossref] [PubMed]
12. Reyhanoğlu N, Çerçi S, Uyrdağ N, Özaydın Ö. Türkiye'de hemşirelik alanında yapılan lisansüstü tezlerde COVID-19 pandemisinin yansımaları [Reflections of COVID-19 pandemic on postgraduate theses in the field of nursing in Turkey]. *Gevher Nesibe Journal of Medical And Health Sciences.* 2023;8(4):1122-36. [Crossref]
13. Luzipho N, Joubert P, Dhurup M. Job stressors, work tension and job satisfaction of academics at a university in South Africa. *SA Journal of Human Resource Management.* 2023;21. [Crossref]
14. Zaghini F, Biagioli V, Fiorini J, Piredda M, Moons P, Sili A. Work-related stress, job satisfaction, and quality of work life among cardiovascular nurses in Italy: structural equation modeling. *Appl Nurs Res.* 2023;72:151703. [Crossref] [PubMed]
15. Chaabane S, Chaabna K, Bhagat S, Abraham A, Doraiswamy S, Mamtani R, et al. Perceived stress, stressors, and coping strategies among nursing students in the Middle East and North Africa: an overview of systematic reviews. *Syst Rev.* 2021;10(1):136. [Crossref] [PubMed] [PMC]
16. Erkutlu H, Ergün EE, Köseoğlu İ, Vurgun T. Yapay zekâ ve örgütsel davranış [Artificial intelligence and organizational behaviour]. *Nevşehir Hacı Bektaş Veli Üniversitesi SBE Dergisi.* 2023;13(3):1403-17. [Crossref]
17. Soori M, Arezoo B, Dastres R. Artificial intelligence, machine learning and deep learning in advanced robotics, a review. *Cognitive Robotics.* 2023;3:54-70. [Crossref]
18. Rubinger L, Gazendam A, Ekhtiari S, Bhandari M. Machine learning and artificial intelligence in research and healthcare. *Injury.* 2023;54 Suppl 3:S69-S73. [Crossref] [PubMed]
19. Tanyel T. Analysis of Perceived Stress Test using Machine Learning. *arXiv.org.* 2023. [Link]
20. Yaşar H. Yüz görüntülerinden derin öğrenmeye dayalı stres tespiti [Yüksek lisans tezi]. *Bartın: Bartın Üniversitesi;* 2023. [Erişim tarihi: 28 Mayıs 2024]. Erişim linki: [Link]
21. Yüksel H. Yapay zeka algoritmaları kullanılarak öğrencilerin akademik başarısı ile stres ilişkisinin keşifsel bir analizi [An exploratory analysis of the relationship between students' academic success and stress using artificial intelligence algorithms]. *JISMAR.* 2023;5(2):10-20. [Crossref]
22. Vos G, Trinh K, Samyay Z, Rahimi Azghadi M. Generalizable machine learning for stress monitoring from wearable devices: a systematic literature review. *Int J Med Inform.* 2023;173:105026. [Crossref] [PubMed]
23. Naegelin M, Weibel RP, Kerr JI, Schinazi VR, La Marca R, von Wangenheim F, et al. An interpretable machine learning approach to multimodal stress detection in a simulated office environment. *J Biomed Inform.* 2023;139:104299. [Crossref] [PubMed]
24. Özel G, Aba YA. Teknolojinin görünmeyen yüzü: hemşirelik mesleğinde teknostres [The invisible face of technology: technostress in nursing profession]. *Genel Sağlık Bilimleri Dergisi.* 2023;5(2):258-74. [Crossref]
25. Hosseini S, Gottumukkala R, Katragadda S, Bhupatiraju RT, Ashkar Z, Borst CW, et al. A multimodal sensor dataset for continuous stress detection of nurses in a hospital. *Sci Data.* 2022;9(1):255. [Crossref] [PubMed] [PMC]
26. Simons A, Doyle T, Musson D, Reilly J. Impact of physiological sensor variance on machine learning algorithms. *IEEE International Conference on Systems, Man, and Cybernetics (SMC).* 2020:241-7. [Crossref]
27. Cuijpers RH, van Dijk ETK, Longhi S, Marchegiani E, Monterù A. Psychophysiological stress control via heart rate entrainment. *Zooming Innovation in Consumer Technologies Conference (ZINC).* 2019:9-10. [Crossref]
28. Yao X, Xu N, Gao M, Jiang A, Liu X. Comparison analysis of classifiers for speech under stress. *IEEE International Conference on Internet of Things (IThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCoM) and IEEE Smart Data (SmartData).* 2016:429-32. [Crossref] [PMC]
29. Al-Jumaily AA, Matin N, Hoshyar AN. Machine learning based biosignals mental stress detection. In: Mohamed A, Yap BW, Zain JM, Berry MW, eds. *Soft Computing in Data Science.* 1st ed. Singapore: Springer; 2021. p.28-41. [Crossref]