



TÜRKİYE CUMHURİYETİ
MARMARA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

**KONVOLUSYONEL YAPAY SİNİR AĞLARI KULLANARAK
ATALETSEL ÖLÇÜM BİRİMİ TABANLI HAREKET ANALİZİNDE
VERİ ÇOĞALTMA**

EMRAH MURAT TEKELİ

YÜKSEK LİSANS TEZİ

BEDEN EĞİTİMİ VE SPOR ANABİLİM DALI
SPORDA BİLİŞİM TEKNOLOJİLERİ YÜKSEK LİSANS PROGRAMI

DANIŞMAN

Prof. Dr. HALDUN AKPINAR

2021-İSTANBUL



TÜRKİYE CUMHURİYETİ
MARMARA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

**KONVOLUSYONEL YAPAY SİNİR AĞLARI KULLANARAK
ATALETSEL ÖLÇÜM BİRİMİ TABANLI HAREKET ANALİZİNDE
VERİ ÇOĞALTMA**

EMRAH MURAT TEKELİ

YÜKSEK LİSANS TEZİ

BEDEN EĞİTİMİ VE SPOR ANABİLİM DALI
SPORDA BİLİŞİM TEKNOLOJİLERİ YÜKSEK LİSANS PROGRAMI

DANIŞMAN

Prof. Dr. HALDUN AKPINAR

2021-İSTANBUL

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün safhalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışması ile elde edilmemiş bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığı beyan ederim.

Emrah Murat TEKELİ

TEŞEKKÜR

Bu yüksek lisans tez çalışmasının tamamlanmasında bilgi, deneyim ve tecrübesini hiçbir zaman esirgemeyen ve takıldığım her noktada beni yalnız bırakmayarak zorlukları aşmamı sağlayan hocam ve danışmanım sayın Prof. Dr. Haldun AKPINAR'a saygı ve teşekkürlerimi sunarım. Tanıştığımız günden beri desteğini ve sevgisini benden esirgemeyen kıymetli eşim Dr. Elif Sibel ATIŞ TEKELİ'ye, yaşamımın her anında bana ilham veren rahmetli babam Oğuz Günyıl TEKELİ ve annem Pınar TEKELİ'ye, ayrıca evimizin neşe kaynağı olan, yaşamın değerini ve hayatın anlamını bana hatırlatan oğlum Mert Can TEKELİ'ye tüm içten duygularım ile teşekkürlerimi sunarım.

İÇİNDEKİLER

BEYAN.....	i
TEŞEKKÜR	ii
ŞEKİL LİSTESİ.....	iv
TABLO LİSTESİ	v
1. ÖZET.....	1
2. SUMMARY	2
3. GİRİŞ VE AMAÇ	3
4. GENEL BİLGİLER.....	7
4.1. Ataletsel Sensörler – Ataletsel Ölçüm Birimleri.....	7
4.2. Ataletsel Ölçüm Birimlerinden Elde Edilen Veri	9
4.3. Zaman Serileri.....	12
4.4. Derin Öğrenme.....	13
4.4.1. Konvolusyonel yapay sinir ağları	15
4.4.2. Konvolusyonel yapay sinir ağlarının ortaya çıkışı.....	16
4.4.3. Konvolusyonel yapay sinir ağları mimarisi ve çalışma prensibi	16
4.5. Veri Çoğaltma	20
4.5.1. Zaman serilerinde veri çoğaltmada temel yaklaşımlar.....	22
4.5.2. Zaman serilerinde veri çoğaltmada ileri yaklaşımlar	27
5. GEREÇ VE YÖNTEM.....	29
5.1. Yazılım ve Donanım	29
5.2. Veri Tabanı.....	29
5.3. Yürüme ve Koşma Verilerinin Görselleştirilmesi.....	34
5.4. Yürüme ve Koşma Verilerinin Çoğaltılması.....	35
6. BULGULAR.....	37
7. TARTIŞMA VE SONUÇ.....	52
8. KAYNAKLAR	54
ÖZGEÇMİŞ.....	Hata! Yer işareti tanımlanmamış.

ŞEKİL LİSTESİ

Şekil 1. IMU Örnekleri

Şekil 2. Leomo marka ataletsel ölçüm birimi

Şekil 3. Üç eksen üzerinde toplanan ivmelenme verisine ait ekran görüntüsü

Şekil 4. IMU ivmelenme grafiği

Şekil 5. Yıllar içerisinde sibernetikten derin öğrenmeye geçiş basamakları

Şekil 6. Temel yapay sinir ağı mimarisi

Şekil 7. Konvolusyonel yapay sinir ağı mimarisi

Şekil 8. Girdi matrisi, filtre matrisi ve matris özellik haritası örneği

Şekil 9. Maksimum havuzlama ve ortalama havuzlama örneği

Şekil 10. Zaman serilerinde veri çoğaltma taksonomisi

Şekil 11. Sensörlerin alt ekstremitedeki yerleşimleri

Şekil 12. HuGaDB: Sensör lokasyonları

Şekil 13. HuGaDB katılımcı dağılımı

Şekil 14. 16 katılımcıya ait yürüme verilerinin ivmelenme değerlerinin grafiksel gösterimi

Şekil 15. 16 katılımcıya ait yürüme verilerinin jiroskop değerlerinin grafiksel gösterimi

Şekil 16. 4 katılımcıya ait koşma verilerinin ivme değerlerinin grafiksel gösterimi

Şekil 17. 4 katılımcıya ait koşma verilerinin jiroskop değerlerinin grafiksel gösterimi

Şekil 18. Sıra dışı değerlerin görsel olarak tespit edilmesi

Şekil 19. 3 nolu katılımcının yürüme aktivitesi ve koşma aktivitesi esnasında sol ayak üzerinde kaydedilen ivme ölçer değerleri üzerinden analizi

Şekil 20. Orijinal sinyal (sol), dalga bozulumu uygulanmış sinyal (sağ)

Şekil 21. Orijinal sinyal (sol), ölçeklendirme tekniği uygulanmış sinyal (sağ)

Şekil 22. Orijinal sinyal (sol), rotasyon tekniği uygulanmış sinyal (sağ)

Şekil 23. Orijinal sinyal (sol), permutasyon tekniği uygulanmış sinyal (sağ)

Şekil 24. Orijinal sinyal (sol), kırpma tekniği uygulanmış sinyal (sağ)

Şekil 25. Orijinal sinyal (sol), rotasyon ve ölçeklendirme uygulanmış sinyal (sağ)

Şekil 26. Orijinal sinyal (sol), ölçeklendirme ve dalga bozulumu uygulanmış sinyal (sağ)

Şekil 27. Orijinal sinyal (sol), ölçeklendirme ve permutasyon uygulanmış sinyal (sağ)

Şekil 28. Orijinal sinyal (sol) ve permutasyon ve kırpma uygulanmış sinyal (sağ)

TABLO LİSTESİ

Tablo 1. HuGaDB: Fiziksel aktivite tablosu

Tablo 2. Katılımcıların, kilo, boy, yaş ve cinsiyet tablosu

Tablo 3. Veri çoğaltma teknikleri tablosu

Tablo 4. CNN model parametreleri

Tablo 5. Veri tabanlarından elde edilen doğruluk (*accuracy*) oranları



1. ÖZET

Konvolusyonel yapay sinir ağları kullanarak ataletsel ölçüm birimi tabanlı hareket analizinde veri çoğaltma

Öğrenci Adı: Emrah Murat TEKELİ

Danışman Adı: Prof. Dr. Haldun AKPINAR

Anabilim Dalı: Beden Eğitimi ve Spor

Amaç: Hareket analizinde kullanılan ataletsel ölçüm birimleri, üç boyutlu lineer ivmelenme ve açısal hızlarını dolaylı yoldan ölçmektedir. Veri çoğaltma, eldeki sınırlı mevcut verilerin dönüştürülerek yeni verilerin oluşturulması işlemidir. Bu çalışmada, çeşitli veri çoğaltma teknikleri kullanılarak veri çoğaltma işlemi gerçekleştirilmiş ve tekniklerin hareket analizinde uygulanabilirliği araştırılmıştır.

Gereç ve yöntem: Çalışmaya, HugaDB veri tabanında bulunan koşma ve yürüme aktivitelerine ait ataletsel ölçüm birimi sinyalleri dâhil edilmiştir. Matlab® kullanılarak dalga bozulumu, ölçeklendirme, rotasyon, permutasyon, genlik çarpıtma, kırpma, ölçeklendirme ve dalga bozulumu, ölçeklendirme ve permutasyon, permutasyon ve kırpma teknikleri veri tabanındaki koşma ve yürüme sinyallerine uygulanmış ve konvolusyonel sinir ağı üzerinden sonuçlar değerlendirilmiştir.

Bulgular: Bu çalışma sayesinde, koşma verisine ait 12 ölçüm 1104 ölçüme; yürüme verisine ait 87 ölçüm 8004 ölçüme çoğaltılmıştır. HugaDB veri tabanında koşma ve yürüme aktiviteleri %97,978 (+/-0,003) doğruluk oranı ile ölçülmüştür. Ölçeklendirme tekniği ile elde edilen türev veri tabanının doğruluk oranının (%98,790), HugaDB veri tabanından (%97,978) daha yüksek olduğu ölçümlenmiştir. En düşük doğruluk oranı dalga bozulumu tekniği (%95,760) uygulanmış türev veri tabanında elde edilmiştir.

Sonuç: Konvolusyonel sinir ağı kullanılarak gerçekleştirilen hareket analizinde veri tabanını çoğaltmak için ölçeklendirme, kırpma, permutasyon ve dalga bozulumu gibi farklı teknikler bir arada veya ayrı olarak uygulanabilir. Ölçeklendirme ve kırpma teknikleri literatürde belirtilenin aksine daha düşük bir doğruluk oranı sağlamaktadır. Konvolusyonel sinir ağı modelleri kullanılarak veri analizinde veri çoğaltma modelleri amaca ve ihtiyaca uygun olarak denenerek tespit edilmesi önem arz etmektedir.

Anahtar kelimeler: Veri çoğaltma, hareket analizi, konvolusyonel sinir ağları

2. SUMMARY

Data augmentation in motion analysis based on inertial measurement units by using convolutional neural networks

Student Name: Emrah Murat TEKELİ

Name of Supervisor: Prof. Dr. Haldun AKPINAR

Department: Physical Education and Sports

Objective: Relatively low-cost inertial measurement units are used to measure articular kinematics. The purpose of this study is to develop a database, which size is suitable to apply in convolutional neural networks (CNN) by applying various data augmentation techniques.

Material and methods: The signals are the part of HuGaDB database. Wave distortion (jittering), scaling, rotation, permutation, magnitude warping, cropping, scaling and jittering, scaling and permutation, permutation and cropping techniques were applied to running and walking signals by using Matlab® and the results were evaluated over convolutional neural network.

Results: In this study, 12 measurements of running data and 87 measurements of walking data were augmented to 1104 and 8004 measurements respectively. The CNN model was measured to be able to detect running and walking activities in the HuGaDB database with an accuracy rate of 97.978% (+/- 0.003). For scaling technique, the accuracy rate (98.790%) of the derivative database obtained with the CNN model was measured higher than the original database (97.978%). The lowest accuracy rate was obtained in the derivative database where the jittering technique (95.760%) was applied.

Conclusion: Different techniques such as scaling, cropping, permutation and jittering can be applied together or separately to reproduce the database in motion analysis. Scaling and cropping techniques were found to have a lower accuracy rate than stated in the literature. It is important to determine data replication models in data analysis using CNN models by testing them in accordance with the purpose and needs.

Keywords: Data augmentation, gait analysis, convolutional neural network

3. GİRİŞ VE AMAÇ

Hareket analizi insan mekaniğinin değerlendirilmesinde kullanılan önemli bir tekniktir. Hareket analizinde milisaniyeler içinde değişen hareketleri tespit etmek için yüksek hızlı kameralar, kuvvet platformları ve elektromiyografi gibi teknolojilerden faydalanılır (Dönmez ve ark., 2014). Hız ve ivmeyi ölçmek için kullanılan cihazlara ataletsel ölçüm birimi (*inertial measurement unit - IMU*) denmektedir.

Birçok hareket analizi sisteminde katılımcının hareketlerini algılamak için kinematik bir veri toplama sistemi bulunmaktadır. Veri toplama sistemlerinin büyük bir kısmı, belirlenmiş bazı kural ve protokollere göre deneklerin üzerine yerleştirilmiş bulunan işaretleyicilerin (*markers*) yerlerinin, kameralar yardımı ile 3 boyutlu olarak bulunması ilkesine göre çalışır. Kameralar deneye başlanmadan önce, 3 boyutlu uzayda koordinatları önceden bilinen sabit işaretleyiciler kullanılarak (statik kalibrasyon) veya bir cisim üzerine yerleştirilmiş ve birbirlerine göre konumları önceden bilinen birkaç işaretleyici, deneyin gerçekleştiği bölge içerisinde hareket ettirilerek (dinamik kalibrasyon) kalibre edilir (Tönük, 2014).

