

Vasküler Vertigo Yapay Zekâ Yöntemleriyle Tanınabilir mi? Can Vascular Vertigo Be Recognized by Artificial Intelligence Methods?

Aslihan TASKIRAN-SAG¹, Hilal ARSLAN², Hare YAZGI³, Erdal EROGLU¹, Kadriye Serife UGUR⁴

¹Department of Neurology, Faculty of Medicine, TOBB University of Economics and Technology, Ankara, Türkiye

²Department of Software Engineering, Faculty of Engineering and Natural Sciences, Ankara Yıldırım Beyazıt University, Ankara, Türkiye

³Faculty of Medicine, TOBB University of Economics and Technology, Ankara, Türkiye

⁴Department of Otorhinolaryngology, Faculty of Medicine, TOBB University of Economics and Technology, Ankara, Türkiye

ÖZ

Giriş ve Amaç: Altta yatan nedenlerin çeşitliliği, baş dönmesinin ayırıcı tanısında tıbbi bir zorluk oluşturmaktadır. Birçok hasta için tanıya ulaşma süresi oldukça uzundur ve birkaç test içerir. Bu, bazı nörolojik acil durumların tanınmasını ve tedavisini geciktirirken sağlık sistemine önemli bir mali yük getirir. Bu makalede, zamanında yönetim gerektiren baş dönmesinin vasküler nedenlerinin erken tanınmasına yardımcı olmak için makine öğrenimi tabanlı bir yöntem sunuyoruz.

Yöntem: Yaş, cinsiyet, eşlik eden semptomlar, komorbiditeler ve yaygın olarak bilinen kan parametreleri gibi veriler kullanılarak, hasta için en uygun grubu tahmin etmek üzere makine öğrenimi tabanlı bir ön değerlendirme yöntemi tasarlandı. İstatistiksel yöntemler kullanılarak etkili özellikler belirlendikten sonra, baş dönmesi gruplarını belirlemek için çeşitli makine öğrenimi yöntemleri (karar ağacı, lojistik regresyon, destek vektör makineleri, k-en yakın komşu, çok katmanlı algılayıcı ve topluluk öğrenme yöntemleri) kullanıldı.

Bulgular: Deneysel sonuçlar, yaş, serum albümini, baş ağrısı, hipertansiyon ve diyabetin varlığının vasküler vertigo hastalarını sınıflandırmak için önemli özellikler olduğunu göstermektedir. Doğruluklar %81,7 ile %86 arasında değişmektedir ve en iyi sonuç lojistik regresyon yöntemi ile elde edilmektedir. Karar ağacı, destek vektör makineleri, k-en yakın komşu, çok katmanlı algılayıcı ve topluluk yöntemleri sırasıyla %83, %85,5, %84, %81,7 ve %82,8 doğruluklara ulaşmıştır.

Sonuç: Çalışmamız, makine öğrenimi modellerinin hastaneye başvurudan önce vasküler vertigo vakalarını tahmin etmede yararlı olabileceğini öne süren makul kanıtlar sunmaktadır. Modelin doğruluğunu arttıracak daha kapsamlı benzer çalışmalara ihtiyaç vardır. Modelimiz, ambulans personeli, pratisyen hekimler ve atipik ve zor baş dönmesi vakalarıyla karşılaşan uzmanlar için faydalı olabilir.

Anahtar Sözcükler: Baş dönmesi, inme, makine öğrenimi, vertigo, yapay zeka

ABSTRACT

Introduction: The diversity of underlying causes poses a medical challenge in the differential diagnosis of dizziness. For many patients, the time to reach a diagnosis is quite long and includes several tests. This imposes a significant financial burden on the healthcare system while delaying the recognition and treatment of some neurological emergencies. In this paper, we present a machine learning-based method to aid in the early recognition of vascular causes of vertigo, which require timely management.

Methods: Using data such as age, gender, accompanying symptoms, comorbidities, and commonly known blood parameters, a machine learning-based preliminary evaluation method was designed to predict the most appropriate group for the patient. After identifying the effective features using statistical methods, various machine learning methods (decision tree, logistic regression, support vector machines, k-nearest neighbor, multilayer perceptron, and ensemble learning methods) were employed to determine dizziness groups.

Results: Experimental results present that age, serum albumin, presence of headache, hypertension and diabetes are crucial features to classify vascular vertigo patients. Accuracies range from 81.7% to 86% and the best result is achieved with the logistic regression method. The decision tree, support vector machines, k-nearest neighbor, multilayer perceptron, and ensemble methods reached accuracies of 83%, 85.5%, 84%, 81.7%, and 82.8%, respectively.

Conclusion: Our study provides reasonable evidence suggesting that machine learning models may be useful in predicting vascular vertigo cases before hospital admission. Further studies are needed to confirm these findings and improve accuracy. Our model may be beneficial for ambulance personnel, practitioners and for the specialists facing atypical and difficult cases of dizziness.

Keywords: Artificial intelligence, dizziness, machine learning, stroke, vertigo

Cite this article as: Taskiran-Sag A, Arslan H, Yazgi H, Eroglu E, Ugur KS. Vasküler Vertigo Yapay Zekâ Yöntemleriyle Tanınabilir mi?. Arch Neuropsychiatry 2026;63:246-252. doi: 10.29399/npa.29122

Öne Çıkan Noktalar

- Makine öğrenmesi, hastaneye başvurudan önce vasküler vertigo tanısını öngörebilir.
- En yüksek doğruluğa %86 oranıyla lojistik regresyon modeli ulaşmaktadır.
- Başlıca ayırt edici özellikler albümin, yaş, baş ağrısı, hipertansiyon ve diyabetir.
- Makine öğrenimi baş dönmesinde maliyetleri azaltabilir, hızlı müdahale sağlayabilir.

