.

“A Machine Learning Model to Detect Falls Mimicking Cardiac Arrest-Related Collapse Based on Wrist Derived Accelerometry: The DETECT-2 Study” Çalışma Değerlendirmesi

Dr. Bilal Canberk İlhan, Dr. Mustafa Gökhan Vural

“A Machine Learning Model to Detect Falls Mimicking Cardiac Arrest-Related Collapse Based on Wrist Derived Accelerometry: The DETECT-2 Study” Çalışma Değerlendirmesi

Hazırlayan: Dr. Bilal Canberk İlhan1, Dr. Mustafa Gökhan Vural2
1Araştırma Görevlisi Doktor, T.C. Sağlık Bakanlığı Ankara Eğitim ve Araştırma Hastanesi Kardiyoloji Kliniği, Ankara, Türkiye
2 Profesör Doktor, T.C. Sağlık Bakanlığı Atatürk Sanatoryum Eğitim ve Araştırma Hastanesi Kardiyoloji Kliniği, Ankara, Türkiye

Çalışmanın adı: A machine learning model to detect falls mimicking cardiac arrest-related collapse based on wrist derived accelerometry: the DETECT-2 study

Çalışmanın amacı ve metodolojisi: Tanıksız hastane dışı kardiyak arrestlerde sağkalım oranları oldukça düşüktür. Kardiyak arresti tespit etme ve sağlık ekiplerine haber verme işlevine sahip giyilebilir cihazların kullanımı erken müdahale ile sağkalımın iyileştirilmesine katkıda bulunabilir. Giyilebilir cihazlarda nabız yokluğunu saptamak için en yaygın kullanılan sensör olan fotopletismografi (FPG) yüksek duyarlılıklı olmakla birlikte, günlük yaşam aktiviteleri sırasındaki artefaktlara bağlı yanlış pozitif uyarılar problem olmaya devam etmektedir. Kardiyak arrest tespit modeline ivmeölçer verilerinin eklenmesi, devam eden hareketin algılanması ile yanlış pozitif uyarıların önlenmesine yardımcı olabilir. DETECT-2 çalışması ise kardiyak arrestin sıklıkla ilk belirtisi olan yere yığılmanın saptanması amacıyla ivmeölçer tabanlı bir makine öğrenmesi modeli geliştirmek üzere yürütülmüştür.
Çalışmada kardiyak arreste bağlı yere yığılma sağlıklı gönüllüler tarafından ani ve yumuşak düşmeler yoluyla taklit edilmiştir. Ani düşmeler kardiyak arrestleri inceleyen önceki çalışmalar temel alınarak ayakta dururken ya da koşarken öne, yana ve geriye doğru düşmeleri içermiştir. Yumuşak düşmeler ise doğrudan yere olmayan, sandalyeden ya da duvara yaslanarak kaymayı içeren düşmeleri kapsamıştır. Her düşme tipi katılımcı başına 5 kez tekrarlanmış ve katılımcılar düşme sonrası 20 saniye boyunca hareketsiz yatmıştır. Ek olarak katılımcılar önceden belirlenmiş bir dizi günlük yaşam aktivitelerini gerçekleştirmiştir. İvmeölçer sinyalleri (3 eksenli [X, Y, Z]; örnekleme frekansı 32 Hz) CardioWatch bilekliği kullanılarak toplanmış, referans olarak video kayıtları alınmıştır. Düşme tespiti için ivmeölçer tabanlı bir gradyan artırma modeli eğitilmiş (%70) ve test edilmiştir (%30). Birincil sonlanım noktası düşmelerin tespit edilmesindeki duyarlılık, ikincil sonlanım noktaları ise yanlış pozitif düşme uyarılarıdır.

Çalışmanın sonuçları ve tartışma: Eğitim setinde 13 katılımcı tarafından 260 ani düşme, 128 yumuşak düşme gerçekleştirilmiş ve 23,5 saatlik ivmeölçer verisi elde edilmiştir. Sonrasında hareketsizlik izlenen düşmenin tespit edilmesindeki duyarlılıklar ani düşme için %100 (%95 GA %98-100), yumuşak düşme için %97,7 (%95 GA %93-99) olarak saptanmıştır. Hareketsizlik dikkate alındığında düşmenin tespitinde modelin duyarlılığı 4 yanlış pozitif ile %99,2 (%95 GA %98-100) olarak hesaplanmıştır. Hareketsizlik dikkate alınmaksızın tek başına düşmenin tespit edilmesindeki duyarlılık ise 18 yanlış pozitif ile %96,7 (%95 GA %94-98) olmuştur. Test seti 120 ani düşme, 59 yumuşak düşme gerçekleştiren 6 katılımcıdan elde edilen 9,5 saatlik ivmeölçer verisinden oluşmuştur. Hareketsizliğin takip ettiği ani ve yumuşak düşmelerin tespit edilmesindeki duyarlılıklar sırasıyla %100 (%95 GA %96-100) ve %88,1 (%95 GA %76-95) olarak belirlenmiştir ($p<0,001$). Yanlış pozitif sayısı 2 olup düşmenin tespit edilmesindeki duyarlılık %96,1 (%95 GA %92-98) olarak bulunmuştur. Hareketsizliğe bakılmaksızın tek başına düşme tespitindeki duyarlılık %94,4 (%95 GA %90-97) olmuş ve 10 yanlış pozitif uyarı izlenmiştir.