Kinematik veri ölçümünde ataletsel ölçüm birimlerinin kullanılması, kameraya olan gerekliliği ortadan kaldırmaktadır (Vienne ve ark., 2017). Ataletsel ölçüm birimlerinden elde edilen veriler 3 boyutlu uzayda cismin koordinatlarını içermediği için, eklem kinematiğini dolaylı yoldan ölçmektedir. Bu sebeple ataletsel ölçüm birimleri ile elde edilen sonuçlar, altın standart olarak kabul edilen optoelektronik sistemlerle her zaman mukayese edilebilecek düzeyde olmamaktadır (Ngoh ve ark., 2018; Kumar ve Minz, 2014). Ataletsel verilerin mevcut optoelektronik veriden simule edilerek geçerliliğinin geliştirildiği çalışmalar literatürde bulunmaktadır (Tamura, 2014; Palermo ve ark., 2014; Kherif ve Latypova, 2020).

Ayrıca makine öğreniminin bir dalı olan yapay sinir ağları kullanılarak insan vücudunun simule edildiği modeller de geliştirilmiştir (Lapham ve Bartlett, 2008; Prakash ve ark., 2018). Uygulaması kolay olmayan bir süreç olan makine öğrenimi, bir sistemin programlanması yerine, verilerden öğrenilmesini sağlayan bir yapay zekâ

türüdür. Algoritmalar eğitim verilerini (*training data*) aldığıında, bu verilere dayalı daha ayrıntılı modeller oluşturulabilir. Özellikle son yıllarda, makine öğrenimi alanında önem kazanan bir yaklaşım derin öğrenmedir (*deep learning*). Derin öğrenmede, birçok katman kullanılarak, öznitelik (*attribute*) çıkarma ve dönüştürme işlemleri gerçekleştirilir. Bir katmandan elde edilen çıktı diğer katmanın girdisini oluşturur. Derin öğrenme, temel olarak denetimli öğrenme (*supervised learning*) ve denetimsiz öğrenme (*unsupervised learning*) olmak üzere ikiye ayrılır (Deng ve Yu, 2014). Son yıllarda, birçok yazar tarafından pekiştirmeli öğrenme (*reinforcement learning*) üçüncü bir dal olarak önerilmektedir (Wiering ve Otterlo, 2012; Sutton ve Barto, 2018). Derin öğrenme, konvolusyonel sinir ağları (*convolutional neural networks - CNN*), yinelemeli / tekrarlayan sinir ağları (*recurrent neural network - RNN*), uzun kısa vadeli bellek ağları (*long short term memory - LSTM*) gibi farklı mimarilerden oluşmaktadır. Konvolusyonel sinir ağları, biyomedikal alanında, doğal dil işleme alanında, ses ve görüntü işleme alanında uygulanmaktadır (Akpınar, 2018). Derin öğrenme tekniklerinde veri kümesinin boyutu sonuç üzerinde oldukça etkilidir. Küçük veri kümeleri derin öğrenme teknikleri için elverişli değildir. Böyle bir durumda, veri çoğaltma teknikleri, öğrenme aktarımı veya destek vektör makineleri kullanılabilir (Krizhevsky ve ark., 2012).

Son yıllarda konvolusyonel sinir ağları büyük boyutta etiketlenmiş veri kümelerinin sınıflandırılmasında oldukça başarılıdır. Ancak her zaman büyük boyutta veriyi toplamak ve etiketlemek kolay değildir. Sonuç olarak konvolusyonel sinir ağlarında küçük boyuttaki verileri kullanmak zor ve meşakkatlidir.

Veri çoğaltma (*data augmentation*), toplanabilen az sayıdaki veriden hareketle etkin veri analizlerini gerçekleştirebilmek amacıyla, verinin çoğaltılması için yapılan işlemler bütünüdür. Veri çoğaltmadaki temel amaç analiz edilen modeli yeterli miktarda veri ile destekleyerek daha isabetli tahminler yapmasını sağlamaktır. Özellikle derin öğrenme modellerini eğitmek için oldukça fazla miktarda veriye ihtiyaç duyulmaktadır. Bu nedenle veri aktarma tekniklerini kullanarak hali hazırda bulunan verilerden kopya veriler türetilerek ihtiyaç duyulan hacimdeki veriye ulaşılır.

Veri çoğaltma, verinin türüne bağılı olarak farklı şekillerde gerçekleştirilebilir. Örneğin veri türü,

- Görüntü (*image*) ise döndürme (*rotation*), öteleme (*translation*), kırpm (cropping), soldurma (*discoloration*), ölçeklendirme (*scaling*);
- Ses ise frekans maskeleme (*frequency filtering*), ölçeklendirme;
- Kelime ise eş anlamlısıyla değıştirme, rastgele kelime ekleme veya çıkarma

gibi çeşitli teknikler uygulanarak sentetik olarak işlenmiş yeni veri kopyaları oluşturulmaktadır. Bu sentetik kopyaların üretimi yapay zekâ uygulamalarında mevcut öğrenme verisine eklenerek amaçlanan veri büyüklüğüne ulaşılncaya kadar devam edilir. Diğ (er bir ifade ile, mevcut veri üzerinde veri çoğaltma, oluşturulmak istenen modeli yeterince veri ile destekleyerek sistemin daha isabetli tahminler yapmasını sağlamaktır. Bir veri kümesindeki ortak özellikleri tespit edebilmek amacıyla yapılan her ç (aba sistemin yüksek doğrulukla, diğ (er ifade ile sağlıklı ve istikrarlı çalışmasına hizmet eder. Bu nedenle küçük veri kümeleri, modellerin veriyi doğru bir şekilde modelleyememesine neden olmakta ve gerçek hayat problemlerinde düşük doğruluk (*low accuracy*), başka bir ifade ile ezberlemesi (*over fitting*) sonucunu doğ (urur.

Hareket analizinde gerçekleştirilen veri çoğaltma işleminde çeşitli zorluklarla karşılaşılmaktadır. Karşılaşılan zorluklardan biri yer bildirim etiketlerinde olmaktadır. Veri çoğaltma teknikleri uygulandığında yer bildirimlerinde hatalar oluşabilmekte ve çoğaltılan veri haritada göstermesi gerekenden çok daha farklı bir noktayı işaret edebilmektedir. Bununla birlikte, giyilebilir sensör verisinde olduğı gibi, eğer veri koşma, yürüme, zıplama gibi etiketler içeriyorsa, veri üzerinden çoğaltma işlemleri gerçekleştirildiğinde elde edilen yeni verinin etiketleri değıştirmedięine dikkat edilmelidir. Örneğin, yürümeye ait hız verisinin ölçeklendirilmesi hareket yoğunluğunu farklılaştırarak veri etiketinin koşma olarak değıerlendirilmesine neden olabilir. (Um ve ark., 2017)

Bu çalışmanın amacı, çeşitli veri çoğaltma tekniklerini küçük boyuttaki ataletsel ölçüm birimleri verisine uygulayarak veri çoğaltma işleminin gerçekleştirilmesidir. Bu sayede konvolusyonel sinir ağı üzerinden sınıflama performansının etkinliğinin değıerlendirilmesinde kullanılabilecektir. Uygulanacak teknikleri, kullanılacak yapay

sinir ağı modeli ve elde edilmesi hedeflenen sonuçlar doğrultusunda spor bilimleri alanında ülkemizde özgün bir çalışma olacaktır. Bu çalışma ile hareket analizinde veri çoğaltma teknikleri ile küçük boyuttaki veriler artırılarak daha büyük boyuta çıkarılacak ve elde edilen verinin yapay sinir ağı modellerinde uygulanabilirliği araştırılacaktır.



4. GENEL BİLGİLER

4.1. Ataletsel Sensörler – Ataletsel Ölçüm Birimleri

Newton'un birinci yasasına göre bir cismin üzerine etki eden tüm kuvvetlerin vektörel toplamı sıfır ise, bu cisim mevcut durumunu korur diğer bir deyişle bu cisim durmakta ise durmaya, sabit hızla hareket ediyorsa aynı yönde ve hızda hareketine devam eder. Newton'un birinci yasasında bahsettiği olgu atalet (eylemsizlik) olarak adlandırılmaktadır (<https://bit.ly/2MO0f3G>, Erişim Tarihi: 09.02.2021). Ataleti ölçmek için ataletsel ölçüm birimleri diğer bir adıyla ataletsel sensörler kullanılmaktadır.

Ataletsel sensör (*inertial sensor*) terimi lineer ivmelenme sensörleri ve açısal hız sensörlerini içeren geniş bir sensör ailesini ifade etmektedir. Bu sensörler, kendi hareketlerini ve dolayısıyla bağlı oldukları nesnelerin hareketlerini ataletsel prensipleri kullanarak ölçümler. İvmelenme, üzerinde sensör bulunan serbest bir kütlenin hareketine karşı oluşan dirençle ilişkilidir. Diğer bir ifade ile dışarıdan uygulanan bir güç veya tork etkisiyle ivmelenme gerçekleşir. İvmeölçer ve jiroskop sırasıyla doğrusal ivme ve açısal hızı duyarlı olduğu ekseninde ölçer. Teknolojinin hızla ilerlemesi ve elektronik devrelerin küçülmesi sayesinde artık bu sensörler çok ufak ölçülerde üretilmektedir.

Ataletsel ölçüm birimi (AÖB) (*inertial measurement unit, IMU*), üç ortogonal jiroskobun ve üç ortogonal ivmeölçerin birleşiminden oluşmakta, bazılarında ayrıca manyetometre de bulunabilmektedir. Şekil 1'de farklı ticari markalarda ve jenerik ataletsel ölçüm birimlerinden örnekler paylaşılmıştır. İçlerinde EPSON MARKA (10 x 12 x 4 mm boyutlarında olup sadece 1 gr ağırlığında) ticari olarak sunulan, dünyanın en küçük ve en hafif ataletsel ölçüm birimlerinden biri de mevcuttur. Şekil 1'deki resimlerden de anlaşılabileceği üzere oldukça küçük boyutlarda ve hafiflikte üretilen bu cihazlar saniyede yüzlerce ölçüm alabilmektedir.

Ticari olarak temin edilebilen ataletsel ölçüm birimleri, üç boyutta doğrusal ivmelenmeyi ve açısal hızı sensör-gömülü sistemleri küçük, hafif, kablosuz iletişime uygun ve hareketi engellemeyecek şekilde vücudun uzuvlarına takılabilecek şekilde üretilmektedir. Uygulama alanlarına göre değişmekle beraber, bu cihazlarda gömülü bluetooth/ wireless transmitterler, veri depolama amaçlı SD kartlar bulunabilmektedir.

Deneylerde vücudun tek bir uzvuna takılı bir ataletsel ölçüm birimi kullanılabileceği gibi, vücudun birden fazla uzvuna birden fazla da takılabilir. Birden fazla kullanılan bu gibi durumlarda verinin zamana bağlı senkronizasyonu gerekmektedir. Ancak ticari bazı cihazlarda birden fazla ataletsel ölçüm biriminden elde edilen verinin senkronizasyonu dahili olarak gerçekleştirilebilmektedir.

Ataletsel ölçüm birimlerinin, yukarıda paylaşılan teknolojik ve uygulama avantajlarının yanında, kendilerine has bazı dezavantajları ve kullanım sınırlamaları da bulunmaktadır. Örneğin, bir ataletsel ölçüm biriminin temel dezavantajı, sürüklenme (*drift*) olarak da bilinen ve zaman içinde kümülatif olarak biriken ölçüm hatasına yatkın olmasıdır. Cihazın referans çerçevesi kendisi olduğu için ölçümler her zaman kendisine göre değişiklikleri ölçer. Ataletsel ölçüm birimleri hesaplamalarında zamanla biriken küçük kesirleri sürekli olarak yuvarlar. Bu hatalar düzeltilmeden bırakıldığında, bu küçük belirsizlikler belirgin (*significant*) hatalara yol açabilir (<https://bit.ly/3o89dWo>, 29.11.2020). Bu durum özellikle hava taşımacılığı ve savunma sanayinde belirgin bir risk oluşturur.



Şekil 1. IMU Örnekleri a) EPSON markalı dünyanın en küçük ve en hafif Ataletsel Ölçüm Birimi (IMU) (<https://bit.ly/2ZJPeUS>, Erişim tarihi: 14.01.2021), b) Memsense markalı AÖB (<https://www.memsense.com/products/ms-imu3020>, Erişim Tarihi: 14.01.2021) c) Technaid markalı Tech-IMU V4 model AÖB (<https://www.technaid.com/products/inertial-measurement-unit-tech-imu-biomechanichs/>, Erişim Tarihi: 14.01.2021) , ç) Microstrain markalı AÖB (<https://www.microstrain.com/inertial/3dm-gx4-15>, Erişim Tarihi: 14.01.2021), d) Leomo markalı AÖB (<https://www.leomo.io/products/type-r-motion-sensor>, Erişim Tarihi: 14.01.2021), e) Pololu markalı CHR-6d model AÖB (<https://www.pololu.com/product/1263/resources>, Erişim Tarihi: 14.01.2021)

4.2. Ataletsel Ölçüm Birimlerinden Elde Edilen Veri


Ataletsel ölçüm birimlerinden elde edilen verinin doğru bir şekilde yorumlanması önem arz etmektedir. Bu nedenle Leomo marka ataletsel ölçüm birimi üzerinden tüm benzer sistemlerin çalışma mekanizması, ölçümlerin nasıl alındığı ve ölçüm değerlerinin nasıl yorumlandığı ve bu kısımda açıklanmıştır. Daha önce de ifade edildiği üzere, ataletsel ölçüm birimleri üzerinde temelde 3 adet ivme ölçer, 3 adet jiroskop ve bazı modellerde zorunlu olmamakla birlikte manyetometre de içeren mikro elektro mekanik sistemler (*microelectronic systems*, *MEMS*) bulunmaktadır (Fischer ve ark., 2015). İvme ve açısal hız değerlerindeki değişiklikler x, y, z eksenleri üzerinden üç boyutlu olarak ölçümlenmekte ve genellikle ölçümlenen veri başka bir cihaza (bilgisayar veya veri depolama alanına) *bluetooth* üzerinden aktarılmaktadır. Saniyede yüzlerce ölçüm yapabilen ataletsel ölçüm birimleri hakkında dikkat edilmesi

gereken en önemli nokta pozisyonlardaki değişimi lokal referans noktalarına göre ölçmesidir. Diğer bir deyişle ölçümler kesin bir referans noktasına bağlı olarak gerçekleşmediği için koordinat sistemde gösterilen veri global referans çerçevesine göre değişmemektedir. Dolayısıyla tek başına ataletsel ölçüm birimlerinden elde edilen ivme ve açısal hız değerlerinden yola çıkarak ölçümü yapılan nesnenin konum zaman grafiği doğrudan elde edilememektedir. Konum zaman grafiği elde edebilmek için yardımcı başka cihazların veya parametrelerin bilinmesine ihtiyaç duyulmaktadır. Elbette bu durum ataletsel ölçüm cihazlarının önemini ve faydalarını azaltmamaktadır.