GİRİŞ

Baş dönmesi, bir yılda genel popülasyonun yaklaşık %15-30'unu etkileyen yaygın bir semptomdur (1). Aile hekimleri, acil doktorları, nörologlar ve kulak-burun-boğaz uzmanlarının en sık karşılaştığı şikayetlerden biridir. Birinci basamak ve acil servis başvurularının ~%4'ünü oluştururken, genel nöroloji kliniklerinde bu oran %30'a kadar çıkabilmektedir (1, 2). Erişkinlerin yaklaşık %30-40'ı hayatları boyunca klinik olarak anlamlı baş dönmesi yaşamaktadır (3). Baş dönmesi, uzaysal oryantasyon hissinde bozukluk olarak tanımlanır (4). Hastalar bu terimi; sersemlik, dengersizlik, bayılacakmış gibi hissetme gibi durumlar için de kullanabilir (5). **Vertigo** ise baş dönmesinin bir alt tipi olup *yanlış hareket algısı* şeklinde tanımlanır. Genellikle çevrenin dönmesi veya kişinin kendi etrafında dönüyormuş gibi hissetmesi olarak tarif edilir (6). Baş dönmesinin vestibüler bozukluklar, ortostatik hipotansiyon, dehidratasyon, ilaç yan etkileri, anksiyete, vitamin eksiklikleri veya nörolojik hastalıklar gibi çeşitli nedenleri olabilir. Bu durumların çoğu iyi gidişlidir. Vertigo, periferik veya santral vestibüler disfonksiyonun bir işaretidir. Etiyolojide benign paroksizmal pozisyonel vertigo (BPPV), vestibüler nörit, Meniere hastalığı, labirentit gibi iç kulak patolojileri veya vertebroziler yetmezlik, inme, demiyelinizan hastalıklar gibi nörolojik durumlar yer alır.

Klinik pratikte bu semptomların ayırıcı tanısı tıbbi bir zorluk teşkil eder (7). Kesin tanı için kapsamlı bir öykü ve fizik muayene gereklidir. İtme testleri, videonistagmografi (VNG), manyetik rezonans görüntüleme (MRG), boyun damarlarının Doppler ultrasonu gibi ek tetkikler sıklıkla başvurulan yöntemlerdir. Ancak, baş dönmesi olan hastaların büyük çoğunluğunda altta yatan neden benign olup, ilgili uzmana ulaşıldığında tanı kolayca konulabilir. Önceki çalışmalar, baş dönmesi şikayeti olan hastaların %50'sinde tanı sürecinin 5 ay veya daha uzun sürdüğünü ve %75'inin yüksek maliyetli bir tetkik olan MRG yaptırdığını göstermiştir (8). Bu şikayetlerin yüksek prevalansı düşünüldüğünde, sağlık sistemleri ve iş gücü kaybı üzerinde ciddi bir ekonomik yük oluştuğu açıktır (9, 10).

Öte yandan, özellikle inme, vertebroziler geçici iskemik atak, intrakraniyal kanama gibi *nörolojik aciller* için bazı hastalarda zaman kaybetmeden görüntüleme yapılması gerekir. Vasküler nörolojik patolojilerin akut tedavisi için 4,5 saatlik bir zaman penceresi bulunmaktadır (11). Bu grupta erken tanı hayati önem taşır. Ancak klinik pratikte, posterior sirkülasyon inme hastalarının nörolojiye başvurmadan önce KBB uzmanına gitmesi veya tanıya götürmeyen bir takım tetkikler yaptırması nadir bir durum değildir.

Yapay zeka, sağlık alanında birçok problemin çözümünde giderek daha fazla kullanılmaktadır. Kanseri, inme, nörofibromatozis gibi nadir nörojenetik sendromlarda bile makine öğrenmesi yöntemleriyle çeşitli çalışmalar yapılmıştır (12-16). Son dönemde baş dönmesi alanında da yapay zeka uygulamalarına dair çalışmalar yayınlanmıştır. Kabade ve ark., hasta öyküsü ve test sonuçlarını işleyerek vertigo etiyojisini tahmin eden modeller geliştirmiştir (17). Anh ve ark., denge fonksiyon testi verileriyle

periferik vestibüler (PV) ve PV dışı hastalıkların sınıflandırılmasında makine öğrenmesi kullanmıştır (18). Tang ve ark., BPPV ile non-BPPV'yi ayırt etmek için klinik ve laboratuvar verilerini kullanan bir model önermiştir. Model, %100 duyarlılık ve 0,93'ün üzerinde AUC değerleriyle yüksek tanılabilir performans göstermiştir (19).

Bu projenin temel amaçları: 1. Makine öğrenmesi algoritmalarıyla nörolog/ acil hekimi tarafından hızla değerlendirilmesi gereken baş dönmesi hastalarını seçmek. 2. Vasküler vertigolu hastaların makine öğrenmesiyle ayırt edilmesini kolaylaştıran klinik ve biyokimyasal özelliklerini belirlemektir. Yapay zeka tabanlı bir triyaj aracı, gereksiz tetkik ve başvuruların önüne geçebilir.

YÖNTEM

Veri Toplama

Bu çalışmaya, Mayıs 2023 ile Mayıs 2024 tarihleri arasında TOBB ETÜ Hastanesi'ne başvuran toplam 470 baş dönmesi hastası dahil edilmiştir. Hastaların kayıtları, Nöroloji Bölümü veritabanından retrospektif olarak elde edilmiştir. Hastalara ait şu bilgileri içeren bir veri kümesi oluşturulmuştur: Yaş, cinsiyet, eşlik eden semptomlar (denge bozukluğu, baş ağrısı, çift görme, tinnitus, parestezi), klinik özellikler (baş dönmesi şikayetinde dalgalanmalar veya ataklarla seyrediyor olması), komorbiditeler (hipertansiyon ve diyabet), kesin tanı, biyokimyasal veriler (serum albumin, ferritin, transferrin, ürik asit, trigliserit, düşük yoğunluklu lipoprotein (LDL), yüksek yoğunluklu lipoprotein (HDL), total kolesterol, vitamin B12, vitamin D, kan üre nitrojeni (BUN) ve kreatinin). Tüm tanılabilir incelemeleri gözden geçiren uzmanlar (ATS, SU, EE), her hasta için kesin tanıyı belirlemiştir. Hastalar altı farklı kategoriye ayrılmıştır: periferik, vasküler, migren, diğer santral vertigo, psikojenik, nutrisyonel. Böylece, 470 katılımcıya ait yukarıda belirtilen 21 öznel ve sınıf etiketlerini içeren anonimize edilmiş bir veri kümesi oluşturulmuştur. Veri kümesinin özellikleri Tablo 1'de özetlenmiştir. Bu çalışmadaki temel hedefimiz, acil müdahale gerektirdiği için vasküler kökenli vakaları diğerlerinden ayırt etmektir. Bu nedenle, vasküler tanı alan hastalara sınıf etiketi "1", diğerlerine ise "0" atanmıştır. Oluşturulan veri kümesi üzerinde, vasküler baş dönmesi nedenlerini tahmin etmek için son teknoloji makine öğrenimi yöntemleri kullanılmıştır. Bu çalışma, TOBB ETÜ Bilimsel Araştırmalar Etik Kurulu tarafından onaylanmıştır (21.02.2024/BAEK02).

