



Plantar Basınç Dağılımı Sinyalleri Kullanılarak Erken MS'lilerde Ataksinin Hybrt CNN Modelleri ile Belirlenmesi

Aslı Sesli^{1*}, Seda Arslan Tuncer², Furkan Bilek³

^{1*} Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yazılım Mühendisliği Bölümü, Elazığ, Türkiye, (ORCID: 0000-0002-6514-4908), aslisesli8@gmail.com

² Fırat Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, Elazığ, Türkiye (ORCID: 0000-0001-6472-8306), satuncer@firat.edu.tr

³ Fırat Üniversitesi, Sağlık Bilimleri Fakültesi, Fizyoterapi ve Rehabilitasyon Bölümü, Elazığ, Türkiye (ORCID: 0000-0003-1567-7201), fzt.furkanbilek@gmail.com

(1st International Conference on Applied Engineering and Natural Sciences ICAENS 2021, November 1-3, 2021)

(DOI: 10.31590/ejosat.1009129)

ATIF/REFERENCE: Sesli, A., Arslan-Tuncer, S. & Bilek, F. (2021). Plantar Basınç Dağılımı Sinyalleri Kullanılarak Erken MS'lilerde Ataksinin Hybrt CNN Modelleri ile Belirlenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 579-583.

Öz

Multipl Skleroz (MS), ataksi ve denge bozukluklarına neden olan bir merkezi sinir sistemi hastalığıdır. Atakside genellikle ilk semptom yürüyüş bozukluğu olarak görülmektedir. Yürüyüş ataksisi klinik olarak artmış çift destek süresi, kısalmış adım uzunluğu ve düzensiz adımlar ile tanımlanabilir. Bu yüzden ataksi tespitinde yürüme bozukluğunun değerlendirilmesi doğru bir yol olacaktır. Derin öğrenme çok sayıda girdi verisinden özellik çıkararak çıktı verisini tahmin eden bir makine öğrenmesi yöntemidir. Derin öğrenme nesne tanıma, sınıflandırma ve sinyal işleme gibi alanlarda sıklıkla kullanılmaktadır. Bu çalışmada plantar basınç dağılımı sinyalleri içeren görüntüler kullanılarak MS'li bireyler (PwMS) için ataksi tespiti yapılmaya çalışılmıştır. Bu amaçla PwMSi olan ve sağlıklı olan bireylerin plantar basınç dağılımı sinyallerini içeren toplam 418 görüntü önceden eğitilmiş Hybrt CNN ağlar yardımıyla sınıflandırılmıştır. Veri setinden özellik çıkarılırken VGG16, VGG19, ResNet, MobilNet ve NasNet derin öğrenme mimarileri kullanıldı. Daha sonra elde edilen özellik vektörleri SVM, KNN ve ANN sınıflandırıcıları kullanılarak sınıflandırıldı. Bu çalışma sonucunda en iyi sınıflandırma performansı, SVM sınıflandırıcısı ile VGG19 %85.71 Acc %81.81 Sen, %88.23 Spe derin öğrenme mimarisi kullanılarak elde edilmiştir. Yapılan bu çalışmanın yapay zeka yardımı ile PwMS'de ataksi tespitinde hekime yardımcı olacağı kanaatine varılmıştır.

Anahtar Kelimeler: Multiple Skleroz, Ataksi, Derin Öğrenme, Sınıflandırma

Determination of Ataxia With Hybrt CNN Models in Early MS Using Plantar Pressure Distribution Signals