Şekil 2’de Leomo marka ataletsel ölçüm cihazı 3 boyutlu uzayda orijin merkezinde olacak şekilde gösterilmektedir. Cihazın kendi referans çerçevesi üzerinde değişken hızlarda hareket ettirilmesi veya kendi eksenini etrafında döndürülmesiyle göreceli ölçümler alınmaktadır.

Şekil 3’te sırasıyla x ekseninde hareket ettirilen, daha sonra belirli bir süre y ekseninde hareket ettirilen ve yine ardından bir süre beklenerek z ekseninde hareket ettirilen ataletsel ölçüm biriminin ölçüm değerleri gösterilmiştir. Grafiklerden de anlaşılaacağı üzere ivmeölçer değerleri pozitif ve negatif değerler alabilmektedir.


Bir IMU tek bir eksen üzerinde eylemsiz dururken x_0 noktasından $+x$ yönünde x_1 noktasına hareket ettirildiğinde şekil 4a’daki gibi bir ivmelenme grafiği elde edilmektedir. Grafikten de anlaşıldığı üzere IMU öncelikle pozitif ivmelenme değeri almış daha sonra IMU yavaşlamaya geçerek negatif bir ivmelenme değeri elde edilmiştir. Ölçüm eksenini sıfır değerinde kestiği nokta ise ataletsel ölçüm biriminin sabit hızlı hareket ettiği, dolayısıyla ivmelenmenin sıfır olduğu değerdir.



Şekil 2. Leomo marka ataletsel ölçüm birimi (<https://www.leomo.io/products/type-r-motion-sensor> , Erişim Tarihi: 14.01.2021)



Şekil 3. Üç eksen üzerinde toplanan ivmelenme verisine ait ekran görüntüsü (<https://www.youtube.com/watch?v=MAR4yvxQpzc>, Erişim Tarihi: 14.01.2021)



Şekil 4. IMU ivmelenme grafiği: a) IMU'nun +x yönünde ivme grafiği (sol) b) IMU'nun -x yönünde hareket grafiği (sağ) (<https://www.youtube.com/watch?v=MAR4yvxQpzc>, Erişim Tarihi: 14.01.2021)

Bir ataletsel ölçüm birimi tek bir eksen üzerinde eylemsiz dururken x_1 noktasından $-x$ yönünde x_0 noktasına hareket ettirildiğinde şekil 4b'deki gibi bir ivmelenme grafiği elde edilmektedir. Ataletsel ölçüm birimi yine önce hızlanıp sonra yavaşlayarak yer değiştirmesine rağmen, elde edilen grafiğin farklı olmasının nedeni, bu kez hareket yönünün $-x$ yönünde olmasından kaynaklanmaktadır. Ataletsel ölçüm biriminin ivmelenmesi pozitif olmasına rağmen, hareket yönü $-x$ ekseninde olduğu için sonuç negatif olmuştur. İvmenin yavaşladığı ve negatif değer aldığı süreçte ise hareket yönü $-x$ doğrultusunda olduğundan sonuç pozitif değer almıştır. Her iki grafikte de sıfır değerleri hız değişiminin sıfır olduğu, dolayısıyla ivmelenmenin sıfıra eşit olduğu noktalardır. Bu noktalarda cisim ya duruyor ya da sabit hızla hareket ediyor olabilir.

4.3. Zaman Serileri

Zaman serileri, bilimin birçok alanında uygulamaları bulunan bir yöntemdir. Spor bilimleri araştırmalarında ölçülen veriler ile biyomekanik, fizyolojik veya antropometrik parametreler arasında bir ilişkinin gösterimi mümkündür. Bu amaçla, analizi yapılacak modelde yer alacak değişkenlerle ilgili verilerin toplanması, derlenmesi ve düzenlenmesi gerekmektedir. Bir zaman serisi, ilgilenilen bir büyüklüğün zaman içerisinde sıralanmış ölçümlerinin bir kümesidir. Zaman serileri ile analiz yapılma amacı ise, gözlem kümesince temsil edilen gerçeğin anlaşılması ve zaman serisindeki değişkenlerin gelecekteki değerlerinin doğru bir şekilde tahmin edilmesidir (Allen, 1964).

Bir zaman serisi, belirli bir zaman sırasına göre indekslenmiş, grafiğe aktarılmış ya da listelenmiş bir dizi veri noktası olarak tanımlanabilir. Belirli bir zaman içinde birbirini takip eden eşit aralıklı noktalarda alınan bir dizi ifadesi de zaman serisinin en yaygın tanımlarından birisidir. Zaman serileri, kullanıldığı alanlar incelendiğinde başta istatistik, ekonometri, örüntü tanıma, hava tahmini, sinyal işleme, finans, deprem tahmini, kontrol mühendisliği, astronomi zamansal ölçümleri içeren uygulamalı bilim ve mühendisliğin gelmektedir. Somut örnekler vermek gerekirse denizde dalgaları yükseklikleri, güneşte oluşan lekelerin sayısı ve borsada günlük kapanış değerleri

zaman serisine verilebilecek örneklerden sadece bazılarıdır. (<https://bit.ly/3sCnnCu>, Erişim Tarihi: 17.01.2021).

Zaman serileri genel eğilim (trend), mevsim bileşeni, çevrimsel bileşen ve düzensiz bileşen olmak üzere dört bileşenden oluşmaktadır (Newbold, 2000).

1. Genel Eğilim (Trend) bileşeni; zaman serilerinin uzun bir zaman sürecinde gösterdiği azalma ve artma süreçlerinden sonra oluşan kararlı (istikrarlı) durumu temsil etmektedir.
2. Mevsim Bileşeni; Zaman serilerinde mevsimlere göre değişmeyi ifade etmektedir. Zaman serileri açısından kullanılan verilerin bazı dönemleri diğer dönemlere göre farklılık gösterebilir.
3. Çevrimsel Bileşen; Ekonomide, mevsimsel değişimler ile ilgili olmayan dönemsel değişimler olarak tanımlanmaktadır. Örneğin, ekonomide genel eğilimden bağımsız kısa vadeli (sürelî) genişleme ya da daralma durumlarında çevrimsel süreci tarif etmektedir.
4. Düzensiz Bileşen; Diğer unsurlar gibi belirli olmayan, hata terimi ile ifade edilebilecek değişimlerdir.


4.4. Derin Öğrenme

Makine öğrenmesi uygulaması kolay olmayan bir süreç olup, bir bilgisayar sisteminin açıkça programlanması yerine verilerden öğrenmesini sağlayan bir yapay zekâ türüdür. Amerikan bilgisayar bilimcisi Arthur Samuel tarafından 1959 yılında literatüre kazandırılmıştır (www.ibm.com/analytics/machine-learning, Erişim Tarihi:14.04.2020).

“Yapay zekâ ismi ile taçlandırılan araştırma çalışmaları, 60 yıllık süre içerisinde çok büyük alanda yapılan olağanüstü yatırımlara rağmen, sürekli olarak heyecanla başlanan ve uzun bir sürenin sonunda hüsrarla sonuçlanan projelerle anılmıştır. Ancak

her hüsrarla sonuçlanan proje, aradan on yıllar geçse de bir sonraki atılımın hasretle beklenen filizi olmuştur. Bununla birlikte başarısızlıkla biten dönemler, alaycı bir ifade ile yapay zekânın kışları (*AI winter*) olarak anılmıştır. 1990’lı yıllarda da makine öğreniminin büyük ölçüde sekteye uğraması ile yeni bir yapay zekâ kışının başladığı dönemdir.” (Akpınar, 2018)

“Özellikle 2010 yılından bu yana ise, yeni bir yapay zekâ ilkbaharı sürmekte ve bu dalga kısaca Derin Öğrenme (*deep learning*) olarak isimlendirilmektedir. Microsoft, Google, Facebook, IBM gibi büyük oyuncuların oyuna katılması, derin öğrenme algoritmalarının hızla gelişmesinde destekleyici rol oynamıştır.” (Akpınar, 2018)




Şekil 5. Yıllar İçerisinde Sibernetikten Derin Öğrenmeye Geçiş Basamakları (Akpınar,2018)

Derin Öğrenme (*deep learning*), yapay sinir ağlarını içeren makine öğrenmesinin bir alt sınıfıdır. World School Council London tarafından ilk defa uygulanmıştır (Akpınar, 2018). Derin öğrenmede, birçok katman kullanılarak, öznel çıkarma ve dönüştürme işlemleri gerçekleştirilir. Bir katmandan elde edilen çıktı diğer katmanın girdisini oluşturur. Bilindiği üzere, derin öğrenme, temelde denetimli öğrenme ve denetimsiz öğrenme olmak üzere iki gruba ayrılmaktadır (Deng ve Yu, 2014). Her iki grup derin öğrenme modelindeki sistemler öğrenebilen sistemlerdir. Derin öğrenme, konvolusyonel sinir ağları (*convolutional neural network, CNN*), tekrarlayan sinir

ağları (*recurrent neural network*, RNN), uzun kısa vadeli sinir ağları (*long short term memory*, LSTM) gibi farklı mimarilerden oluşmaktadır. Konvolusyonel sinir ağları, biyomedikal alanında, doğal dil işleme alanında, ses ve görüntü işleme alanında kullanılmaktadır (Akpınar,2018). Şekil 5’de 1940’larda Sibernetik ile başlayan ve günümüzde derin öğrenmeyle devam eden sürecin yapı taşları paylaşılmıştır.

4.4.1. Konvolusyonel yapay sinir ağları

Konvolusyonel yapay sinir ağları temel olarak girdi katmanı (*input layer*), gizli katman/katmanlar (*hidden layer*) ve çıktı katmanı (*output layer*) olmak üzere 3 bölümden oluşmaktadır. Girdi ve çıktı katmanı arasındaki birden fazla katman olabileceği için gizli katman birden fazla olabilir. Şekil 6’de temel bir yapay sinir ağı mimarisi gösterilmiştir. Girdi katmanı n farklı girdiden oluşmakta, çıktı katmanı ise olabilecek sonuçları içermektedir. Şekildeki daireler düğüm (*node*) olarak ifade edilen birimleri göstermektedir.




Şekil 6. Temel yapay sinir ağı mimarisi (Akpınar,2018)

4.4.2. Konvolusyonel yapay sinir ağlarının ortaya çıkışı

Konvolusyonel yapay sinir ağları (*Convnet / CNN*) temelde görüntü analizi gerçekleştirmek için tasarlanmış bir yapay sinir ağıdır (Akpınar, 2018). El yazısıyla yazılan numaraların sınıflandırılmasının geriye yayılım (*back propagation*) algoritması ve denetimli öğrenme kullanılarak gerçekleştirildiği ilk konvolusyonel sinir ağı çalışması 1989 yılında gerçekleştirilmiştir (LeCun ve ark., 1989). Biyolojik görme çalışmalarından esinlenerek geliştirilen konvolusyonel sinir ağları *de facto* olarak on yıllardır bilgisayarla görme (*computer vision*), doğal dil işleme (*natural language processing*) çalışmalarında verimli bir şekilde kullanılmaktadır. Günümüzde konvolusyonel yapay sinir ağlarının uygulandığı yeni alanlar halen keşfedilmektedir. Astrofizikten, genetiğe kadar birçok alanda konvolusyonel yapay sinir ağlarının başarıyla uygulandığı görülmektedir (Flagel ve ark., 2019; Petrillo ve ark. 2019).

4.4.3. Konvolusyonel yapay sinir ağları mimarisi ve çalışma prensibi

Girdi katmanı, konvolusyon katmanı, havuzlama (*pooling*) katmanı, düzleştirici katman, tam bağlantı katmanı ve çıktı katmanından oluşan konvolusyonel yapay sinir ağları, temelde görüntüleri sınıflandırmak, gruplandırmak ve benzerlikleri ortaya koymak amacıyla geliştirildiğinden, sistemin mimari yapısının açıklanmasında ve çalışma mantığı açıklanırken fotoğraf örneği üzerinden ilerlenmiştir. Şekil 7’de görüldüğü üzere girdi katmanındaki görsel en (1), boy (1) ve RGB (3) değerlerinden oluşmaktadır. Bu değerler sisteme birer matris olarak tanıtılmakta ve dolayısıyla diğer katmanlarda görsel üzerinden matematiksel işlemlerin yapılabilmesi sağlanmaktadır.