Makine Öğrenmesi Yöntemleri

Bu çalışmada toplam altı farklı makine öğrenmesi tekniği kullanılmıştır: karar ağacı, lojistik regresyon, destek vektör makineleri, k-en yakın komşu, çok katmanlı algılayıcı ve ensemble öğrenme yöntemleri.

Karar ağaçları (DT), veri kümelerindeki örüntüleri ortaya çıkarmak için kullanılan bir veri analizi tekniğidir (20). Bir karar ağacının yapısı düğümler ve dallardan oluşur; her düğüm bir özelliği, her dal ise o özelliğin bir değerini temsil eder. Veriler daha küçük gruplara ayrılır ve her alt grup için tahminler yapılır. Öğrenme süreci, örneklerin özellik değerlerine göre ağaç dalları boyunca yönlendirilmesini ve her düğümde karar verilmesini içerir. Karar ağaçları hem sınıflandırma hem de regresyon görevlerinde yaygın olarak kullanılır ve model parametreleri performansı önemli ölçüde etkiler.

Lojistik regresyon (LR), bir sonucun, olayın veya gözlemin gerçekleşme olasılığını tahmin eden, denetimli bir makine öğrenmesi algoritmasıdır (21). 0 ile 1 arasında bir olasılık elde etmek için sigmoid fonksiyonunu kullanır. Örnekleri iki sınıfa ayırmak için sigmoid fonksiyonu tarafından üretilen olasılık değeri kullanılır.

Destek vektör makineleri (SVM), genellikle sınıflandırma ve regresyon görevleri için kullanılan güçlü bir makine öğrenmesi algoritmasıdır (22).

Temel amacı, iki sınıfı ayıran optimal hiperdüzlemi bularak veri noktalarını sınıflandırmaktır. Destek vektörleri, sınıflar arasındaki sınırı maksimize eden kritik noktalarıdır. SVM'ler, çekirdek fonksiyonlarından yararlanarak yüksek boyutlu uzaylarda bile oldukça etkilidir ve sınıflandırma ile regresyon problemlerinde iyi performans gösterir. Bu çalışmada doğrusal çekirdek kullanılmıştır.

K-en yakın komşu (KNN), parametrik olmayan, tembel öğrenme temelli bir sınıflandırma tekniğidir (23). Özel bir eğitim aşaması gerektirmez, bunun yerine tüm eğitim veri kümesini saklar ve sınıflandırma sırasında kullanır. Yeni bir veri noktasını sınıflandırırken, KNN algoritması eğitim kümesindeki k en yakın örneği belirler ve çoğunluk oylamasına göre yeni veri noktasını bir sınıfa atar. Bu çalışmada k değeri 1 olarak ayarlanmış ve Öklid mesafesi kullanılmıştır.

Çok katmanlı algılayıcı (MLP), ileri beslemeli bir yapay sinir ağı türüdür ve bir giriş katmanı, bir veya daha fazla gizli katman ile bir çıkış katmanından oluşur (24). Giriş katmanı, veri kümesindeki özellik sayısı kadar nöron içerirken, çıkış katmanı MLP'nin çıktısını sağlayan tek bir nörondan oluşur (25). MLP, veriyi aktivasyon fonksiyonları kullanarak modeller; yaygın olarak lojistik sigmoid, düzeltilmiş doğrusal birim (ReLU) ve hiperbolik tanjant (tanh) fonksiyonları kullanılır. Bu çalışmada, üç gizli katmana sahip temel bir MLP modeli kullanılmış ve ReLU aktivasyon fonksiyonundan yararlanılmıştır.

Ensemble teknikleri, genel doğruluğu artırmak için makine öğrenmesi yöntemlerinden gelen tahminleri birleştirir (26). Yaygın olarak kullanılan ensemble teknikleri arasında bagging, boosting ve stacking bulunur. Bu çalışmada bagging ve boosting yöntemleri uygulanmıştır.

Deneysel Kurulum

Deneyler, 2.6 GHz Intel Core i7 işlemci ve 16 GB RAM ile donatılmış, Ubuntu 18.04.03 LTS işletim sistemi kullanan bir bilgisayarda gerçekleştirilmiştir. Sınıflandırıcıların uygulanmasında, Python dilinde makine öğrenimi için tasarlanmış açık kaynaklı bir araç seti olan Scikit-learn kütüphanesi kullanılmıştır.

Makine öğrenmesi modellerinin performansı; kesinlik (precision), duyarlılık (recall), F1-skoru ve doğruluk (accuracy) metriklerine göre değerlendirilmiştir.

Kesinlik (Precision): Vasküler pozitif olarak doğru tahmin edilen vakaların, vasküler pozitif olarak tahmin edilen toplam vaka sayısına oranıdır.

Duyarlılık (Recall): Makine öğrenmesi modeli tarafından doğru şekilde tanımlanan gerçek vasküler pozitif vakaların oranıdır.

F1-skoru: Kesinlik ve duyarlılığın harmonik ortalamasıdır.

Doğruluk (Accuracy): Hem doğru tahmin edilen vasküler pozitif vakaları hem de doğru tanımlanan negatif vakaları dikkate alarak hesaplanan genel doğru tahmin yüzdesidir. Modelin vasküler pozitif ve negatif vakaları ayırt etmedeki genel etkinliğini gösterir.

Ayrıca, makine öğrenmesi yöntemlerinin kapsamlı değerlendirilmesi için karışıklık matrisleri (confusion matrices) sunulmuştur. Karışıklık matrisleri şunları göstermektedir:

Gerçek pozitifler (TP): Doğru şekilde tanımlanan vasküler pozitif vaka sayısı

Gerçek negatifler (TN): Doğru şekilde tahmin edilen vasküler negatif vaka sayısı

Yanlış pozitifler (FP): Yanlışlıkla vasküler pozitif olarak tahmin edilen negatif vaka sayısı

Yanlış negatifler (FN): Vasküler pozitif sınıfında yanlış tahmin edilen vaka sayısı

BULGULAR

Hastaların ortalama yaşı 52.4 ± 17.8 (ortalama \pm standart sapma) idi. Kadın/erkek oranı 269/201 olarak kaydedildi. Her sınıftaki hasta sayıları Tablo 1'de görülebilir ve hastaların klinik özellikleri ile laboratuvar değerlerinin detaylı analizi Tablo 2'de sunulmuştur.

Tablo 3, ANOVA ile hesaplanan önem skorlarını göstermektedir. ANOVA analizi, farklı grupların nitelik değerlerinin ortalamaları arasındaki varyansın, F1-skoruyla göre toplam varyansa kıyasla istatistiksel olarak anlamlı olup olmadığını değerlendirir. Daha yüksek F1-skoru, grup ortalamaları arasında anlamlı bir fark olduğunu gösterir.