Abstract

Multiple sclerosis (MS) is a disease of the central nervous system that causes ataxia and deficits in balance. In ataxia, the first symptom is usually seen as gait disturbance. Gait ataxia can be clinically defined by increased double support time, shortened stride length, and irregular strides. In this direction, the evaluation of deterioration in the detection of ataxia would be the right way. Deep learning is a machine learning method that predicts output data by extracting features from a large number of input data. Deep learning is frequently used in areas such as object recognition, classification and signal processing. In this study, it was aimed to detect ataxia for individuals with MS (PwMS) using images containing plantar pressure distribution signals. For this purpose, a total of 418 images containing the plantar pressure distribution signals of healthy individuals with PwMSi were classified with the help of pre-trained Hybrid CNN networks. VGG16, VGG19, ResNet, MobilNet and NasNet deep learning architectures were used to extract features from the dataset. Then the obtained feature vectors were classified using SVM, KNN and ANN classifiers. As a result of this study, the best classification performance was obtained by using the SVM classifier and VGG19 85.71% Acc 81.81% Sen, 88.23% Spe deep learning architecture. It was concluded that this study will help the physician in the detection of ataxia in PwMS with the help of artificial intelligence..

Keywords: Multiple Sclerosis, Ataxia, Deep Learning, Classification

* Sorumlu Yazar: aslisesli8@gmail.com

1. Giriş

Multipl skleroz (MS), merkezi sinir sisteminin kronik, enflamatuar ve otoimmün bir hastalığıdır, çoklu demiyelinizan plakların zaman ve mekânda yayıldığı çeşitli belirtilere ve semptomlara neden olur [1]. Ataksi bu semptomların en zorlayıcılarından biridir. Serebellar, vestibüler ve / veya duyuşal sistem problemlerine bağlı olarak ortaya çıkar. Kas kuvvet kayıpları, spastisite, duyuşal sorunlar, yorgunluk MS'de görülen yürüyüş bozukluklarının Ataksik semptomların şiddeti ve özellikleri bu sorunların varlığına göre değişir ve genellikle birlikte ortaya çıkar [2].

Yürüyüşün yaşam kalitesine ve fonksiyonel bağımsızlığa olan önemine dair artan farkındalık, pek çok araştırma grubunun bu motor fonksiyonların pato-fizyolojisi, epidemiyolojisi, klinik ve terapötik yönlerini incelemesine neden olmuştur [5].

Minimal engelli MS'libireylerde (PwMS), yürüyüş değişikliklerinin tespiti ve anlaşılması zordur. Bazı çalışmalar hız, kadans ve adım uzunluğunu ve çift desteğin artmış süresini bildirirken diğerleri sağlıklı bireyler ile ilgili herhangi bir fark tespit edememekte veya bunları birkaç parametrede bulamamaktadır [7-10].

İnsan gözü saniyede 18–25 adet görüntü algılayabilmektedir. Bu sebeple yürüyüş esnasında milisaniyeler içinde gerçekleşen hareketlerin objektif olarak değerlendirilmesi mümkün değildir.

Başarılı bir tedavi uygulanabilmesi için tanının doğru konulması önemli iken normal ve patolojik yürüyüş özellikleri bilinmeli ve yürüyüşü etkileyen asıl neden anlaşılmalıdır [11].

PwMS'de ataksi tespiti için yürüyüşün basınç dağılımını içeren görüntüyü kullanan makine öğrenmesi temelli yaklaşımlara literatür de rastlanmamıştır. Fakat MS dışındaki farklı hastalıklarda ataksi tespiti için derin öğrenme ya da makine öğrenme yöntemi kullanılmıştır. Bu amaçla genellikle yüksek maliyetli giyilebilir sensörler ya da accelerometric kullanmışlardır [12,15].

Mevcut yöntemlerle hastalardan veri elde etmek için giyilebilir teknoloji veya Win-Track platformları kullanılmaktadır. Ancak tanı için elde edilen veriler doğrudan uzman hekim tarafından değerlendirilir. Hastalığın erken evrelerinde, henüz semptomatik olmayan veya EDSS skoru ikinin altında olan bireylerdeki minimum etkileşimli yürüyüş farklılıklarının hekimler tarafından teşhisi klinik olarak oldukça zordur. Yüksek performanslı karar destek sistemleri, hastalığın erken teşhisi ve bu alanda hekim değerlendirmesine yardımcı olması açısından çok önemli olacaktır.