Şekil 7. Konvolusyonel yapay sinir ağı mimarisi (kendi çizimim)

Girdi katmanından sonra gelen konvolusyon katmanı, özelliklerin çıkartılarak filtrelerin oluşturulduğu bir katman olduğu için CNN'in en önemli katmanı olarak değerlendirilebilir. Filtre uygulama işlemi temel olarak bir matris çarpımıdır ve filtre matrise çevrilmiş olan girdi görüntüsü üzerinde adım adım kaydırılarak çarpma işlemi gerçekleştirilmektedir. Filtreler ihtiyaca yönelik olarak 2x2, 3x3, 5x5 vb. boyutlardan oluşabilmektedir. Elde edilen çarpım sonuçları matris özellik haritası olarak adlandırılan ayrı bir matriste saklanmaktadır. Örnek birer girdi matrisi ve filtre matrisi ile gerçekleştirilen çarpım işlemi ve bu işlem sonucunda oluşan matris özellik haritası şekil 8'de paylaşılmıştır.

1	0	1	0
1	1	0	1
0	1	1	0
1	0	1	1
0	1	0	1
1	0	0	0
1	1	1	0
0	1	1	1

9 x 5 MATRIS

1	0
0	1

2 x 2 FİLTRE

2	0	2
2	2	0
0	2	2
2	0	2
0	1	0
2	1	0
2	2	2

MATRİS ÖZELLİK HARİTASI


Şekil 8. Girdi matrisi, filtre matrisi ve matris özellik haritası örneği (kendi çizimim)

Elde edilen çarpım sonucunda oluşan matris bir sonraki gizli katmanın girdisini oluşturmaktadır. Yapay sinir ağını oluşturan düğümler arasında geçiş sağlanmadan önce aktivasyon fonksiyonları adı verilen matematiksel işlemler gerçekleşmektedir. Bu işlemler sayesinde üretilen çıktı değerleri üzerinde bazı değişiklikler elde edilebilmektedir. Örneğin sıklıkla kullanılan ve doğrultulmuş lineer birim (*rectified linear unit, ReLU*) fonksiyonu olarak adlandırılan aktivasyon fonksiyonu matris çarpımında elde edilen pozitif değerleri değiştirmeden kullanırken; negatif değerleri sıfıra dönüştürmektedir (Akpınar,2018).

Literatürde ikili adım fonksiyonu (*binary step function*), doğrusal aktivasyon fonksiyonu (*linear activation function*) ve doğrusal olmayan aktivasyon fonksiyonu (*non-linear activation function*) olmak üzere üç farklı türde aktivasyon fonksiyonları bulunmaktadır. Her bir aktivasyon fonksiyonunun kendine has avantajları ve dezavantajları bulunmaktadır. *Sigmoid / logistic, TanH / Hyperbolic Tangent, ReLU, Leaky ReLU, parametric ReLU, Softmax, Swish* yapay sinir ağlarında en çok kullanılan aktivasyon fonksiyonlarına örnek olarak gösterilebilir (<https://bit.ly/3cfX91h>, erişim tarihi: 01.03.2021). Bu nedenle ihtiyaca yönelik uygulanabilir en doğru çözüm için yapay sinir ağı modeli, donanım mimarisi, veri tabanı büyüklüğü gibi parametreler göz önüne alınarak karar verilmelidir.

Havuzlama katmanı, yapay sinir ağına aşırı öğrenmeye neden olmasını önlemek için kullanılmaktadır. Bunu gerçekleştirebilmek için ağ boyunca oluşan değişkenlerin ve dolayısıyla hesaplamaların azaltılması gerekmektedir. Bu amaç doğrultusunda maksimum havuzlama (*maximum pooling*) ve ortalama havuzlama (*average pooling*) olmak üzere iki farklı yöntem uygulanmaktadır.

Maksimum havuzlama yönteminde bir önceki basamakta yani konvolusyon basamağında elde edilen matris özellik haritası üzerinde kayan filtre geçirilmektedir. Her bir adımda filtre üzerindeki en büyük değer sonuç olarak kabul edilmekte ve dolayısıyla her adımda en büyük sayısal değer alınmaktadır. Ortalama havuzlama yönteminde ise filtre üzerinde karşılık gelen değerlerin aritmetik ortalaması alınmaktadır. Şekil 9’da bu olgu gösterilmektedir.



Şekil 9. Maksimum havuzlama ve ortalama havuzlama örneği (kendi çizimim)

Düzleştirme katmanı (*flattening layer*), konvolusyon ve havuzlama katmanlarından gelen matris olarak gelen veriyi tek boyutlu diziye çevirmek için kullanılmaktadır. Burada asıl hedeflenen amaç tam bağlantı katmanına uygun girdi şeklinin oluşturulmasıdır. Tam bağlantı katmanı (*fully connected layer*), düzleştirme işlemin gerçekleştirilmiş veriyi tüm nöronlarla bağlamaktadır. Bu katman içerisinde sınıflandırma işlemi gerçekleştirilir. *Softmax* aktivasyonu gibi fonksiyonlar kullanılarak olasılık dağılımı elde edilerek, konvolusyonel yapay sinir ağı modelinin tahmin etmeye çalıştığı sınıflandırma etiketlerine sıfır ile bir değeri arasında bir değer atar. Böylelikle çıktı katmanında en yüksek olasılık değerine sahip olan etiket modelin bulduğu sonucu oluşturur.

Yukarıda kısaca temel kavramlarına değinilmiş olan konvolusyonel yapay sinir ağları sadece görüntü işlemede değil, aynı zamanda zaman serilerinde ve hareket analizinde kullanılmaktadır (Yang ve ark., 2015; Zhao ve ark.,2017; Dehzangi ve ark.,2017; Alharthi ve ark.,2019).

Özetle, konvolusyonel yapay sinir ağları her ne kadar görsel veriyi işlemek ve bu veriden yola çıkarak günlük yaşamda karşılaşılan görsellerin sınıflandırılması nesnelerin yerinin tespiti ve görüntü yakalama gibi sorunları ele almak amacıyla geliştirilmiş olsa da günümüzde astrofizikten, genetik analize, hareket analizinden sağlık uygulamalarına kadar geniş bir alanda uygulama alanı bulmaktadır.

4.5. Veri oaltma

Son yıllarda birçok alanda uygulanan derin öğrenme, zaman serileri analizinde oldukça iyi sonuçlar vermektedir. Örneğın bilgisayarların görme (*vision*), doğal dil işleme (*natural language processing*), konuşma işleme (*speech processing*) gibi işlevleri derin öğrenmenin en başarılı olduėu alanlar arasında sayılabilir. Derin öğrenmede elde edilen bu başarılar, temel olarak yüksek miktardaki eğitim verisi sayesinde elde edilmektedir. Derin öğrenmede, modellerin ezberlemesini önlemek için oldukça fazla sayıda eğitim verisine ihtiyaç duyulmaktadır. Bazen sağlık ve spor alanında aranılan kriterlere uygun yeterli sayıda katılımcı bulmak neredeyse imkânsızdır. Büyük boyutlarda veriye ulaşabilmek hem maliyetli hem de zaman alan bir süreçtir. Dolayısıyla eğitim verilerinin kalitesini ve boyutunu artırmak için veri çoğaltma tekniklerinden faydalanılmaktadır.

Derin öğrenme tekniklerinde veri kümesinin boyutu elde edilen sonuç üzerinde oldukça etkilidir. Küçük veri kümeleri derin öğrenme teknikleri için elverişli değildir. Kaldı ki, denetimli derin öğrenme modellerinde başarı oranı sisteme tanımlanan verinin niteliğı ve niceliğı ile orantılı olarak değişmektedir (Krizhevsky ve ark., 2012). Dolayısıyla veri miktarı ve veri etiketlerinin niteliğı arttıkça görece daha zeki derin öğrenme modelleri oluşturulabilmektedir.

Günümüzde Google, Apple, Amazon gibi uluslararası şirketler olağanüstü miktarda zetabyte seviyelerini geçen ve büyük veri (*big data*) olarak isimlendirilen yüksek nitelikte veriye sahipler. Bu büyüklükteki etiketli veri kümelerinin sınıflandırılmasında, konvolusyonel sinir ağıları oldukça başarılıdır. Ancak, derin öğrenmeyle ilgilenen birçok araştırmacı ve ticari kuruluş, gerek sahip oldukları teknolojik altyapının yetersizliğı nedeniyle, gerekse büyük veriyi elinde tutan kurumların sınırlı erişim yetkisi vermesi ya da hiç erişim yetkisi vermemesi nedeniyle araştırmalarını daha küçük boyutlardaki veri ile çalışmak zorunda kalmaktadır.

Spor bilimlerinde yapılan bilimsel çalışmalarda, her zaman fazla sayıda denek üzerinden araştırma yapmak ve veri toplamak mümkün olmamaktadır. Küçük

boyutlardaki veri kullanılarak arařtırmalar yapılmaktadır. Dolayısıyla konvolusyonel sinir aęlarında küçük boyuttaki verileri kullanmak zor ve meřakkatlıdır. Kaldı ki, çok büyük boyutlarda veri toplansa bile, bu verinin etiketlenmesi de bařlı bařına bir iřtir ve bu iři tamamlamak dahi büyük bir alıřan kadrosunu ve uzunca bir zamanı gerektirdięinden kolay deęildir. Bu durum, özellikle derin öğrenme gibi yüksek veri kümelerine ihtiya duyan arařtırmaların gerekleřtirilmesinde engel teřkil etmektedir.

Yukarıda belirtilen nedenlerle daha küçük veri kümeleri kullanarak geliřtirilen derin öğrenme modellerinde birok engelle karřılařılmaktadır. Bu engellerden birisi de ezbere öğrenme problemidir. Ezbere öğrenme, makine öğreniminde sıklıkla karřılařan bir sorundur ve bu sorunu gidermek için erken durdurma (*early stopping*), düzenlileřtirme (*regularization*), gruptama (*ensemble*) gibi farklı teknikler geliřtirilmiřtir (Akpınar,2018). Ayrıca veri oęaltma yöntemi de küçük boyutlu verinin artırılmasında kullanılan bir bařka iřlemdir.

Veri oęaltma, eldeki sınırlı mevcut verilerin dönüřtürölerek yeni verilerin oluřturulması iřlemidir ve küçük boyutlu verinin derin öğrenmede kullanılması amacıyla uygulanmaktadır. Derin öğrenmede, elde yeterli büyüklükte veri yoksa, veri oęaltma tekniklerini kullanarak hali hazırdaki veri boyutundan daha büyük veri üretmek sürecin geneli göz önüne alındığında faydalı ve etkili bir iřlemdir (Lin ve ark., 2014). Veri oęaltma özellikle sınırlı sayıda eğitim örneęi (*training samples*) nedeniyle konvolusyonel sinir aęlarında karřılařılan ezbere öğrenme problemini özmek için etkili bir metottur. Veri olasılık uzayını yakınsamak için girdiler (*inputs*); yatay çevirme, rastgele kırpma/kesme, parazit ekleme, bilgi kaybı ve yönlendirme gibi tekniklerle manipöl edilir (Zheng ve ark., 2020).

Veri oęaltmada bazı zorluklarla da karřılařılmaktadır. Bu zorluklar oęunlukla etiketlerle ilgili olmaktadır. Örneęin, hızlanma verilerinin öleklendirilmesi etiketleri deęiřtirebilir, ünkü bazı etiketler hareket yoğunluęuna göre farklılařır (Um ve ark, 2017). Veri oęaltmada karřılařılan zorluklardan bir dięeri de yer bildirimi gerektiren doęru etiketi koruyan yeni verileri oluřturmaktır. Bununla birlikte, örneęin giyilebilir


sensör verilerinde olduğu gibi, etiket koruyucu çoğaltmanın nasıl gerçekleştirileceği literatürde açık değildir.

Veri çoğaltma, veri üzerinde önceden bilinen sabit özelliklerin dönüştürülmesi olarak görülebilir. Çoğaltılmış veri (*augmented data*), henüz keşfedilmemiş girdi uzayını kapsayabilir, ezbere öğrenmeyi önleyebilir, derin öğrenme modelinin genelleştirilmesini elverişli hale getirebilir (Goodfellow ve ark., 2016). Literatürde, görüntü tanımlamada (*image recognition*) kullanılan dalga bozulumu (*jittering*), ölçekleme (*scaling*), kaydırma (*warping*), kesme (*cropping*) ve rotasyon (*rotation*) tekniklerinin çok az bir değişikliğe neden olduğu ve veri etiketinde herhangi bir değişikliğe neden olmadığı belirtilmektedir. Ancak giyilebilir sensör verilerinde bu tekniklerin uygulanmasının ne tür sonuçlar doğurduğu henüz net bir şekilde ortaya konmamıştır. Örneğin ivmelenme verisinde ölçeklendirme tekniğinin uygulanması veri etiketlerini değiştirebilir (Um ve ark., 2017). Dolayısıyla giyilebilir sensör verilerinde veri çoğaltma tekniklerini uygulamadan önce, bu teknikleri iyi analiz etmek gerekmektedir.