Şekil 1, DT, LR, SVM, KNN, MLP ve ensemble yöntemlerinin karışıklık matrislerini sunmaktadır. 'Vasküler-' kategorisi periferik, migren, santral vertigo, psikojenik ve beslenmeye bağlı vakaları içermektedir. DT yönteminin sonuçlarına göre, 44 vasküler örnek (%50) doğru sınıflandırılırken, kalan 44 vasküler örnek yanlış sınıflandırılmıştır. 'Vasküler-' grubunda ise 346 örnek (%91) doğru sınıflandırılırken, 36 vaka yanlış sınıflandırılmıştır. DT'nin kesinlik (precision), duyarlılık (recall) ve F1-skorları sırasıyla 0,5, 0,55 ve 0,52'dir. LR yönteminin sonuçları, vasküler vakalarda DT ile aynı olmakla birlikte, "vasküler-" grubunda daha doğru sonuçlar vermiştir. LR'nin kesinlik (precision), duyarlılık (recall) ve F1-skorları sırasıyla 0,5, 0,66 ve 0,57'dir.

Tablo 1. Baş dönmesi grupları ve özellikleri

Baş dönmesi grubu adı	Grup açıklaması	Hasta sayısı	Sınıf etiketi
Periferik	Benign paroksizmal pozisyonel vertigo, endolenfatik hidrops, Meniere hastalığı, vestibüler nörit	176	0
Vasküler	İnme, geçici iskemik atak, hipertansif kriz, vertebrobaziler yetmezlik, ortostatik hipotansiyon	88	1
Migren	Vestibüler migren	36	0
Diğer santral vertigo	Nörodegeneratif ve demiyelinizan hastalıklar	48	0
Psikojenik	Anksiyete bozuklukları, depresyon ve somatoform bozukluklar	71	0
Nutrisyonel	Demir eksikliği anemisi, B12 vitamini ve D vitamini eksiklikleri	51	0

Tablo 2. Hastaların tanımlayıcı analizi

Baş dönmesi nedenlerine göre hasta grupları							
	Periferik	Vasküler	Psikojenik	Vitamin Eksikliği	Santral	Migren	
Cinsiyet	Kadın 90(%19,1) Erkek 86 (%18,3)	Kadın 43 (%9,1) Erkek 45 (%9,6)	Kadın 47 (%10) Erkek 24 (%5,1)	Kadın 29 (%6,2) Erkek 22 (%4,7)	Kadın 30 (%6,4) Erkek 18 (%3,8)	Kadın 29 (%6,2) Erkek 7 (%1,5)	
Yaş (Ort.):	50,59	71,93	44,26	40,41	58,25	39,28	
Laboratuvar Değerleri							
Serum Albumin (Ort.):	4,521	4,265	4,45	4,983	4,258	4,483	
Ferritin (Ort.):	116,52	117,65	76,9	91,407	99,877	56,034	
Transferrin (Ort.):	29,433	26	28,33	20,75	21,143	36,2	
Ürik asit (Ort.):	5,314	5,625	5,392	4,657	5,525	4,773	
Trigliserit (Ort.):	162,808	165,35	136,536	113,25	157,556	98,261	
Düşük Yoğunluklu Lipoprotein (Ort.):	129,085	122,732	123,616	121	127,867	117,7	
Yüksek Yoğunluklu Lipoprotein (Ort.):	51,37	52,125	52,212	52,333	53,852	55,705	
Total Kolesterol (Ort.):	197,799	206,326	189,322	184,539	207,938	193,821	
Kan Üre Nitrojeni (Ort.):	14,144	17,419	12,537	12,783	19,021	11,781	
Vitamin B12 (Ort.):	446,783	458,399	595,675	356,074	482,069	464,715	
Vitamin D (Ort.):	25,528	25,893	30,724	17,533	39,004	31,602	
Klinik Özellikler							
Yakınmalar:	Baş Ağrısı	Evet 55 (%31,25) Hayır 121 (%68,75)	Evet 20 (%22,73) Hayır 68 (%77,27)	Evet 30 (%42,25) Hayır 41 (%57,75)	Evet 22 (%43,14) Hayır 29 (%56,86)	Evet 13 (%27,08) Hayır 35 (%72,92)	Evet 33 (%91,67) Hayır 3 (%8,33)
	Çınlama	Evet 57 (%32,39) Hayır 119 (%67,61)	Evet 14 (%15,91) Hayır 74 (%84,09)	Evet 15 (%21,13) Hayır 56 (%78,87)	Evet 15 (%29,41) Hayır 36 (%70,59)	Evet 10 (%20,83) Hayır 38 (%79,17)	Evet 11 (%30,56) Hayır 25 (%69,44)
Paresteziler		Evet 38 (%21,59) Hayır 138 (%78,41)	Evet 8 (%9,09) Hayır 80 (%90,91)	Evet 20 (%28,17) Hayır 51 (%71,83)	Evet 11 (%21,57) Hayır 40 (%78,43)	Evet 9 (%18,75) Hayır 39 (%81,25)	Evet 7 (%19,44) Hayır 29 (%80,56)
	Dengesizlik / Yürüme Bozukluğu	Evet 89 (%50,56) Hayır 87 (%49,44)	Evet 56 (%63,64) Hayır 32 (%36,36)	Evet 26 (%36,62) Hayır 45 (%63,38)	Evet 24 (%47,06) Hayır 27 (%52,94)	Evet 30 (%62,5) Hayır 18 (%37,5)	Evet 15 (%41,67) Hayır 21 (%58,33)
Diplopi		Evet 6 (%3,4) Hayır 170(%96,6)	Evet 3 (%3,41) Hayır 85 (%96,59)	Evet 1 (%1,41) Hayır 70 (%98,59)	Evet 1 (%1,96) Hayır 50 (%98,04)	Evet 3 (%6,25) Hayır 45 (%93,75)	Evet 1 (%2,78) Hayır 35 (%97,22)
	Komorbiditiler: Hipertansiyon	Evet 50 (%28,4) Hayır 126 (%71,6)	Evet 47 (%53,41) Hayır 41 (%46,59)	Evet 14 (%19,72) Hayır 57 (%80,28)	Evet 6 (%11,76) Hayır 45 (%88,24)	Evet 27 (%56,25) Hayır 21 (%43,75)	Evet 5 (%13,89) Hayır 31 (%86,11)
Diabetes Mellitus		Evet 24 (%13,64) Hayır 139 (%78,97) İnsulin Direnci 13 (%7,39)	Evet 21 (%23,86) Hayır 58 (%65,91) İnsulin Direnci 9 (%10,23)	Evet 5 (%7,04) Hayır 61 (%85,92) İnsulin Direnci 5 (%7,04)	Evet 3 (%5,88) Hayır 45 (%88,24) İnsulin Direnci 3 (%5,88)	Evet 13 (%27,08) Hayır 31 (%64,58) İnsulin Direnci 4 (%8,34)	Evet 2 (%5,56) Hayır 34 (%94,44) İnsulin Direnci 0 (% 0)
	Vertigonun özellikleri: Tekrarlayıcı	167 (%94,89)	86 (%97,73)	65 (%91,55)	49 (%96,08)	46(%95,83)	34 (%94,44)
	İlk kez	9 (%5,11)	2 (%2,27)	6 (%8,45)	2 (%3,92)	2 (% 4,17)	2 (%5,56)