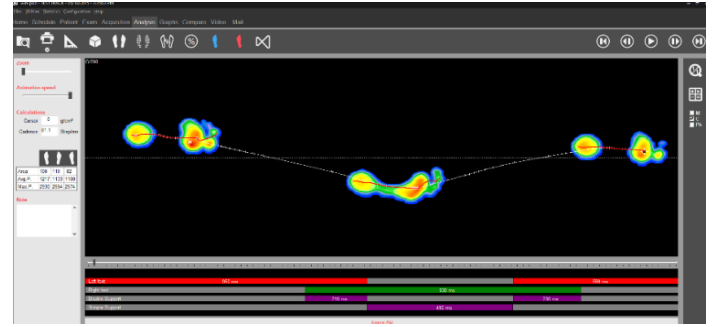
Bu çalışmada, plantar basınç dağılımı sinyalleri içeren bir görüntü veri seti kullanılarak, derin öğrenme tabanlı bir yaklaşımla PwMS için ataksi tespit edilmesi amaçlanmaktadır. Çalışmada PwMS'yi erken evrelerde teşhis etmek amacıyla hekimlere yardımcı olacak alternatif ve objektif bir yöntem önerilmektedir.

2. Materyal ve Metot


Bu çalışmada Fırat Üniversitesi Hastanesi Nöroloji Bölümüne başvuran ve Mc Donald kriterlerine göre kesin MS tanısı konulmuş gönüllü 43 ataksik MS'li birey ve 62 sağlıklı olmak

üzere toplam 105 bireyin verileri kullanıldı. Tüm işlemler, Fırat Üniversitesi Girişimsel Olmayan Araştırmalar Etik Kurulu tarafından onaylanan ilkelere uygun olarak gerçekleştirildi ve tüm katılımcılar yazılı bilgilendirilmiş onam verdi. Tüm katılımcıların ataksi durumu, Ataksiyi Değerlendirme ve Değerlendirme Ölçeği (SARA) ile değerlendirildi [16].

Win-Track platformu (MEDICAPTEURS Technology, Fransa), yalınayak yürüme sırasında plantar basıncı ve yürüyüş parametrelerini ölçen bir araçtır. Boyutları 1610 mm × 652 mm × 30 mm (uzunluk / genişlik / yükseklik)'dir. Platform dirençli tipte 12288 sensör içerir. Sensörlerin boyutları 7.8 × 7.8 mm2'dir ve aparatın yakalama frekansı 200 görüntü / saniyedir. Her bir hastanın yürüyüş esnasında taban altı basınç dağılımını içeren görüntüyü almak için Win-Track basınç platformu kullanıldı. Şekil 1 PwMS ait plantar basınç dağılımı görüntülerini gösterirken, Şekil 2 ise çalışmada kullanılan veriyi göstermektedir. Şekil 2 de 3 farklı renkte sinyal bulunmaktadır. Görüntüdeki sinyallerden kırmızı sinyal sol ayak, yeşil sinyal sağ ayak mor sinyal ise dönüşümlü olarak double support, single support ve swing faz parametrelerini göstermektedir.



Şekil 1: MS'li Bireye Ait Plantar Basınç Dağılımı Görüntüsü



Şekil 2: MS'li Bireye Ait Plantar Basınç Dağılımı Sinyalleri

Evrışimli sinir ağı (CNN), günümüzde en çok kullanılan derin öğrenme modellerinden biridir. CNN modelleri, nesne tanıma, sinyal ve görüntü işleme gibi birçok alanda kullanılmaktadır [17]. Bu çalışmada yürüyüş basınç dağılımı sinyalleri ile önceden eğitilmiş CNN modelleri kullanılarak PwMS'de ataksi tespitinin yapılması amaçlanmıştır.

Büyük hacimli bir eğitim verisi veya işleyecek donanım gücünün olmaması durumunda Transfer Learning yöntemi yaklaşımı kullanılır. Transfer learning, büyük miktarlarda ve uzun süreler eğitim sonucunda optimum parametrelere ulaşmış ağırlıklar üzerinden mevcut düşük miktarlı veriler üzerinde öznetelik çıkarmak için yaygın olarak kullanılmaktadır [17].