4.5.1. Zaman serilerinde veri çoğaltmada temel yaklaşımlar

Zaman serilerinde veri çoğaltma, en basit ve temel tanımıyla etiketlerin doğruluğunun korunduğu sentetik bir veri kümesi oluşturmaktır. Literatürde görüntü işlemeye yönelik, örneğin AlexNet gibi, veri çoğaltmanın etkin olarak uygulandığı birçok başarılı uygulama vardır (Krizhevsky ve ark, 2012). Ancak görüntü işleme teknikleri ile karşılaştırıldığında, zaman serilerinde uygulanabilecek veri çoğaltma tekniklerini içeren çok fazla sayıda çalışmaya rastlanılmamaktadır. Elbette bunun bazı nedenleri vardır. Zaman serisi verilerinin karakteristik özellikleri nedeniyle, mevcut veri artırma yöntemleri tam olarak uygulanamamaktadır. Görüntü verilerinden farklı olarak, zaman serisi verileri zaman-frekans alanında (*domain*) dönüştürülebilir ve etkili bir veri çoğaltma metodu dönüştürülen alanda (*transformed domain*) tasarlanabilir ve uygulanabilir (Wen ve ark, 2020).

Literatürde Wen ve arkadaşları zaman serilerinde veri çoğaltmayı şekil 10’da belirtildiği üzere sınıflandırmışlardır. Şekil 10’ da görüldüğü üzere zaman serilerinde veri çoğaltma (*time series data augmentation*), temel yaklaşım (*basic approach*) ve ileri düzey yaklaşım (*advanced approach*) olmak üzere ikiye ayrılmaktadır. Temel yaklaşım kendi içerisinde zaman alanı (*time domain*), frekans alanı (*frequency domain*), zaman-frekans alanı (*time-frequency domain*) olmak üzere 3 farklı alt kategoriden oluşmaktadır.



Şekil 10. Zaman serilerinde veri çoğaltma taksonomisi (Wen ve ark., 2020)

Her bir kategoride kırpma (*cropping*), döndürme (*flipping*), dürme (*wrapping*) ve karıştırma (*perturbing*) gibi farklı veri çoğaltma teknikleri uygulanabilmektedir. İleri düzey yaklaşımda ise ayrışma yaklaşımlı yöntemler (*decomposition based methods*), model yaklaşımlı yöntemler (*model methods*), öğrenme yaklaşımlı yöntemler (*learning methods*) olmak üzere 3 farklı yöntem bulunmaktadır. Öğrenme yaklaşımlı yöntemler kendi içerisinde 3 alt daldan oluşmaktadır: Gömülü uzak (*embedding space*), (GAN/Adversial), (RL/Meta-Learning).

Zaman alanı (*Time Domain*), zamana göre matematiksel fonksiyonların, fiziksel sinyallerin veya ekonomik ya da çevresel verilerin zaman serilerinin analizini gerçekleştirmek için kullanılmaktadır. Zaman etki alanı grafiği, bir sinyalin zamanla nasıl değiştiğini gösterirken, bir frekans etki alanı grafiği, sinyalin ne kadarının belirli

bir frekans aralığında olduğunu gösterir (https://en.wikipedia.org/wiki/Time_domain, Erişim Tarihi: 18.12.2020).

Zaman alanındaki dönüşümler, zaman serisi verileri için en basit veri artırma yöntemleridir. Birçoğu Gaus parazitinde (*Gaussian noise*) veya daha komplike parazit kalıplarında örneğin *spike*, *spike like trend* ve *slope like trend* olduğu üzere, orijinal zaman serisi girdisini değiştirir (Wen ve ark., 2020).

Frekans alanı, matematiksel fonksiyonların veya sinyallerin zaman yerine frekansa göre analizini ifade eder (Broughton ve Brayn, 2008). Diğer bir ifade ile, bir zaman alanı grafiği, bir sinyalin zaman içinde nasıl değiştiğini gösterirken, bir frekans alanı grafiği, sinyalin ne kadarının belirli bir frekans aralığında diğer bir deyişle ne kadarının belirli bir frekans bandında olduğunu gösterir. Bir frekans alan gösterimi, orijinal zaman sinyalini geri kazanmak için frekans bileşenlerini yeniden birleştirebilmek için her sinüzoidde uygulanması gereken faz kayması hakkında bilgi de içerebilir (https://en.wikipedia.org/wiki/Frequency_domain, Erişim Tarihi: 18.12.2020).

Literatür çalışmalarında elde edilen bilgilere göre; mevcut veri artırma yöntemlerinin çoğu zaman alanına odaklanırken, yalnızca birkaç çalışma zaman serileri için frekans alanı perspektifinden veri artırmayı araştırmaktadır.

2020 yılında gerçekleştirilen bir çalışma, konvolusyonel sinir ağı ile zaman serisi anormallik tespitinde veri artışı için frekans alanında hem genlik spektrumunda hem de faz spektrumunda pertürbasyonların kullanılmasını önermektedir (Gao ve ark., 2020).

Zaman-frekans alanı (*Time Frequency Domain*) analizi, bir sinyali çeşitli zaman-frekans temsillerini kullanarak aynı anda hem zaman hem de frekans alanlarında inceleyen teknikleri içermektedir. 1 boyutlu bir sinyali ve bazı dönüşümleri görüntülemek yerine, zaman-frekans analiz iki boyutlu bir sinyali incelemektedir (Cohen,1995; Sejdic ve ark, 2009).

Zaman-frekans analizi, derin sinir ağlarında uygun bir girdi özelliği olarak kullanılabilen, zaman serisi analizi için yaygın olarak uygulanan bir tekniktir. Bununla birlikte, frekans alanındaki veri artırmaya benzer şekilde, yalnızca birkaç çalışma, zaman serileri için zaman-frekans alanından veri artırmayı dikkate almıştır (Wen ve ark.,2020).

Zaman serilerinde veri çoğaltmada temel yaklaşım; zaman, frekans ve zaman-frekans alanlarında gerçekleştirilen dalga bozulumu, ölçeklendirme, rotasyon, kırpma, döndürme, dürme ve karıştırma gibi farklı veri çoğaltma tekniklerini ihtiva etmektedir. Bu nedenle aşağıda, bu tez çalışmasında uygulanan temel yaklaşıma ait veri çoğaltma teknikleri açıklanmıştır.

Dalga bozulumu (*jittering*) tekniği, çoğaltılacak veri kümesine küçük miktarda beyaz parazit (*white noise*) veya tekdüze parazit (*uniform noise*) gibi farklı bir sinyal eklenerek yeni veri elde edilmesi olarak tanımlanabilir. Sinyal işlemede beyaz parazit farklı frekanslarda eşit yoğunluğa sahip olan ve sabit bir güç spektral yoğunluğu (*power spectral density*) sağlayan rastgele bir sinyal olarak tanımlanmaktadır (Mancini ve Bruce, 2009). Diğer bir ifade ile veri üzerinde bilinçli olarak uygulanmış bir faz bozulması olarak ifade edilen dalga bozulumu, uygulanış şekliyle ölçümlerde oluşan parazitten farklıdır.

Dalga bozulumu tekniği, ataletsel ölçüm birimi ile elde edilen sinyalde ek olarak sensör paraziti eklenerek uygulanabilmektedir. Her bir sensör farklı türlerde mekanik parazite sahiptir. Tesadüfi sensör parazitinin simule edilerek eğitim kümesine eklenmesi, modelin farklı sensör türlerine ve bu sensörlerin neden olduğu parazitlere karşı daha etkili bir öğrenme sağlamasına katkıda bulunur (Rashid ve Louis, 2019; Goodfellow ve ark., 2016).

Ölçeklendirme (*scaling*) tekniği, veri etiketlerini koruyarak ham verinin genliğini değiştirmekte kullanılan bir veri çoğaltma tekniğidir (Rashid ve Louis, 2019). Ölçeklendirme ham verinin rastgele bir skaler sayı ile çarpımı ile gerçekleştirilir.

Sinyal genliğindeki ufak değişimler veri etiketlerini hedeflenen amaca bağlı olarak genelde korumaktadır (Goodfellow ve ark., 2016).

Rotasyon (Rotation) tekniği, ham verinin belirli açılarda çevrilmesiyle gerçekleştirilmektedir. Ham verilere rastgele rotasyon uygulamak, veri toplama sırasında titreşim nedeniyle sensör yönelimindeki küçük değişiklikleri açıklayabilir. Ayrıca rastlantısal rotasyon tekniğinin ham veriye uygulanması sensörlerin farklı yerleştirilmesini simule etmek için kullanılabilir. (Rashid ve Louis, 2019). Örneğin, ataletsel ölçüm birimi sensör verilerinde, sensörün ters yerleştirilmesi okunan değer in işaretini değiştirir ancak veri etiketini değiştirmez (Goodfellow ve ark., 2016).

Permutasyon (Permutation) tekniği, bir zaman serisinin zaman değişkenini korumamakla beraber yeni bir model üretmek için bir zaman serisinin bölümlerini yeniden düzenleme yöntemi olarak geliştirilmiştir (Um ve ark., 2017). Literatürde eşit boyutlu segmentler ve değişken boyutlu segmentler olmak üzere iki farklı şekilde uygulanabilir. Permutasyon tekniği eşit boyutlu segmentlere uygulanmasında zaman serisi T adet eşit zaman boyutuna bölünerek zaman serisinin sırası değiştirilir.

Genlik Çarpıtma (Magnitude Warping) tekniği, zaman serilerine özgü bir veri çoğaltmadır. Burada sinyalin genliği pürüzsüz eğri (*smoothed curve*) ile çarpıtılır. Genlik çarpıtmanın temelinde yatan fikir zaman serilerindeki veriye küçük dalgalanmalar ekleyerek rastgele bölgelerdeki genliklerde artış ve azalış sağlamaktır (Um ve ark., 2017).

Zaman atlatma (Time warping / Time Step Deformation) tekniği, belirli bir görev için bir ekipmanın farklı zamansal özelliklerinden sentetik eğitim verisi oluşturmak için kullanılır (Goodfellow ve ark., 2016). Örneğin bir halterci, ağırlık kaldırma aktivitesini farklı hızlarda yapabilir. Her aktivite süresi farklı saptırma oranları kullanılarak kısaltılıp, uzatılabilir. Zaman serisi analizinde, dinamik zaman atlama (DTW), hızda değişebilen iki zamansal dizi arasındaki benzerliği ölçmek için kullanılan algoritmalar dan biridir.

Kırpma (Cropping) tekniği, görsel kırmaya veya pencere dilimleme (*window slicing*) yöntemlerine benzemektedir. Bu teknik zaman serisinde hareketin gerçekleştiği yere olan bağımlılığı ortadan kaldırmak için uygulanır. Eğer kırpma işlemi, hareketin gerçekleşmediği bir alana denk gelirse, hareketin etiketi değişebilir (Banko ve Brill, 2017). Diğer bir deyişle, örneğin aralıklı koşma hareketinin olduğu bir zaman serisinde kırpma işlemi katılımcının durduğu ana denk gelirse hareket koşmayı değil durmayı gösterecektir.

4.5.2. Zaman serilerinde veri çoğaltmada ileri yaklaşımlar

Zaman serilerinde veri çoğaltmada kullanılan ileri yaklaşımlar ayrışmaya dayalı yöntemler (*decomposition based methods*), model tabanlı yöntemler (*model based methods*) ve öğrenme tabanlı yöntemler (*learning based methods*) olmak üzere 3 ana grupta toplanmaktadır. Ayrıştırmaya dayalı yöntemler fikri, karmaşık bir veriyi parçalamaya dayanmaktadır. Böylece daha küçük, daha sade ve daha yönetilebilir parçalar mevcut araçlar kullanarak çözümlenir. Ardından orijinal sorunu çözmek için bu çözümler bir araya getirilerek karmaşık verinin çözümlenmesi sağlanır (<https://www.ise.bgu.ac.il/faculty/liorr/hbchap46.pdf>, 23.12.2020). Ayrışmaya dayalı zaman serisi veri çoğaltma yöntemi, örneğin tahmin (*forecasting*), kümeleme (*clustering*) ve anormallik algılama (*anomaly detection*) gibi birçok zaman serisi görevinde benimsenmiş ve başarılı şekilde uygulanmıştır (Wen ve ark.,2020).

Modele dayalı zaman serisi veri çoğaltma yöntemi yaklaşımları tipik olarak zaman serilerinin dinamiklerinin istatistiksel modellerle modellenmesini içermektedir. Esasen bu modeller, t zamanındaki değerin önceki noktalara bağlı olduğunu varsayarak zaman serilerinin koşullu dağılımını tanımlar. İlk değer bozulduğunda, koşullu dağılımın ardından yeni bir zaman serisi dizisi oluşturulabilir.

Öğrenme yaklaşımlı yöntemler kendi içerisinde (*GAN/Adversial*), Gömülü uzay (*embedding space*), (*RL/Meta-Learning*) olmak üzere 3 alt dalda sınıflandırılmaktadır. GAN, sentetik örnekler oluşturulmasında ve eğitim kümesi etkili bir şekilde arttırılmasında üretken bir model olarak kullanılmaktadır. GAN çerçevesi

birçok alanda ilgi görmesine rağmen, zaman serilerinin nasıl oluşturulacağı hala açık bir sorun olmaya devam etmektedir (Wen ve ark., 2020).