Ort.: Ortalama

SVM yönteminin sonuçları değerlendirildiğinde, 40 vasküler vaka (%45) doğru tanımlanırken, 48 pozitif vaka yanlışlıkla vasküler negatif olarak etiketlenmiştir. Öte yandan, 362 negatif vaka (%95) doğru sınıflandırılmış, ancak 20 gerçek vasküler negatif vaka atlanmıştır. SVM'in kesinlik (precision), duyarlılık (recall) ve F1-skorları sırasıyla 0,45, 0,66 ve 0,54'tür.

KNN yönteminde, 28 vasküler örnek (%32) doğru sınıflandırılırken, kalan 60 örnek yanlış sınıflandırılmıştır. 'Vasküler-' grubunda ise 367 örnek (%96) doğru sınıflandırılmış ve yalnızca 15 gerçek vasküler negatif örnek atlanmıştır. KNN'nin kesinlik (precision), duyarlılık (recall) ve F1-skorları sırasıyla 0,31, 0,65 ve 0,42'dir.

MLP yönteminde, 46 vasküler örnek (%52) doğru sınıflandırılırken, 42 örnek yanlış sınıflandırılmıştır. 'Vasküler-' grubunda ise 338 örnek (%88)

doğru sınıflandırılırken, 44 örnek yanlış sınıflandırılmıştır. MLP'nin kesinlik (precision), duyarlılık (recall) ve F1-skorları sırasıyla 0,52, 0,51 ve 0,52'dir. Ensemble öğrenme tekniğinde en iyi sonuçlar Bagging yöntemi ile elde edilmiştir. Ensemble yöntemi ile 34 vasküler örnek (%39) doğru sınıflandırılırken, 54 örnek yanlış sınıflandırılmıştır. 'Vasküler-' grubunda ise 355 örnek (%93) doğru sınıflandırılmış ve 27 örnek yanlış sınıflandırılmıştır.

Şekil 2, makine öğrenmesi yöntemlerinin doğruluk (accuracy) sonuçlarını göstermektedir. Doğruluk sonuçları %81,7 ile %86 arasında değişmekte olup, en iyi sonuç LR yöntemi ile elde edilmiştir. DT, SVM, KNN, MLP ve Ensemble yöntemleri sırasıyla %83, %85,5, %84, %81,7 ve %82,8 doğruluk oranlarına ulaşmıştır.

Tablo 3. ANOVA Algoritmasına Göre Özellik Önem Skorları

Özellik Adı	F1-Skor
Serum albümini	98,48
Yaş	98,48
Baş ağrısı	26,92
Hipertansiyon	22,95
Diyabet	8,71
Cinsiyet	5,09
Denge bozukluğu	4,87
Düşük yoğunluklu lipoprotein	3,89
Tinnitus	2,84
Parestezi	2,59
Transferrin	1,99
Kan üre nitrojeni	1,89
Trigliserit	1,56
D vitamini	1,47
Ürik asit	1,09
Yüksek yoğunluklu lipoprotein	0,58
Ferritin	0,49
Tekrarlayan tip	0,45
Toplam kolesterol	0,42
B12 vitamini	0,29
Diplopi	0,25


TARTIŞMA

Baş dönmesinin potansiyel olarak ciddi nedenlerini benign etiyolojilerden ayırt etmek uzun süredir devam eden tıbbi bir zorluktur. Bu makale, vasküler baş dönmesi nedenlerinin erken tanısına yardımcı olacak bir makine öğrenmesi yöntemi sunmaktadır. "Vasküler vertigo"nun bu şekilde bilgisayar destekli, hızlı ve doğru tekniklerle tespiti, acil hastaların gecikmeksizin nöroloji uzmanına başvurmasını veya acil servise yatışını sağlayacak, ilk başvuruda kesin tanı konulmasını mümkün kılacaktır. Böylece gerekli terapötik müdahaleler hızla başlatılabilecektir.

Önerilen yöntem, temel klinik bilgileri (baş dönmesini tanımlayan özellikler, eşlik eden semptomlar, bazı demografik veriler, komorbiditeler) ve hastanın bazı bilinen biyokimyasal verilerini ön değerlendirme aracı olarak kullanmaktadır.

Tablo 1'de sunulduğu üzere, çalışmamızda en yüksek ayırt edici güce sahip ilk beş özellik serum albümini, yaş, baş ağrısı varlığı, hipertansiyon ve diyabet varlığı olarak belirlenmiştir. Yaş, hipertansiyon, hiperlipidemi (çalışmamızda LDL) ve diyabet vasküler olaylar için risk faktörleridir. Albümin, plazmanın ana protein bileşenidir ve aynı zamanda kanda dolaşan endojen bir antioksidandır (27). İleri yaş, malnütrisyon ve bazı metabolik hastalıklar albümin seviyelerinde düşüğe neden olabilir. Klinik olarak albüminin doğrudan baş dönmesi ile ilişkilendirilmesi olası değildir. Hipoalbuminemi daha ziyade nörodejeneratif hastalıklarda ve baş dönmesine de neden olan yaşa bağlı sağlık sorunlarında bir epifenomen olabilir (28). Tanı için klinik olarak önemli görünmeyen özellikler, büyük verinin örtük kalıplarında anlamlı ve değerli olabilir. Öte yandan, diplopi çoğunlukla klinisyeni uyaran ciddi bir semptomdur.