Kardiyak arreste bağlı yere yığılmayı taklit eden ani ve yumuşak düşmeler el bileğine bağlı ivmeölçer verileri kullanılarak yüksek duyarlılıkla tespit edilebilmiştir. Modelin ani düşmeleri saptamada daha iyi performans gösterdiği görülmüş ve bu durum yere doğrudan çarpmanın daha güçlü bir ivmeölçer sinyali üretmesine bağlı olarak değerlendirilmiştir. Günlük yaşam aktiviteleri sırasında sık el kullanımı düşmenin diğer hareketlerden ayırt edilmesini zorlaştırmakta olup test setindeki yanlış pozitif uyarıların tümü el çırpma sırasında meydana gelmiştir. Kardiyak arrest için tipik olan düşme sonrası hareketsizlik durumu modele dahil edildiğinde yanlış pozitiflerin sayısı azalmıştır. Giyilebilir cihaz tabanlı otomatik kardiyak arrest tespitine yönelik bir sonraki adım ivmeölçer sinyallerinin mevcut FPG tabanlı modele entegre edilmesidir. Böylece kullanıcının devam eden hareketleri FPG analizine dayalı olası bir kardiyak arrest ile uyumlu olmadığında hatalı uyarıların önüne geçilebilir. Bu yaklaşım günlük yaşamdaki kullanımda yanlış pozitiflikleri azaltma ve duyarlılığı artırma potansiyeline sahiptir.

Erişim Linki: https://esc365.escardio.org/presentation/330394

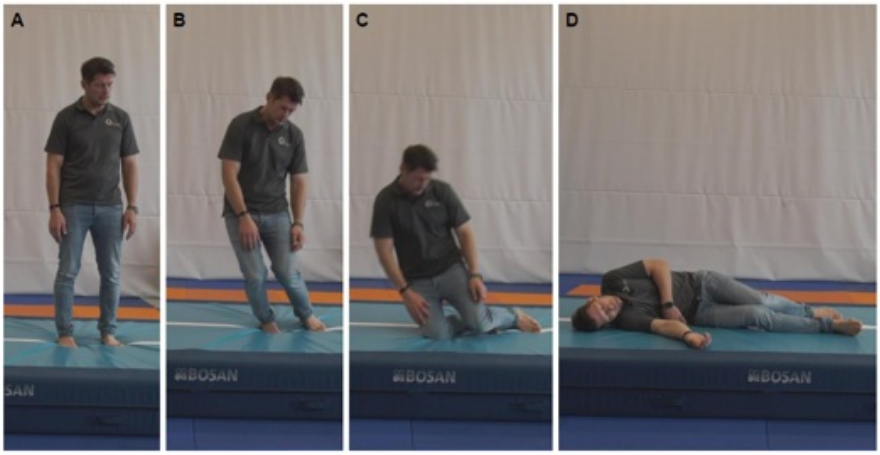


Figure 1 Video screenshots of the instructor demonstrating the fall sideways, which is one of the sudden falls. The CardioWatch was worn on the right wrist. *A*) starting position, *B*) initiation of the fall to the right, *C*) fall to the right, and *D*) after the fall, the subject lay still for 20 s.

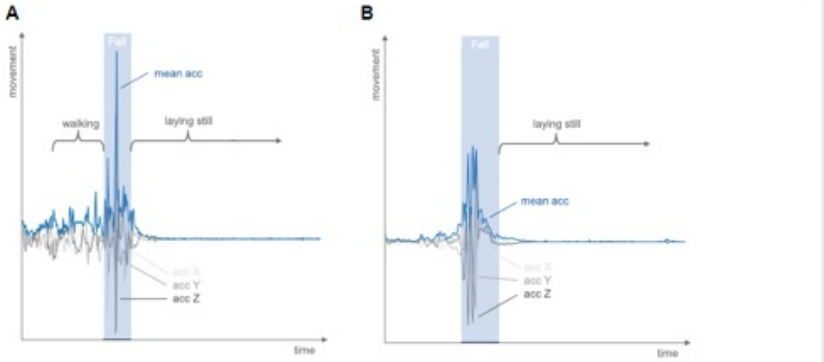


Figure 2 Accelerometer signals of two types of falls. The grey signals are the X, Y, and Z of the accelerometer sensor. The blue signal (mean acc) is the square root of the sum of the squared three signals. *A*) Accelerometry data from a sudden fall forward preceded by walking. On the left, the subject is walking. In the blue frame, the subject falls forward and then lies still. *B*) Accelerometry data from a soft fall. In the blue frame, the subject slides off a chair and then lies still. The sudden fall creates a stronger accelerometer signal than the soft fall.