Gömülü uzayda; veri çoğaltmanın, öğrenme işlemi gerçekleştirilmiş alanda yapılması önerilmektedir (DeVries ve Taylor, 2017). Ham girdiler yerine kodlanmış girdilere uygulanan basit dönüşümlerin, özellik uzayında ortaya çıkan çeşitlilik nedeniyle daha makul sentetik veriler üreteceğini varsaymaktadır. Yeni sentetik verilerin üretilmesine özellikle interpolasyon ve ekstrapolasyon uygulanır. Aynı etikete sahip dönüştürülmüş alandaki en yakın ilk k etiketi belirlenir. Daha sonra, her bir komşu örnek çifti için, bunların lineer kombinasyonu olan yeni bir örnek oluşturulur. İnterpolasyon ve ekstrapolasyon arasındaki fark, örnek oluşturmada ağırlık seçiminde yatmaktadır. Bu teknik özellikle zaman serisi sınıflandırması için kullanışlıdır (Wen ve ark., 2020).

Pekiştirmeli öğrenme (*reinforcement learning*), iyileştirilmiş/geliştirilmiş veri artırma politikalarını otomatik olarak araştırmak için veri çoğaltma da kullanılmıştır (Çubuk ve diğerleri, 2019). Spesifik olarak, bir veri çoğaltma prosedürü birçok alt süreçten oluştuğu bir arama alanını tanımlanır. Her alt süreç iki işlemden oluşur ve her işlem, çevirme, döndürme veya kesme gibi bir görüntü işleme işlevi olarak tanımlanır.

Literatürde veri çoğaltmanın nasıl uygulandığı aktarılmıştır. Görüldüğü üzere veri çoğaltma, temel yaklaşım ve ileri yaklaşım olmak üzere iki ayrılmakta ve temel yaklaşımın yeterli olmadığı durumlarda ileri teknik tekniklere ihtiyaç duyulmaktadır. Dolayısıyla oluşan ihtiyaçlar neticesinde halen yeni teknikler ve yöntemler geliştirilmektedir.

Bu bölümde ataletsel sensörlerin ve ataletsel ölçüm birimlerinin ne olduğu açıklanmış ve ardından çalışma mekanizmalarından bahsedilmiştir. Günümüzde kullanılan ataletsel ölçüm birimlerinden örnekler verilmiş ve bu cihazlardan elde edilen verinin nasıl toplandığı, bu verinin nasıl aktarıldığı ve nasıl yorumlanması gerektiği örneklerle açıklanmıştır. Zaman serileri kavramına yer verilmiştir. Derin öğrenme, veri çoğaltma yaklaşımları ve veri çoğaltma tekniklerinin veriye nasıl uygulandığı açıklanmıştır.

5. GEREÇ VE YÖNTEM

5.1. Yazılım ve Donanım

Bu tez çalışmasının gerçekleştirilmesinde veri çoğaltma işlemleri Matlab® (2020a) versiyonu yüklü, 12 GB RAM içeren, Intel i5 işlemcili, 250gb SSD sabit diske sahip Linux tabanlı bir kişisel bilgisayar kullanılarak gerçekleştirilmiştir. Konvolusyonel yapay sinir ağı modeli çalışmaları ise altyapısı Google Colaboratory® üzerinden temin edilmiştir. CNN modelini oluşturmak için numpy, pandas, matplotlib ve keras kütüphaneleri kullanılmış ve python dilinde kodlanmıştır.


5.2. Veri Tabanı

“Human Gait Database” (HuGaDB), HSE (Moskova) Üniversitesinde çalışan Roman Chereshev ve Atilla Kertesz Farkas tarafından, “HuGaDB: Human Gait Database for Activity Recognition from Wearable Inertial Sensor Networks” adlı makalede 2017 yılında yayımlanmıştır. HuGaDB, oldukça ayrıntılı olarak insan hareketlerini betimleyen ilk veri tabanıdır. Bu veri tabanı, referans belirterek kullanılmak şartıyla bilim dünyasıyla paylaşılmıştır.

Bu veri tabanı sadece hareketin tespitinde değil, aynı zamanda hareketin nasıl gerçekleştiğini ve eylemci uzuvları oluşturan bölümlerin birbirleriyle nasıl ilişkili hareket ettiğini incelemek amacıyla kullanılabilecek yeterlilikle veri içermektedir. Örneğin HuGaDB veri tabanı yürüme rehabilitasyonu veya parkinson hastalığının tespiti gibi insan sağlığı çalışmalarının gerçekleştirilmesinde, sanal gerçeklikte ve oyunlarda insanımsı hareketlerin simülasyonunda veya insanımsı robotların yürüme modellerinde de kullanılabilir.


HuGaDB veri tabanındaki veri, altı adet giyilebilir ataletsel sensör (ivmeölçer ve jiroskop) ve iki adet EMG sensörü kullanılarak kaydedilmiştir. Ataletsel sensörler, sol ve sağ tibia, femur ve metatarsal üzerine; EMG sensörleri ise kas aktivitesini ölçmek için quadriseps kası (*musculus quadriceps femoris*) üzerine şekil1’de gösterildiği gibi bağlanmıştır.

Sensörlerin uzuvlardaki bağlantı yerleri belirlenirken cihazların bağlantı noktalarından düşmeyecek veya kaymayacak şekilde olmasına, uzuvların kütle merkezlerine yakın ve uzuvların hareketlerini kısıtlamayacak şekilde kaydedilmesine dikkat edilmiştir.



Şekil 11. Sensörlerin alt ekstremitedeki yerleşimleri (Chereshnev ve Kertész-Farkas, 2017)


Şekil 12’de görüldüğü gibi HuGaDB üzerinde kayıtlar şu şekilde tutulmuştur: Fiziksel faaliyetin adı, katılımcıların boy, kilo, yaş ve cinsiyet gibi kişiyi tanımlama verisi, deneyin tekrar sayısı, sensörlerin nerede takılı olduğu (sağ metatarsal, sol metatarsal, sağ tibia, sol tibia, sağ femur ve sol femur), ivmelenme değerleri (x, y, z eksenlerinde) ve jiroskop değerleri (x, y, z eksenlerinde) her bir ataletsel ölçüm biriminden ölçülerek kayıt altına alınmıştır.



Şekil 12. HuGaDB: Sensör lokasyonları (Kendi çizimim)

Deneyde görev alan katılımcılar ayrıca farklı bedensel hareket kombinasyonlarını gerçekleştirmiş ve veriler sürekli olarak kaydedilmiştir. Örneğin bir katılımcıya oturur pozisyondayken ayağa kalkması, yürümesi, merdiven çıkması ve tekrar oturması gibi komutlar peşi sıra verildiğinde, ölçümler bilgisayara hareket etiketleri ile kaydedilir. Toplamda 18 katılımcıdan 2.111.962 adet örnek elde edilmiştir. Toplam kayıt süresi 10 saatin üzerindedir. Tablo 1’de hareketler ve bu hareketlerin detayları açıklanmıştır.

HuGaDB veri tabanında ölçüm yapılan deneklerin boy, kilo ve yaş değerlerini içeren tablolar 18 katılımcıya aittir. Şekil 9’da paylaşılan pasta grafikte gösterildiği üzere katılımcıların %78’i erkeklerden; %22’si ise kadınlardan oluşmaktadır. Şekil 13’teki çubuk grafikte ise 18 katılımcının boy, kilo ve yaş dağılımları görülmektedir. Tablo 2’de paylaşılan tabloda da görülebileceği üzere bu katılımcılar, sağlıklı yetişkin 4 kadın ve 14 erkekten oluşmaktadır. Yaş ortalamaları 23,67 yıl (std:3,69) olup; boy uzunluğu ortalama 179,06 cm (std:9,85); kilo ortalaması 73,44 kg (std:16,67) olarak hesaplanmıştır. Katılımcılara ait bilgilerin grafiksel gösterimini şekil 13’te paylaşılmıştır.



Şekil 13. HuGaDB katılımcı dağılımı (Chereshnev ve Kertész-Farkas, 2017)

HugaDB’de bilim dünyası ile paylaşılan ana veri tabanı, 3 eksenli ivmeölçer, 3 eksenli jiroskop ve EMG sensörleri verisinden oluşmaktadır. Üç çift ataletsel sensör ve bir çift EMG sensörü sol ve sağ bacaklara elastik bantlarla tutturulmuştur. Bir çift ataletsel sensör *rectus femoris* kasına diz kapağından 5 cm yüksekte olacak şekilde; bir çift sensör ise tibial kemiğini ortalayacak şekilde baldırın bittiği noktaya ve bir çift sensör ise metatarsal kemiğin üzerine yerleştirilmiştir. EMG sensörleri ise *vastus lateralis*’e yerleştirilmiştir. EMG üç elektrot ile cilde bağlanmıştır. İki elektrot arasında elektrik potansiyeli ölçülmüştür. Toplamda her bir katılımcının 38 farklı sinyali ölçülmüştür. Jiroskop ölçümleri için sensör ayarları -2000 derece/saniye’den +2000 derece/saniye’ye kadar ve ivmeölçerin sensör ayarı ise -2g’den 2g’ye ayarlanmıştır.

Deneylerin bazılarında jiroskop ile bağlantı koptuğu için HuGaDB verisinde bozuk veriler bulunmaktadır. Bozuk veriler çalışmaya dahil edilmemiştir. Veri tabanının kullanımı ve analizler hakkında ilgili yazarlarla iletişime geçilmiş, yazarlarla gerçekleştirilen elektronik posta yazışmalarında, bacakların farklı bölümlerinin arasındaki açığı elde etmek için ivmeölçer ve jiroskop ölçümlerinde tamamlayıcı filtreden (*complimentary filter*) faydalandıklarını belirtmişlerdir. Tezin ilgili kısımlarında yeri geldikçe konuyla ilgili teknik bilgilere değinilmiştir.

Katılımcı	Fiziksel Faaliyet	Süre (sn.)	Yüzde (%)	Toplanan Örnek Sayısı	Fiziksel Faaliyet Tanımı
1	Yürümek	11,544	32.15	679,073	Düz bir zeminde farklı hızlarda yürümek ve dönmek
2	Koşmak	1,218	3.39	71,653	Farklı tempolarda koşmak
3	Merdivenden Yukarı Çıkmak	2,237	6.23	131,604	Farklı hızlarda ve basamak sayısında merdiven çıkmak
4	Aşağı İnme	1,982	5.52	116,637	Farklı hızlarda ve basamak sayısında merdiven inmek
5	Ayaktayken Sandalyeye oturmak	4,111	11.45	241,849	Ayaktayken Sandalyeye oturmak
6	Oturmak	409	1.14	24,112	Sandalyede Oturmak
7	Ayağa Kalkmak	380	1.06	22,373	Sandalyeden Ayağa Kalkmak
8	Ayakta Durmak	5,587	15.56	328,655	Ayakta sabit durmak
9	Bisiklet	2,661	7.41	156,560	Bisiklet sürmek
10	Asansörle Yukarı Çıkmak	1,515	5.22	89,144	Yukarı yönde hareket halindeki asansörde ayakta durmak
11	Asansörle Aşağı İnme	1,185	3.30	69,729	Aşağı yönde hareket halindeki asansörde ayakta durmak
12	Arabada Oturmak	3,069	8.55	180,573	Araçta yolcu koltuğunda oturmak
Toplam		35,903	100.00	2,111,962	

Tablo 1. HuGaDB: Fiziksel aktivite tablosu (Chereshnev ve Kertész-Farkas, 2017)

Katılımcı	Kilo (kg)	Boy (cm)	Yaş	Cinsiyet (E = Erkek, K = Kadın)
1	75	177	24	E
2	80	183	22	E
3	65	183	23	E
4	93	189	24	E
5	63	183	35	E
6	54	168	25	K
7	52	161	22	K
8	80	176	23	E
9	65	175	24	K
10	118	183	27	E
11	85	203	24	E
12	85	192	23	E
13	64	174	18	E
14	68	175	19	E
15	72	178	23	E
16	48	164	26	K
17	85	179	25	E
18	70	180	19	E

Tablo 2. Katılımcıların, kilo, boy, yaş ve cinsiyet tablosu (Chereshnev ve Kertész-Farkas, 2017)

Human Gait Data Analysis (HuGADB) veri tabanında 16 katılımcının düz bir zeminde farklı hızlarda yürürken ve 4 katılımcının ise farklı tempolarda koşarken ataletsel ölçüm birimleri ile 6 farklı noktadan toplanmış ivmelenme ve jiroskop değerleri bulunmaktadır. Toplanan bu verilerden jiroskop değerlerinin bir kısmının hatalı olduğu belirtilmiştir. İvme değerlerinde ise bir hatanın olmadığı açıklanmıştır.

5.3. Yürüme ve Koşma Verilerinin Görselleştirilmesi

Çalışmaya, açık kaynaklı Human Gait Database (HuGaDB) veri tabanında bulunan ve katılımcıların alt ekstremitelerine yerleştirilen 6 adet ataletsel ölçüm biriminden toplanmış, 12 farklı ölçüme ait 1218 saniyelik koşma aktivitesine ve 87 farklı ölçüme

ait 11544 saniyelik yürüme aktivitesine, üç eksenli ivme ve jiroskop sinyalleri dâhil edilmiştir.

İlk aşamada, veri çoğaltma teknikleri uygulanmadan önce, eldeki verinin anlaşılması için görselleştirme çalışmaları gerçekleştirilmiştir. Bu amaçla yürüme ve koşma aktivitelerine ait ivmelenme ve jiroskop değerlerinin 3 boyutlu uzayda nasıl betimlendiğini görmek için Matlab® (2020a) yardımı ile 3 boyutlu koordinat sistem grafikleri hazırlanmıştır. Ardından, Matlab® (2020a) *Signal Analyzer* eklentisi kullanılarak güç spektrumu (*power spectrum*) ve normalleştirilmiş frekans bilgilerini de içeren görseller hazırlanmıştır.