Model	Actual VASCULAR-	Actual VASCULAR+	Predict VASCULAR-	Predict VASCULAR+
DT	346	44	36	44
LR	360	44	22	44
SVM	362	48	20	40
KNN	367	60	15	28
MLP	338	42	44	46
ENSEMBLE	355	54	27	34

Şekil 1. Makine Öğrenmesi Yöntemlerinin Karışıklık Matrisleri**Şekil 2.** Makine Öğrenmesi Yöntemlerinin Doğruluk (Accuracy) Sonuçları

Dahil ettiğimiz özellikler arasında, makine öğrenmesi ile baş dönmesini sınıflandırmada en az etkili olanı olarak ortaya çıkmıştır. Bunun nedenleri arasında hastalar tarafından semptomun doğru tanımlanamaması olabilir. Hastanın çift görme, osilatuar görme, monoküler diplopi veya binoküler diplopi yaşayıp yaşamadığı ancak detaylı bir anamnez ve tam nörolojik muayene sonrasında netleşir. Bu durum, klinik karar vermede insan deneyimi ve becerisine olan ihtiyacı vurgulamaktadır.

Klinik testler veri setimize dahil edilmemiştir. Yüksek boyutlu veriler makine öğrenmesi algoritmalarının sınıflandırma doğruluğunu artırır. Fizik muayene bulguları, klinik ve laboratuvar testleri ile radyolojik verileri içeren çeşitli çalışmalar yapılmıştır (29) (30) (31) (32) (33) (34). Bu çalışmaların bazıları yalnızca periferik nedenleri, bazıları yalnızca spesifik bir etiyojolojiyi içermiş ve çoğu, klinisyen tarafından yapılmış olan tanısal testlere veriyeye dahil etmiştir. Bizim amacımız, baş dönmesi şikayeti olan hastaların triajı için hızlı ve doğru bir araç geliştirmektir. Burada, hastaların uygun tıbbi branşlara yönlendirilmesi ve acil bakım gerektiren potansiyel olarak ciddi vakaların belirlenmesi için uzman hekim muayenesi öncesinde kullanılacak yardımcı bir model sunuyoruz. Klinik testlerin, hekimin muayene bulgularının ve spesifik laboratuvar testlerinin dahil edilmesi muhtemelen doğruluğu artıracaktır.

Makine öğrenmesi yöntemlerinin sağlık uygulamalarındaki performansı değişkenlik göstermiştir. Seven ve arkadaşları, 393 hepatosellüler karsinom hastasının klinik, patolojik ve laboratuvar verilerini kullanarak makine öğrenmesi yöntemleriyle sağkalım tahmini yapmış ve modellerin erken evre sağkalım için %91'e varan duyarlılık, ileri evrede %92'ye varan doğrulukla güçlü performans sergilediğini bildirmiştir (12). Esen ve arkadaşları, geleneksel görüntüleme yöntemlerinin kısıtlılıklarını aşmak için biyoempedans ve laboratuvar verileri kullanarak safra taşı hastalığını tahmin eden bir makine öğrenmesi yaklaşımı sunmuştur. 319 katılımcı (161 safra taşı hastası ve 158 sağlıklı) ile yapılan çalışmada D vitamini, CRP seviyeleri, toplam vücut suyu ve yağsız kütle en önemli belirleyiciler olarak tanımlanmıştır. Gradyan artırma yöntemi %85.42 tahmin doğruluğu ile en yüksek performansı göstermiştir (35). Erken safra taşı hastalığının tanısında bu yöntem maliyet etkin ve non-invazif bir seçenek olarak görülmektedir. Kos ve arkadaşları, metastaz yapmamış kolorektal kanser hastalarında genel ve zamana özgü sağkalımı tahmin etmek için makine öğrenmesi modellerini değerlendirmiştir. 10 yıllık takip verileriyle yapılan analizde karar ağacı modeli 1 yıllık sağkalımda (AUC 0.89), ensemble modeli 2-5 yıllık tahminlerde ve destek vektör makinesi modeli 10 yıllık sağkalımda (AUC 0.84) en iyi performansı göstermiştir. Tüm modeller, kanser evreleri genelinde %70 veya daha yüksek doğruluk göstermiş, makine öğreniminin kısa ve uzun vadeli kolorektal kanser sonuçlarını tahmin etme potansiyelini kanıtlamıştır (13). Sharafi ve arkadaşları, sporadik ve ailesel Nörofibromatozis tip 1 arasındaki klinik farklılıkları incelemiş ve semptomlara dayalı olarak sporadik vakaları tahmin etmek için makine öğrenmesi modellerini değerlendirmiştir. XGBoost algoritması %62.86 tahmin doğruluğu ile geleneksel yöntemlere yardımcı olabilecek potansiyel göstermiştir (14).

Wang ve arkadaşları tarafından öne sürülen bir makine öğrenimi aracı, vestibüler migren ile Meniere hastalığını ayırt etmede en yüksek doğruluk oranlarından birini elde etmiştir (29). Çalışmada hasta öyküsü, video-nistagmografi ve odyovestibüler test verileri kullanılmıştır. 274 hastanın (160'ı vestibüler migren tanılı) verileriyle eğitilen modeller, üç farklı klinik senaryoda yüksek doğruluk sergilemiş; AdaBoost ve Random Forest algoritmaları en iyi performansı göstermiştir. Çalışma popülasyonu, tekrarlayıcı spontan vertigo ile seyreden iki hastalık türüyle sınırlanmıştır. Veri kümesi ne kadar homojen olursa, modelin öğrenme kapasitesi ve doğruluk oranları o kadar artmaktadır. Ancak baş dönmesinin ayırıcı tanısı geniş bir hastalık spektrumunu kapsadığından, bizim veri kümemiz kaçınılmaz olarak heterojen yapıdaydı. Lu ve arkadaşları, BPPV tanısı için bir derin öğrenme yöntemi önermiş ve 518

hastanın göz hareketi video verilerini kullanarak %81,7 doğruluk elde etmişlerdir (30). Kim ve arkadaşları ise basit klinik verilerle akut santral baş dönmesini teşhis eden bir makine öğrenimi modeli geliştirmiş; 5048 hasta üzerinde yapılan analizde AUC değeri 0,73, duyarlılık %94,4 ve özgüllük %31,9 olarak raporlanmıştır (33). Bu yöntemin temel dezavantajı düşük özgüllüktür. Ayrıca, veri kümesi eğitim ve test gruplarına ayrılmış, çapraz doğrulama yapılmamıştır. Çapraz doğrulama uygulanmış olsaydı, makine öğrenimi yönteminin performansı düşebilirdi.