Yürüyüş basınç sinyalleri içeren görüntüler VGG16, VGG19, ResNet, MobileNet ve NasNetMobile modellerinin giriş verisi olarak kullanılmış, böylece transfer öğrenme yöntemi kullanılarak her modelden çıktı olarak özellik vektörleri elde edilmiştir.


VGG16 13 konvülosyan katmanı ve 3 tam bağlı katmanlı bir yapıya sahiptir. 2x2 boyutlu 5 max pooling ve son katmanda softmax katmanı bulunmaktadır. Aktivasyon fonksiyonu olarak ReLu kullanılmıştır ve 138 milyon parametreye sahiptir [18].

VGG19 16 konvülosyan katmanı, 3 tam bağlı katmanlı bir yapıya ve 144 milyon parametreye sahiptir [18].

ResNet modeli ise 50 katmanlı bir yapıya sahiptir ve CNN'lerde ağ yapısının derinliği artıkça eğitim zorlaşması sorununu çözmek için normal CNN'lerdeki nonlinear F(x) fonksiyonu kullanarak haritalamak yerine girişten (x) çıkışa bir kısayol bağlantısı yaparak ve belirli katmanları atlayarak, giriş (x) değerini F(x) fonksiyonuna aritmetik (F(x)+x) olarak eklemektedir. Böylece daha kolay bir eğitim süreci gerçekleştirmektedir [19].

MobileNet, hesaplama gücünün zayıf olduğu mobil ve gömülü görsel uygulamalar için geliştirilmiş bir derin CNN mimarisidir. Bu mimari aynı zamanda çoğu gerçek dünya problemlerine çözüm olabilecek gerçek zamanlı nesne tanıma gibi uygulamalarda kullanılmaktadır [20].

NasNet Derin öğrenme mimarilerin eğitiminde neural network oluşturma ve oluşturulan ağın yönetilmesi konusunda mimari mühendislik bilgisi gerektirmektedir. Bu zorluğu minimize etmek amacıyla Google yapay zekâ araştırmacıları tarafından oluşturulacak ağı mimarisini kendi organize edebilen otomatik bir makine öğrenme sistemi tasarlamıştır [21].



Şekil 3 : Önerilen karar destek sistemi

VGG16, VGG19, ResNet, MobileNet ve NasNetMobile modelleri kullanılarak çıkarılan özellikler SVM KNN ve ANN sınıflandırıcıları yardımıyla sınıflandırılmıştır.

Destek vektör makineleri (SVM), bir uzayı bilinen pozitif ve negatif örneklerle ikiye ayıran en iyi hiper düzlemi bulmayı amaçlayan sınıflandırma yöntemlerinden biridir. Zaman serilerinin sınıflandırmasında, yüz tanıma uygulamalarında ve medikal teşhislerin biyolojik veri işlemlerinde sıklıkla kullanılmaktadır.

K-En Yakın komşu (k-NN) algoritması, uygulaması kolay denetimli öğrenme algoritmalarından biridir. Algoritma, belirli sınıflar ile bir örnek kümesindeki verileri kullanarak sınıflandırma yapar. Veri setine dahil edilecek yeni verinin mesafesi mevcut verilere göre hesaplanır ve k yakın komşu kontrol edilir [22].

Yapay Sinir Ağları (ANN) insan beyninin çalışma yeteneğini taklit ederek ortaya çıkmıştır. Yapay sinir ağlarında parametrelerin güncellenmesi için geri yayılım algoritmaları kullanılmaktadır. Delta kuralı, geri yayımlı ağ eğitilirken hedef değerler ile çıkış değerleri arasındaki farkın bir kısmı, her bir eğitim hücrelerine geri yansıtılarak ağırlıkların değiştirilmesini ve bu işlemin belli sayıda tekrarlanarak hatanın en küçük değere ulaşmasını sağlayan bir yöntemdir [23].