5.4. Yürüme ve Koşma Verilerinin Çoğaltılması

Veri çoğaltma, Matlab® (2020a) üzerinden hazırlanan kodlar yardımıyla her bir aktivite ölçümünde kaydedilen üç eksenli ivmelenme ve üç eksenli jiroskop sinyallerine; 1 adet rotasyon (*rotation*), 7 adet ölçeklendirme (*scaling*), 6 adet dalga bozulumu (*jittering*), 6 adet permutasyon (*permutation*), 3 adet kırpma (*cropping*), 7 adet rotasyon ve kırpma, 32 adet ölçeklendirme ve dalga bozulumu, 42 adet ölçeklendirme ve permutasyon, 18 adet permutasyon ve kırpma teknikleri koşma ve yürüme sinyallerine uygulanmıştır.

Böylece koşma verisine ait 12 farklı ölçüm 1104 farklı ölçüme; yürüme verisine ait 87 farklı ölçüm 8004 farklı ölçüme kadar çoğaltılmıştır. Diğer bir deyişle 1218 saniyelik koşma verisi 112056 saniyeye, 11544 saniyelik yürüme verisi ise 1062048 saniyeye çoğaltılmıştır. Tablo 3'te uygulana veri çoğaltma tekniklerini özetlemektedir.

Teknik	Uygulanan İşlemin açıklaması
Rotasyon	Her sinyal -1 ile çarpılarak rotasyona tabi tutulmuştur.
Ölçeklendirme	Her sinyal 0,2; 0,4; 0,6; 0,8; 1,2; 1,4; 1,6; 1,8; 2,0 değerleri göre ölçeklendirilmiştir.
Dalga Bozulumu	Her sinyale 0,1; 0,2; 0,4; 0,6; 0,8 ve 1,0 varyanslı beyaz parazit eklenmiştir.
Permutasyon	Sinyaller 4 parçaya ayrıştırılarak farklı sıralamada tekrar birleştirilmiştir.
Kırpma	Her sinyal belirli aralıklarla 3 farklı bölgeden kırpılmıştır.
Rotasyon ve ölçeklendirme	Her sinyale rotasyon uygulandıktan sonra 0,1; 0,2; 0,4; 0,6; 0,8 ve 1,0 varyanslı beyaz parazit eklenmiştir.
Ölçeklendirme ve Dalga bozulumu	Her sinyale rotasyon uygulandıktan sonra 0,1; 0,2; 0,4; 0,6; 0,8 ve 1,0 varyanslı beyaz parazit eklenmiştir.
Ölçeklendirme ve permutasyon	Her sinyal 0,2; 0,4; 0,6; 0,8; 1,2; 1,4; 1,6; 1,8; 2,0 değerleri göre ölçeklendirildikten sonra 6 farklı permutasyona tabi tutulmuştur.
PERMUTASYON ve kırpma	Her sinyalden 6 farklı permutasyon oluşturulmuş ve belirli aralıklarla 3 farklı bölgeden kırpılmıştır

Tablo 3. Veri çoğaltma teknikleri tablosu

6. BULGULAR

Tüm katılımcıların ölçüm değerlerini içeren grafikler MATLAB® (2020a) kullanılarak oluşturulmuştur ve bu grafiklerin açıklamaları şu şekildedir. Şekil 14'teki grafikler 16 katılımcının düz bir zeminde farklı hızlarda yürürken her bir ataletsel ölçüm birimi üzerinden kaydedilen x, y ve z eksenlerindeki ivmelenme değerlerini göstermektedir. Şeklin üst satırındaki grafikler sol bacak üzerinde sırasıyla sol metatarsal, sol tibia ve sol femur üzerine yerleştirilen ataletsel ölçüm birimlerinden elde edilen ivmelenme değerlerini; alt satırdaki grafikler ise sağ bacak üzerinde sırasıyla sağ metatarsal, sağ tibia ve sağ femur üzerine yerleştirilen ataletsel ölçüm birimlerinden elde edilen ivme değerlerini göstermektedir.

Grafiklerdeki her bir nokta ölçüm anındaki ivmelenmenin x, y ve z eksenlerindeki değerini göstermektedir. Grafiklerden de anlaşıldığı üzere farklı katılımcılardan elde edilen ivme değerleri ölçüm cihazının lokasyonuna göre kendi aralarında örtüşmektedir. Ancak farklı lokasyonlardaki sensörlerden toplanan veriler belirgin farklılıklar göstermektedir. Elbette bu durum uzuvların farklı karakteristikte hareket etmelerinden kaynaklanmaktadır.

Şekil 15'teki grafikler 16 katılımcının düz bir zeminde farklı hızlarda yürürken her bir ataletsel ölçüm birimi üzerinden kaydedilen x, y ve z eksenlerindeki jiroskop değerlerini göstermektedir. Daha önce de belirtilmiş olduğu üzere veri tabanındaki jiroskop değerlerinin bir kısmı hatalıdır. Bu nedenle grafiklerden karşılaştırmalı olarak anlamlı bir sonuç çıkarmak mümkün olmamaktadır. Şekil 16'te ikinci satırdaki üçüncü grafikte görüldüğü üzere sağ femur kemiği üzerine yerleştirilen ataletsel ölçüm biriminden toplanan veri içerisinde sıra dışı değer (outlier) bulunmaktadır. Ölçüm esnasında gerçekleşen bir hatadan ötürü jiroskopun y eksenindeki değeri sıra dışı bir değer aldığı rahatlıkla görülmektedir. Yine karşılaştırmalı olarak grafikler incelendiğinde vücudun sağ ve sol taraflarında aynı yerlere yerleştirilen sensörlerden elde edilen jiroskop değerleri kendi aralarında örtüşmemektedir.

Human Gait Data Analysis (HuGADB) veri tabanında 4 farklı katılımcının farklı tempolarda koşarken ataletsel ölçüm birimleri ile 6 farklı noktadan toplanmış ivmelenme ve jiroskop değerleri şekil 16'de gösterilmiştir. Şeklin üst satırındaki grafikler sol bacak üzerinde sırasıyla sol ayak, sol tibia kemiği ve sol femur üzerine yerleştirilen ataletsel ölçüm birimlerinden elde edilen ivmelenme değerlerini; alt satırdaki grafikler ise sağ bacak üzerinde sırasıyla sağ metatarsal, sağ tibia ve sağ femur üzerine yerleştirilen ataletsel ölçüm birimlerinden elde edilen ivme değerlerini göstermektedir. Grafiklerdeki her bir nokta ölçüm anındaki ivmelenmenin x, y ve z eksenlerindeki değerini göstermektedir.

Koşma aktivitesindeki katılımcı sayısı yürüme aktivitesindeki katılımcı sayısından az olduğu için daha az veri toplanmıştır. Bu nedenle koşma aktivitesine ait grafiklerde üç boyutlu gösterimlerdeki veri yoğunluğu yürüme aktivitesine göre daha azdır.


4 katılımcıya ait koşma verilerinin jiroskop değerlerinin grafiksel gösterimi incelendiğinde (şekil 17) sensörlerin konumları üzerinden anlamlı bir yorum elde edilememektedir. Daha önce de belirtilmiş olduğu üzere veri tabanındaki jiroskop değerlerinin bir kısmı hatalıdır. Bu nedenle grafiklerden karşılaştırmalı olarak anlamlı bir sonuç çıkarmak mümkün olmamaktadır.

Sonuç olarak, Human Gait Data Analysis (HuGADB) veri tabanında 16 katılımcının düz bir zeminde farklı hızlarda yürürken ve 4 katılımcının ise farklı tempolarda koşarken ataletsel ölçüm birimleri ile 6 farklı noktadan toplanmış ivmelenme ve jiroskop değerleri x, y ve z eksenlerinde bir bütün olarak incelendiğinde birbirlerinden ayrıştırıcı temel bir özellik sunmadıkları aksine sürecin değerlendirilmesini daha da karmaşık hale getirdiği gözlemlenmiştir.


Dolayısıyla veri anlamak, anlamlandırmak ve ölçüm cihazlarının konumuna bağlı olarak ayırıcı noktaları tespit etmek ya da bir örüntü elde edebilmek bu yöntemle mümkün olmamaktadır. Elde edilen en önemli çıkarım sıra dışı değerlerin görsel olarak tespit edilmesindeki kolaylık olup (şekil 18), ileriki çalışmalarda bu yöntemden faydalanılabileceği düşünülmektedir. Şekil 20'de jiroskop üzerinden ölçümlenen y

eksenindeki sıra dışı değerin diğer tüm ölçümlerden ayrılarak görsel olarak kendini belirgin bir şekilde belli etmesi yüzbinlerle ifade edilebilecek sayıdaki veri üzerinde daha hızlı karar vermeyi kolaylaştırmaktadır.







Şekil 14. 16 katılımcıya ait yürüme verilerinin ivmelenme değerlerinin grafiksel gösterimi




Şekil 15. 16 katılımcıya ait yürüme verilerinin jiroskop değerlerinin grafiksel gösterimi



Şekil 16. 4 katılımcıya ait koşma verilerinin ivme değerlerinin grafiksel gösterimi




Şekil 17. 4 katılımcıya ait koşma verilerinin jiroskop değerlerinin grafiksel gösterimi



Şekil 18. Sıra dışı değerlerin görsel olarak tespit edilmesi

HuGaDB veri tabanındaki yürüme ve koşma aktivitelerinden elde edilen ivmeölçer ve jiroskop değerlerinin üç boyutlu uzayda gösterimi bu iki aktivitenin ayırıcı unsurlarının tespit edilmesinde yeterli olmamaktadır. Bu nedenle her bir aktivite üzerinden ölçümlenen ivme ve jiroskop değerlerinin ayrı ayrı incelenmesi aralarındaki farklılığı ortaya koyabileceği düşünülmektedir.

Bu nedenle 3 numaralı katılımcının sol ayağı üzerine yerleştirilen ataletsel ölçüm biriminin yürürken ve koşarken kaydettiği ivmeölçer değerleri güç spektrumu ve spektrogram tabloları da göz önüne alınarak karşılaştırılmalı olarak incelenmiştir. Şekil 19’da görüldüğü üzere aynı katılımcının yürürken ve koşarken kaydedilmiş olan x eksenindeki ivmelenme değerleri farklılık arz etmektedir. Koşma esnasındaki ivmelenmedeki pik sayısı daha fazladır.




a) Yürüme Aktivitesi




b) Koşma Aktivitesi

Şekil 19. 3 nolu katılımcının yürüme aktivitesi ve koşma aktivitesi esnasında sol ayak üzerinde kaydedilen ivmeölçer değerleri üzerinden analizi




Şekil 20. Orijinal sinyal (sol), dalga bozulumu uygulanmış sinyal (sağ)

Şekil 20, bu çalışmada kullanılan ham veri üzerinde dalga bozulumu gerçekleştirilmiş ve gerçekleştirilmemiş sensör verisini göstermektedir.




Şekil 21. Orijinal sinyal (sol), ölçeklendirme tekniği uygulanmış sinyal (sağ)

Şekil 21, bu çalışmada kullanılan ham veri üzerinde ölçeklendirme tekniği uygulanmış ve uygulanmamış sensör verisi gösterilmektedir. Ölçeklendirme tekniğini uygulamak için ham veri değerleri 0,2 ile çarpılmıştır.




Şekil 22. Orijinal sinyal (sol), rotasyon tekniği uygulanmış sinyal (sağ)

Şekil 22’de, bu çalışmada kullanılan ham veri üzerinde rotasyon tekniği uygulanmış ve uygulanmamış sensör verisini göstermektedir. Örneğin, rotasyon tekniğini uygulamak için ham veri değerleri eksi bir (-1) ile çarpılmıştır.




Şekil 23. Orijinal sinyal (sol), permutasyon tekniği uygulanmış sinyal (sağ)

Şekil 23'te, bu çalışmada kullanılan ham veri üzerinde permutasyon tekniği uygulanmış ve uygulanmamış sensör verisini göstermektedir.




Şekil 24. Orijinal sinyal (sol), kırpma tekniği uygulanmış sinyal (sağ)

Şekil 24'te, bu çalışmada kullanılan ham veri üzerinde kırpma tekniği uygulanmış ve uygulanmamış sensör verisini göstermektedir.




Şekil 25. Orijinal sinyal (sol), rotasyon ve ölçeklendirme uygulanmış sinyal (sağ)

Şekil 25'te, bu çalışmada kullanılan ham veri üzerinde rotasyon ve ölçeklendirme tekniklerinin bir arada uygulanmış hali ve orijinal sensör verisini göstermektedir.




Şekil 26. Orijinal sinyal (sol), ölçeklendirme ve dalga bozulumu uygulanmış sinyal (sağ)

Şekil 26'da bu çalışmada kullanılan ham veri üzerinde ölçeklendirme ve dalga bozulumu tekniklerinin bir arada uygulanmış hali ve orijinal sensör verisini göstermektedir.



Şekil 27. Orijinal sinyal (sol), ölçeklendirme ve permutasyon uygulanmış sinyal (sağ)

Şekil 27'de, bu çalışmada kullanılan ham veri üzerinde ölçeklendirme ve permutasyon tekniklerinin bir arada uygulanmış hali ve orijinal sensör verisini göstermektedir.