Bizim temel odak noktamız, vasküler vertigo hastalarının erken dönemde ayırt edilmesi idi. Bu nedenle veri kümesini "vasküler" ve "diğerleri" şeklinde ikili sınıflandırmaya tabi tuttuk. Diğer alt gruplardaki doğruluk değerleri düşük çıkmıştır. Bunun nedeni, makine öğreniminde en kritik faktör olan veri kümesi boyutunun bazı alt gruplarda yetersiz kalması veya klinik kayıtlardaki eksik veriler olabilir.

Çalışmamızda en iyi performans gösteren makine öğrenimi yöntemi, lojistik regresyon modeli oldu. Vasküler ve vasküler olmayan baş dönmesi vakalarını doğru sınıflandırmada %86 doğruluk sağladı. Ancak bu yöntemle bile atlanan vasküler vakaların olduğu görülmektedir. Sisteme her yeni kayıt, modelin iyileşmesine katkı sağlayacaktır (mevcut vasküler vaka sayısı: 88). Grup büyüklüğü arttıkça modelin performansının artması beklenmektedir. Atlanan vakaların bir diğer önemli klinik nedeni, vasküler vertigo grubunun kendi içindeki yapısal heterojenitedir. Bu kategori, her biri farklı patofizyolojik mekanizmalara sahip oldukça çeşitli etiyojileri kapsamaktadır. Akut başlangıçlı ve genellikle belirgin nörolojik defisitlerle seyreden inme kaynaklı vertigonun yanı sıra, geçici serebral hipoperfüzyonun neden olduğu, episodik baş dönmesi ile karakterize şiddetli hipotansiyon, presenkop ve senkop vakaları da bu gruptadır. İnme kaynaklı vertigo sıklıkla fokal iskemik bulgularla (nistagmus, ataksi veya kraniyal sinir tutulumu gibi) birlikte bulunurken, hipoperfüzyon kaynaklı baş dönmesi daha çok ortostatik değişikliklerin veya kardiyak disfonksiyonun tetiklediği kısa süreli, tekrarlayıcı epizodlar şeklinde ortaya çıkmaktadır. Bu farklı klinik tabloların "vasküler vertigo" şeklinde tek bir etiket altında sınıflandırılması, ortak vasküler etiyojisi nedeniyle klinik olarak haklı gerekçelere dayansa da, tanısal karmaşıklığa yol açmaktadır. İnme veya geçici iskemik atak kaynaklı vertigo acil nörogörüntüleme ve müdahale gerektirirken, hipotansiyon kaynaklı baş dönmesi acil kardiyolojik veya otonomik değerlendirme gerektirebilir. Altta yatan patolojideki ve ilişkili klinik özelliklerdeki bu çeşitlilik, muhtemelen modelin bu alt gruptaki doğruluk oranının düşük çıkmasına katkıda bulunmuştur.

Görüldüğü gibi çalışmanın başlıca kısıtlılığı, baş dönmesinin çok geniş bir etiyojistik spektruma sahip olması ve her sınıftaki hasta sayısının azlığıdır. Ayrıca, TOBB ETÜ Hastanesinin özel bir vakfı hastanesi olması nedeniyle, hasta demografisinin genel popülasyonu tam yansıtmaması da bir sınırlılık olarak not edilmelidir.

Sonuç olarak, bu çalışma makine öğrenimi algoritmalarının, klinik ve bazı biyokimyasal verilerle vasküler vertigo hastalarını tanımlamada etkili olduğunu göstermiştir. Modelimiz, ambulans personeli, acil hekimleri, pratisyenler ve atipik vakalarla karşılaşan uzmanlar için faydalı olabilir. Yapay zekânın sağlık hizmetlerine entegrasyonu, hasta bakım kalitesini artırabilir ve sağlık harcamalarını azaltabilir.

Hakem Değerlendirmesi: Dış bağımsız.

Yazar Katkıları: Fikir- ATS, HY; Tasarım- ATS, HA; Denetleme- ATS, HA; Malzemeler- ATS, HA, EE, KSU; Veri toplama ve/veya işlemesi- ATS, HY, EE, KSU; Analiz ve Yorumlama- ATS, HY; Literatür Taraması- ATS, HA, HY, EE, KSU; Yazıyı Yazan- ATS, HA; Eleştirel İnceleme- ATS, HA.

Çıkar Çatışması: Yazarlar herhangi bir mali çıkar çatışması veya kişisel ilişki bulunmadığını beyan ederler.

Veri Paylaşımı: Bu çalışmada kullanılan veri seti hasta sağlık verileri içerdiğinden, gizlilik nedeniyle kamuya açık değildir. Anonimleştirilmiş versiyon, ilgili yazara makul bir talep üzerine sağlanabilir.

Teşekkür: Dr. Aslıhan Taşkıran Sağ, bu projeye “XVII. Dr. Aysun-Ahmet Küçükkel Sağlıkta Dijital Dönüşüm ve Yenilikçi Bakış Açısı Ödülü”nü almıştır.