Sınıflandırmanın homojen bir yapıda olması amacıyla en sonda çapraz doğrulama yöntemi kullanılmıştır. K değeri 5 olarak belirlenmiştir. Çapraz doğrulama yöntemi modelin görmediği veriler üzerinde objektif ve daha doğru sonuçlar elde edilmesi için kullanılan istatistiksel bir yöntemdir.

3. Araştırma Sonuçları ve Tartışma

3.1. Bulgular

Bu çalışmada modellerin sınıflandırma performansları doğruluk, hassasiyet özgüllük ve F ölçüsü metrikleri kullanılarak değerlendirilmiştir. Kullanılan metriklerin yöntem ve formülleri aşağıda verilmiştir.

$$\text{Hassasiyet (Sen)} = \frac{N_{TP}}{N_{FN} + N_{TP}}$$

$$\text{Özgüllük (Spe)} = \frac{N_{TN}}{N_{TN} + N_{FP}}$$

$$\text{F1 Skor} = 2 \times \frac{N_{TP}}{N_{FN} + N_{TP}}$$

$$\text{Doğruluk (Acc)} = \frac{N_{TN} + N_{TP}}{N_{TN} + N_{FN} + N_{TP} + N_{FP}}$$

Doğru Pozitif (TP) : Doğru şekilde tanımlanan ataksi geçirmiş MS hastası sayısı

Yanlış Negatif (FN) : Sağlıklı olarak tanımlanan ataksi geçirmiş MS hastası sayısı

Doğru Olumsuz (TN) : Sağlıklı olan ve sağlıklı olarak tanımlanan sağlıklı birey sayısı

Yanlış Pozitif (FP) : Sağlıklı olan ancak ataksi geçirmiş MS hastası olarak tanımlanan birey sayısı

Tablo 1 de, kullanılan performans değerlendirme metrikleri ve modeller ile elde edilen sonuçlar verilmiştir.


Tablo 1 Elde Edilen Sınıflandırma Sonuçları

	Model	Acc (%)	Spe (%)	F1 Measure(%)
SVM	VGG16	85.71	84.31	82.85
	VGG19	85.71	88.23	81.81
	ResNet	79.76	87.03	77.65
	MobileNet	80.95	89.36	77.66
	NasNetMobile	80.95	85.10	77.67
KNN	VGG16	73.80	66.66	77.68
	VGG19	80.95	78.72	77.69
	ResNet	75.00	76.59	77.70
	MobileNet	78.57	76.59	77.71
	NasNetMobile	77.38	80.85	77.72
ANN	VGG16	77.38	76.47	77.73
	VGG19	77.38	86.66	77.74
	ResNet	80.95	87.80	77.75
	MobileNet	80.95	95.74	77.76
	NasNetMobile	80.95	85.10	77.77

Tabloda da görüldüğü gibi VGG19 ile çıkarılan özelliklerin SVM sınıflandırıcıları ile daha yüksek doğrulukla sınıflandırdığı görülmektedir. Aynı zamanda SVM sınıflandırıcılarının diğer tüm sınıflandırıcılardan daha yüksek sonuçlar verdiği gözlenmiştir.


Kullanılan 5 CNN model ve sınıflandırıcılar analiz edildiğinde en yüksek doğruluk, hassasiyet ve özgüllük değerine VGG19 modeli ile (%85.71 Acc %81.81 Sen, %88.23)Spe ulaşmıştır.

Şekil 4 de, kullanılan CNN modeller ve sınıflandırıcılar ile elde edilen doğruluk sonuç grafiği verilmiştir.



Şekil 4: Sınıflandırma Sonuç Grafiği

Karışıklık matrisi, genellikle bir sınıflandırma modelinin test verileri üzerindeki performansını tanımlamak için kullanılan etkili bir araçtır. Aşağıdaki şekilde, en iyi başarıyı sağlayan SVM sınıflandırıcısı ile sınıflandırılmış VGG19 modelinin karışıklık matrisi bulunmaktadır.