Şekil 28. Orijinal sinyal (sol) ve permutasyon ve kırpma uygulanmış sinyal (sağ)

Şekil 28’de, bu çalışmada kullanılan ham veri üzerinde permutasyon ve kırpma tekniklerinin bir arada uygulanmış hali ve orijinal sensör verisini göstermektedir.

Yukarıda belirtilen tekniklerle çoğaltılan veri tabanının başarısı konvolusyonel yapay sinir ağı modelleri üzerinde ölçümlenmiştir. CNN modeli üzerinden gerçekleştirilen çalışmada öncelikle ham veri üzerinden ilerlenmiş ve ardından veri çoğaltma teknikleri uygulanmış veri tabanı üzerinden CNN modeli üzerinden tekrar sistemin başarısı ölçümlenmiştir. Tablo 4’te CNN parametreleri paylaşılmıştır.

Parametre	Değer	Parametre	Değer
Verbose	1	Epoch	10
Batch size	32	Filters	16
Kernel size	3	Activation	Relu & Softmax
Drop out	0.2	Pool size	2
Optimizer	Adam	Metrics	Accuracy
Loss	Categorical_crossentropy		

Tablo 4. CNN model parametreleri

Tablo 5’te gösterildiği üzere, veri çoğaltma teknikleri uygulanarak oluşturulan veri tabanları

CNN modeli üzerinde test edilerek yüzde doğruluk oranları hesaplanmıştır.

Veri Tabanının Adı	% Doğruluk (Accuracy)
Veri Tabanı	% 97,978 (+/-0,003)
Türev Veri Tabanı (Ölçeklendirme)	% 98,790 (+/-0,016)
Türev Veri Tabanı (Ölçeklendirme ve Permutasyon)	% 98,200 (+/-0,020)
Türev Veri Tabanı (Kırpma)	% 98,000 (+/-0,017)
Türev Veri Tabanı (Ölçeklendirme ve Kırpma)	% 97,998 (+/-0,010)
Türev Veri Tabanı (Permutasyon)	% 97,990 (+/-0,012)
Türev Veri Tabanı (Dalga Bozulumu)	% 95,760 (+/-0,019)
Türev Veri Tabanı (Ölçeklendirme ve Dalga Bozulumu)	% 88,850 (+/-0,014)

Tablo 5. Veri tabanlarından elde edilen doğruluk (*accuracy*) oranları

7. TARTIŞMA VE SONUÇ

Bu çalışmada, *Human Gait Database* üzerinde bulunan koşma ve yürüme aktivitelerine ait 6 farklı ataletsel ölçüm birimi kullanılarak kaydedilmiş ivmelenme ve jiroskop veri üzerinden rotasyon, ölçeklendirme, dalga bozulumu, permutasyon, kırpma, rotasyon, ölçeklendirme ve dalga bozulumu, ölçeklendirme ve permutasyon, permutasyon ve kırpma teknikleri uygulanarak veri çoğaltma işlemi gerçekleştirilmiştir.

Tüm veri çoğaltma işlemleri eklenerek elde edilen son veri tabanında koşma aktivitesine ait toplamda 1218 saniyelik 12 farklı ölçüm 11056 saniyelik 1104 farklı ölçüme; yürüme aktivitesine ait 11544 saniyelik 87 farklı ölçüm 1062048 saniyelik 8004 farklı ölçüme kadar çoğaltılmıştır.

Ham veri tabanı ile veri çoğaltma tekniği uygulanarak elde edilen yeni veri tabanının başarısı CNN modelleri üzerinden her bir veri çoğaltma tekniği ayrı ayrı veri tabanına eklenerek CNN modelinde doğruluk oranı hesaplanmıştır. CNN modelinde tablo 4'te paylaşılan parametreler kullanılmış; veri tabanlarından sadece ivmelenme değerleri işleme alınmış, jiroskop değerleri ise işlem dışında bırakılmıştır. CNN modelinin verimliliğini arttırmak için herhangi bir optimizasyon işlemi gerçekleştirilmemiştir. Temel olarak amaçlanan veri çoğaltma tekniklerinin verimliliğini karşılaştırmak olmuştur.

CNN modeli, HuGaDB veri tabanında koşma ve yürüme aktivitelerini %97,978 (+/- 0,003) doğruluk oranı ile tespit edebildiği ölçülmüştür. Bu tez çalışmanın başlangıcında, ilk aşamada veri tabanından elde edilecek doğruluk oranının daha düşük olacağı öngörülmekteydi. Bu durumun temel nedeni 6 farklı sensörlerden toplanan verinin az bir veri kaydı ile daha yüksek doğrulukta sonuç üretmeye yeterli olabileceğinde kaynaklanabileceği gibi yürüme ve koşma aktivitelerinin karakteristiğinden de kaynaklanabilir. Bu açıdan değerlendirildiğinde daha sonraki

alıřmalarda daha az sensr kullanılarak modelin doęruluk oranının azalıp azalmadıęı arařtırılabilir, farklı aktiviteler sisteme eklenerek modelin doęruluęu test edilebilir.

Gerekleřtirilen bu tez alıřmasında, leklendirme teknięi ile elde edilen trev veri tabanının CNN modelindeki doęruluk oranının (%98,790), iřlem grmemiř veri tabanından (%97,978) daha yksek olduęu lmlenmiřtir. En dřk doęruluk oranı dalga bozulumu teknięi (%95,760) uygulanmıř trev veri tabanında elde dilmiřtir. Um ve arkadaşları kendi kullandıkları veri tabanında doęruluk oranını ilk bařta %77,52 olarak hesaplamıřlar ve rotasyon ve permutasyon tekniklerini bir arada uygulayarak bu veri tabanında doęruluk oranını %86,88'e kadar ıkarabilmiřlerdir (Um ve ark., 2017).

Dalga bozulumu teknięinin Um ve arkadaşlarının yapmıř olduęu alıřmada doęruluk oranını azalttıęı gzlemlenmiřtir. Bu tez alıřmasında ise leklendirme ve dalga bozulumu teknięinin bir arada kullanılması en dřk doęruluk oranını saęlamıřtır. Dięer bir taraftan tek bařına uygulanan dalga bozulumu teknięi orijinal veri tabanına kıyasla yine dřk bir doęruluk oranı sunmaktadır.

Sonuç olarak, gerekleřtirilen tez alıřmasından elde edilen veriler literatrde paylařılan verilerle bazı benzerlikler gsterdięi gibi ayrıldıęı noktalarda bulunmaktadır. alıřmanın sonularının benzerlik gsterdięi konulardan bir tanesi konvolusyonel yapay sinir aęları kullanılarak gerekleřtirilen hareket analizde veri tabanını oęaltmak iin leklendirme, kırpma, permutasyon ve dalga bozulumu gibi farklı teknikler bir arada veya ayrı olarak uygulanabileceęidir. Tez alıřmasının literatrde paylařılan sonulardan ayrıřtıęı nokta ise bu tekniklerden leklendirme ve kırpma tekniklerinin literatrde belirtilenin aksine daha dřk bir doęruluk oranına sahip olduęudur. Bu durumdan anlařılmaktadır ki konvolusyonel yapay sinir aęı modelleri kullanılarak veri analizinde ihtiya duyulan veri miktarına ulařabilmek iin uygulanması dřnlen veri oęaltma modelleri amaca ve ihtiyaca uygun olarak denenerek tespit edilmesi nem arz etmektedir.

8. KAYNAKLAR

Akpınar H. DATA Veri Madenciliği ve Veri Analizi. 2. basım, Papatya Bilim Yayınevi, İstanbul; 2018, s:335-353.

Alharthi AS, Yunas SU, Ozanyan KB. Deep Learning for Monitoring of Human Gait: A Review. IEEE Sensors Journal. 2019; 19:9575-91.

Banko M, Brill E. Scaling to very very large corpora for natural language disambiguation. In Proceedings of the 39th annual meeting of the Association for Computational Linguistics. 2001;26-33.

Chereshnev R, Kertész-Farkas A. GaIn: Human gait inference for lower limbic prostheses for patients suffering from double trans-femoral amputation. Sensors. 2018;18:4146.

Dehzangi O, Mojtaba T, and Raghvendar C. IMU-based gait recognition using convolutional neural networks and multi-sensor fusion. Sensors. 2017;17:2735.

Deng L, Yu D. Deep learning: methods and applications, Foundations and Trends in Signal Processing. 2014;7:197–387.

Dönmez G, Ak E, Ödek U, Özberk N, Korkusuz F. Sporda hareket analizi. TOTBİD Dergisi. 2014;13:369-380.

Fischer A, Forsberg F, Lapisa, M, Bleiker S, Stemme G, Roxhed N, Niklaus F. Integrating mems and ics. Microsystems & Nanoengineering. 2015;1(Suppl 1):1-16.

Flagel L, Brandvain Y, Schrider DR. The unreasonable effectiveness of convolutional neural networks in population genetic inference. Molecular biology and evolution. 2019; 36: 220-238.

Goodfellow I, Bengio Y, Courville A. Deep Learning. 1st ed. Cambridge MA: MIT press; 2016, p: 98-164.

Kherif F, Latypova, A. Principal Component Analysis in Machine Learning. 1st ed. London: Academic Press; 2019, p:209-225.

Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. In Advances in neural information processing systems. 2012; 25:1097-1105.

Kumar V, Mind S. Feature selection: a literature reviews. SmartCR, 2014;4(Suppl 3):211-229.

Lapham AC, Bartlett RM. The use of artificial intelligence in the analysis of sports performance: A review of applications in human gait analysis and future directions for sports biomechanics. Journal of Sports Sciences. 1995;13: 229-237.

LeCun Y, Jackel LD, Boser B, Denker JS, Graf HP, Guyon I, Henderson D, Howard RE, Hubbard W. Handwritten digit recognition: Applications of neural network chips and automatic learning. IEEE Communications Magazine. 1989;27(Suppl 11):41-6.

Lin TH, Wang CC. Deep learning of spatio-temporal features with geometric-based moving point detection for motion segmentation. IEEE International Conference on Robotics and Automation (ICRA). 2014;1: 3058-3065.

Mancini R, Bruce C. Op Amps for Everyone. 5th ed. Oxford: Elsevier Inc; 2009, p10–11.

Newbold P. Statistics for Business Administration and Economy Çeviren: Ümit Şenesen. İşletme ve İktisat için İstatistik. 3. basım, Literatür Yayınları. İstanbul; 2000, s:777-785.

Ngoh KJ, Gouwanda D, Gopalai AA, Chong YZ. Estimation of vertical ground reaction force during running using neural network model and uniaxial accelerometer. *Journal of biomechanics*. 2018; 76:269-73.

Palermo E, Rossi S, Marini F, Patane F, Cappa P. Experimental evaluation of accuracy and repeatability of a novel body-to-sensor calibration procedure for inertial sensor-based gait analysis. *Measurement*. 2014;52:145- 55.

Petrillo CE, Tortora CR, Vernardos G, Koopmans LV, Verdoes KG, Bilicki M, Napolitano NR, Chatterjee S, Covone G, Dvornik A, Erben T. LinKS: discovering galaxy-scale strong lenses in the Kilo-Degree Survey using convolutional neural networks. *Monthly Notices of the Royal Astronomical Society*. 2019; 484(3):3879-96.

Prakash C, Kumar R, Mittal N. Recent developments in human gait research: parameters, approaches, applications, machine learning techniques, datasets and challenges. *Artificial Intelligence Review*. 2018;49(Suppl 1):1-40.

Sutton RS, Barto AG. Reinforcement learning: An introduction. 2nd ed. Cambridge: MIT press; 2018, p:1-13.

Tamura T. Wearable inertial sensors and their applications. In: *Wearable Sensors*. 1st ed. San Diego: Academic Press; 2014, p: 85- 104.

Tönük E. Yürüme ve hareket analizi sistemleri: teknik ayrıntılar. *Türk Ortopedi ve Travmatoloji Birliği Derneği (TOTBİD) Dergisi*. 2014;13:309-13.

Um TT, Pfister FM, Pichler D, Endo S, Lang M, Hirche S, Fietzek U, Kulić D. Data augmentation of wearable sensor data for parkinson's disease monitoring using convolutional neural networks. In *Proceedings of the 19th ACM International Conference on Multimodal Interaction*. 2017;216-220.

Vienne A, Barrois RP, Buffat S, Ricard D, Vidal PP. Inertial sensors to assess gait quality in patients with neurological disorders: a systematic review of technical and analytical challenges. *Frontiers in psychology*. 2017;8:817.

Wiering M, Van OM. Reinforcement learning. Adaptation, learning, and optimization. 1st ed. Berlin: Springer; 2012, p:3-73.

Yang J, Nguyen MN, San PP, Li X, Krishnaswamy S. Deep convolutional neural networks on multichannel time series for human activity recognition. In *Twenty-fourth international joint conference on artificial intelligence*. 2015; 1:3995:4001.

Zhao B, Lu H, Chen S, Liu J, Wu D. Convolutional neural networks for time series classification. *Journal of Systems Engineering and Electronics*. 2017;28:162-9.

Zheng Q, Yang M, Tian X, Jiang N, Wang D. A full stage data augmentation method in deep convolutional neural network for natural image classification. *Discrete Dynamics in Nature and Society*. 2020;1:1-11.