KAYNAKLAR

1. Neuhauser HK. The epidemiology of dizziness and vertigo. *Handb Clin Neurol*. 2016;137:67-82. [Crossref]
2. Newman-Toker DE, Hsieh YH, Camargo CA, Jr., Pelletier AJ, Butchy GT, Edlow JA. Spectrum of dizziness visits to US emergency departments: cross-sectional analysis from a nationally representative sample. *Mayo Clin Proc*. 2008;83(7):765-75. [Crossref]
3. Gopinath B, McMahon CM, Rochtchina E, Mitchell P. Dizziness and vertigo in an older population: the Blue Mountains prospective cross-sectional study. *Clin Otolaryngol*. 2009;34(6):552-6. [Crossref] [Crossref] doi: 10.1111/j.1749-4486.2009.02025.x
4. Bisdorff A, Von Brevern M, Lempert T, Newman-Toker DE. Classification of vestibular symptoms: towards an international classification of vestibular disorders. *J Vestib Res*. 2009;19(1-2):1-13. Epub 2009/11/07. [Crossref]
5. Newman-Toker DE. Charted records of dizzy patients suggest emergency physicians emphasize symptom quality in diagnostic assessment. *Ann Emerg Med*. 2007;50(2):204-5. [Crossref]
6. Karatas M. Central vertigo and dizziness: epidemiology, differential diagnosis, and common causes. *Neurologist*. 2008;14(6):355-64. Epub 2008/11/15. [Crossref]
7. Tarnutzer AA, Berkowitz AL, Robinson KA, Hsieh YH, Newman-Toker DE. Does my dizzy patient have a stroke? A systematic review of bedside diagnosis in acute vestibular syndrome. *CMAJ*. 2011;183(9):E571-92. Epub 20110516. [Crossref]
8. To-Alemanji J, Ryan C, Schubert MC. Experiences Engaging Healthcare When Dizzy. *Otol Neurotol*. 2016;37(8):1122-7. Epub 2016/08/16. [Crossref]
9. Ruthberg JS, Rasendran C, Kocharyan A, Mowry SE, Otteson TD. The economic burden of vertigo and dizziness in the United States. *J Vestib Res*. 2021;31(2):81-90. Epub 2020/12/09. [Crossref]
10. Ozdemir S, Ozdemir D, Terzi O, Mehel DM, Ozgur A. The Economic Burden of Vertigo: Results From the Hospitalized and Outpatients. *Ear Nose Throat J*. 2021;100(5_suppl):707S-11S. Epub 2020/02/20. [Crossref]
11. Powers WJ, Rabinstein AA, Ackerson T, Adeoye OM, Bambakidis NC, Becker K, et al. Guidelines for the Early Management of Patients With Acute Ischemic Stroke: 2019 Update to the 2018 Guidelines for the Early Management of Acute Ischemic Stroke: A Guideline for Healthcare Professionals From the American Heart Association/American Stroke Association. *Stroke*. 2019;50(12):e344-e418. Epub 2019/10/31. [Crossref]
12. Seven I, Bayram D, Arslan H, Kos FT, Gumuslu K, Akturk Esen S, et al. Predicting hepatocellular carcinoma survival with artificial intelligence. *Sci Rep*. 2025;15(1):6226. Epub 20250220. [Crossref]
13. Kos FT, Cecen Kaynak S, Akturk Esen S, Arslan H, Uncu D. Comparison of Different Machine Learning Models for Predicting Long-Term Overall Survival in Non-metastatic Colorectal Cancers. *Cureus*. 2024;16(12):e75713. Epub 20241214. [Crossref]
14. Sharafi P, Arslan H, Ersoy Evans S, Varan A, Ayter S. A machine learning approach for predicting familial and sporadic disease cases based on clinical symptoms: introduction of a new dataset. *Turkish Bulletin of Hygiene and Experimental Biology*. 2025;82(1). [Crossref]
15. Sirsat MS, Ferme E, Camara J. Machine Learning for Brain Stroke: A Review. *J Stroke Cerebrovasc Dis*. 2020;29(10):105162. Epub 20200728. [Crossref]
16. Swanson K, Wu E, Zhang A, Alizadeh AA, Zou J. From patterns to patients: Advances in clinical machine learning for cancer diagnosis, prognosis, and treatment. *Cell*. 2023;186(8):1772-91. Epub 20230310. [Crossref]
17. Kabade V, Hooda R, Raj C, Awan Z, Young AS, Welgampola MS, et al. Machine Learning Techniques for Differential Diagnosis of Vertigo and Dizziness: A Review. *Sensors (Basel)*. 2021;21(22). Epub 20211114. [Crossref]
18. Anh DT, Takakura H, Asai M, Ueda N, Shojaku H. Application of machine learning in the diagnosis of vestibular disease. *Sci Rep*. 2022;12(1):20805. Epub 20221202. [Crossref]
19. Tang X, Ye W, Ou Y, Ye H, Zhu X, Huang D, et al. Development and Validation of a Machine Learning Model for Detection and Classification of Vertigo. *Laryngoscope*. 2025;135(5):1652-60. Epub 20241219. [Crossref]
20. Tin Kam H. The random subspace method for constructing decision forests. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1998;20(8):832-44. [Crossref]
21. Nick TG, Campbell KM. Logistic Regression. *Topics in Biostatistics. Methods in Molecular Biology™*2007. p. 273-301.
22. Cortes C, Vapnik V. Support-vector networks. *Machine Learning*. 1995;20(3):273-97. [Crossref]
23. Bishop CM. A New Framework for Machine Learning. *Computational Intelligence: Research Frontiers. Lecture Notes in Computer Science*2008. p. 1-24.
24. Bishop CM. Neural networks and their applications. *Review of Scientific Instruments*. 1994;65(6):1803-32. [Crossref]
25. Bishop CM. *Pattern Recognition and Machine Learning*. New York: Springer; 2006.
26. Dong X, Yu Z, Cao W, Shi Y, Ma Q. A survey on ensemble learning. *Frontiers of Computer Science*. 2019;14(2):241-58. [Crossref]
27. Roche M, Rondeau P, Singh NR, Tarnus E, Bourdon E. The antioxidant properties of serum albumin. *FEBS Lett*. 2008;582(13):1783-7. Epub 2008/05/14. [Crossref]
28. Saeed F, Kousar N, Qureshi K, Laurence TN. A review of risk factors for stroke in patients with chronic kidney disease. *J Vasc Interv Neurol*. 2009;2(1):126-31. Epub 2009/01/01. PubMed PMID: 22518239; PubMed Central PMCID: PMC3317334.
29. Wang C, Young AS, Raj C, Bradshaw AP, Nham B, Rosengren SM, et al. Machine learning models help differentiate between causes of recurrent spontaneous vertigo. *J Neurol*. 2024;271(6):3426-38. Epub 2024/03/23 20:51. [Crossref]
30. Lu H, Mao Y, Li J, Zhu L. Multimodal deep learning-based diagnostic model for BPPV. *BMC Med Inform Decis Mak*. 2024;24(1):82. Epub 2024/03/22. [Crossref]
31. Duvieusart B, Leung TS, Koochi N, Kaski D. Digital biomarkers from gaze tests for classification of central and peripheral lesions in acute vestibular syndrome. *Front Neurol*. 2024;15:1354041. Epub 2024/04/10. [Crossref]
32. Wu P, Liu X, Dai Q, Yu J, Zhao J, Yu F, et al. Diagnosing the benign paroxysmal positional vertigo via 1D and deep-learning composite model. *J Neurol*. 2023;270(8):3800-9. Epub 2023/04/20. [Crossref]
33. Kim BJ, Jang SK, Kim YH, Lee EJ, Chang JY, Kwon SU, et al. Diagnosis of Acute Central Dizziness With Simple Clinical Information Using Machine Learning. *Front Neurol*. 2021;12:691057. Epub 2021/07/30. [Crossref]
34. Du Y, Ren L, Liu X, Wu Z. Machine learning method intervention: Determine proper screening tests for vestibular disorders. *Auris Nasus Larynx*. 2022;49(4):564-70. Epub 2021/11/11. [Crossref]
35. Esen I, Arslan H, Akturk Esen S, Gulsen M, Kultekin N, Ozdemir O. Early prediction of gallstone disease with a machine learning-based method from bioimpedance and laboratory data. *Medicine (Baltimore)*. 2024;103(8):e37258. [Crossref]