Şekil 5: SVM Sınıflandırıcısı ile Sınıflandırılmış VGG19 modeli karışıklık matrisi

3.2. Tartışma

Kesinlik, doğru tahmin ettiğimiz alanların toplam veri kümesine oranı ile hesaplandığından, tek başına yeterli değildir. Hassasiyet, bir testin test edilen koşula sahip kişiler için ne sıklıkla doğru bir sonuç verdiğini ölçerken, Özgüllük, bir testin test edilmekte olan koşula sahip olmayan kişiler için doğru bir negatif sonuç üretme yeteneğini ölçer. Bu nedenle hepsi birlikte değerlendirilmelidir. Sınıflandırıcılar için ise doğrudan sınıflandırıcı başarısından

bahsetmek yerine kullanılan modelin problem çözmeye yatkınlığından bahsedilebilir. Bölüm 3 de elde edilen bulgular analiz edildiğinde VGG19 SVM modelinin çözülmesi amaçlanan problem için daha uygun olduğu söylenebilir.

4. Sonuç

Bu çalışmada, PwMS ait, Plantar basınç dağılımını içeren sinyaller kullanılarak önceden eğitilmiş CNN ağları yardımıyla Ataksi tespiti yapılmıştır. Çalışma PwMS'de ataksi tespiti için otonom bir karar destek sistemi sağlayabilmiştir. Bu sayede probleme insan yanlılığından uzak standardize bir çözüm getirilmiştir. Çalışmanın performansından yola çıkarak, pratikte uygulanabileceğini, henüz semptom vermeyen ve klinik olarak fark edilmeyen ataksinin erken dönemde tespit edilebileceğini ve hekime yardımcı bir sistem olarak önerilebileceği kanaatine varılmıştır.

5. Teşekkür

Değerli katılımcılara işbirlikleri için teşekkür ederiz.

Kaynakça

- [1] McDonald, W. I., Compston, A., Edan, G., Goodkin, D., Hartung, H. P., Lublin, F. D., McFarland, H. F., Paty, D. W., Polman, C. H., Reingold, S. C., Sandberg-Wollheim, M., Sibley, W., Thompson, A., van den Noort, S., Weinshenker, B. Y., & Wolinsky, J. S. (2001). Recommended diagnostic criteria for multiple sclerosis: guidelines from the International Panel on the diagnosis of multiple sclerosis. *Annals of neurology*, 50(1), 121–127. <https://doi.org/10.1002/ana.1032>
- [2] Finlayson, M., Multiple sclerosis rehabilitation: from impairment to participation. (2012): Crc Press, <https://doi.org/10.1201/b12666>.
- [3] Bethoux, F., & Bennett, S. (2011). Evaluating walking in patients with multiple sclerosis: which assessment tools are useful in clinical practice?. *International journal of MS care*, 13(1), 4–14. <https://doi.org/10.7224/1537-2073-13.1.4>
- [4] Givon, U., Zeilig, G., & Achiron, A. (2009). Gait analysis in multiple sclerosis: characterization of temporal-spatial parameters using GAITRite functional ambulation system. *Gait & posture*, 29(1), 138–142. <https://doi.org/10.1016/j.gaitpost.2008.07.011>
- [5] Nutt, J. G., Horak, F. B., & Bloem, B. R. (2011). Milestones in gait, balance, and falling. *Movement disorders : official journal of the Movement Disorder Society*, 26(6), 1166–1174. <https://doi.org/10.1002/mds.23588>
- [6] Heesen, C., Böhm, J., Reich, C., Kasper, J., Goebel, M., & Gold, S. M. (2008). Patient perception of bodily functions in multiple sclerosis: gait and visual function are the most valuable. *Multiple sclerosis (Houndmills, Basingstoke, England)*, 14(7), 988–991. <https://doi.org/10.1177/1352458508088916>
- [7] Benedetti, M. G., Piperno, R., Simoncini, L., Bonato, P., Tonini, A., & Giannini, S. (1999). Gait abnormalities in minimally impaired multiple sclerosis patients. *Multiple sclerosis (Houndmills, Basingstoke, England)*, 5(5), 363–368. <https://doi.org/10.1177/135245859900500510>

- [8] Martin, C. L., Phillips, B. A., Kilpatrick, T. J., Butzkueven, H., Tubridy, N., McDonald, E., & Galea, M. P. (2006). Gait and balance impairment in early multiple sclerosis in the absence of clinical disability. *Multiple sclerosis (Houndmills, Basingstoke, England)*, 12(5), 620–628. <https://doi.org/10.1177/1352458506070658>
- [9] Morel, E., Allali, G., Laidet, M., Assal, F., Lalive, P. H., & Armand, S. (2017). Gait Profile Score in multiple sclerosis patients with low disability. *Gait & posture*, 51, 169–173.
- [10] Morel, E., Allali, G., Laidet, M., Assal, F., Lalive, P. H., & Armand, S. (2017). Gait Profile Score in multiple sclerosis patients with low disability. *Gait & posture*, 51, 169–173. <https://doi.org/10.1016/j.gaitpost.2016.10.013>
- [11] DeLisa, J. A. (Ed.). (1998). *Gait analysis in the science of rehabilitation (Vol. 2)*. Diane Publishing.
- [12] LeMoyné, R., Heerinckx, F., Aranca, T., De Jager, R., Zesiewicz, T., & Saal, H. J. (2016, June). Wearable body and wireless inertial sensors for machine learning classification of gait for people with Friedreich's ataxia. In 2016 IEEE 13th International Conference on Wearable and Implantable Body Sensor Networks (BSN) (pp. 147–151). IEEE.
- [13] Phan, D., Nguyen, N., Pathirana, P. N., Horne, M., Power, L., & Szmulewicz, D. (2019). A random forest approach for quantifying gait ataxia with truncal and peripheral measurements using multiple wearable sensors. *IEEE Sensors Journal*, 20(2), 723–734.
- [14] Prochazka, A., Dostal, O., Cejnar, P., Mohamed, H. I., Pavelek, Z., Valis, M., & Vysata, O. (2021). Deep Learning for Accelerometric Data Assessment and Ataxic Gait Monitoring. *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*, 29, 360–367. <https://doi.org/10.1109/TNSRE.2021.3051093>
- [15] Ilg, W., Seemann, J., Giese, M., Traschütz, A., Schöls, L., Timmann, D., & Synofzik, M. (2020). Real-life gait assessment in degenerative cerebellar ataxia: Toward ecologically valid biomarkers. *Neurology*, 95(9), e1199–e1210. <https://doi.org/10.1212/WNL.00000000000010176>
- [16] Marquer, A., Barbieri, G., & Pérennou, D. (2014). The assessment and treatment of postural disorders in cerebellar ataxia: a systematic review. *Annals of physical and rehabilitation medicine*, 57(2), 67–78. <https://doi.org/10.1016/j.rehab.2014.01.002>
- [17] Duysak, H., Ozkaya, U., & Yigit, E. (2021). Determination of the Amount of Grain in Silos with Deep Learning Methods Based on Radar Spectrogram Data. *IEEE Transactions on Instrumentation and Measurement*. doi: 10.1109/TIM.2021.3085939
- [18] Mateen, M., Wen, J., Song, S., & Huang, Z. (2019). Fundus image classification using VGG-19 architecture with PCA and SVD. *Symmetry*, 11(1), 1.
- [19] Zagoruyko, S., & Komodakis, N. (2016). Wide residual networks. arXiv preprint arXiv:1605.07146.
- [20] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. arXiv preprint arXiv:1704.04861.
- [21] Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 8697–8710).
- [22] Vapnik, V. (1998). The support vector method of function estimation. In *Nonlinear modeling* (pp. 55–85). Springer, Boston, MA.
- [23] He, C., Ma, M., & Wang, P. (2020). Extract interpretability-accuracy balanced rules from artificial neural networks: a review. *Neurocomputing*, 387, 346–358.