



Automatic detection of developmental coordination disorder from power spectral densities of electroencephalography (EEG) signals using deep learning model

Hanife Göker*^{ID}

Vocational School of Health Services, Gazi University, 06830, Ankara, Türkiye

Highlights:

- Highlights Automatic early diagnosis system for developmental coordination disorder in children from EEG signals
- A comparative analysis based on machine learning and deep learning for developmental coordination disorder
- Calculation of power spectral density from EEG signals

Keywords:

- Deep learning,
- Developmental coordination disorder,
- EEG signal processing,
- Spectral analysis,
- Long-short-term memory networks

Article Info:

Research Article
Received: 26.04.2022
Accepted: 23.03.2024

DOI:

10.17341/gazimmfd.1109475

Correspondence:

Author: Hanife Göker
e-mail:
gokerhanife@gazi.edu.tr
phone: +90 505 299 8811

Graphical/Tabular Abstract

In the study, automatic detection of developmental coordination disorder is performed from power spectral densities of EEG signals using deep learning model. The implementation steps of the proposed model are given in Figure A. Feature vectors were extracted by calculating power density values using periodogram, multitaper, and welch spectral analysis methods. Then, the performances of the algorithms were compared.

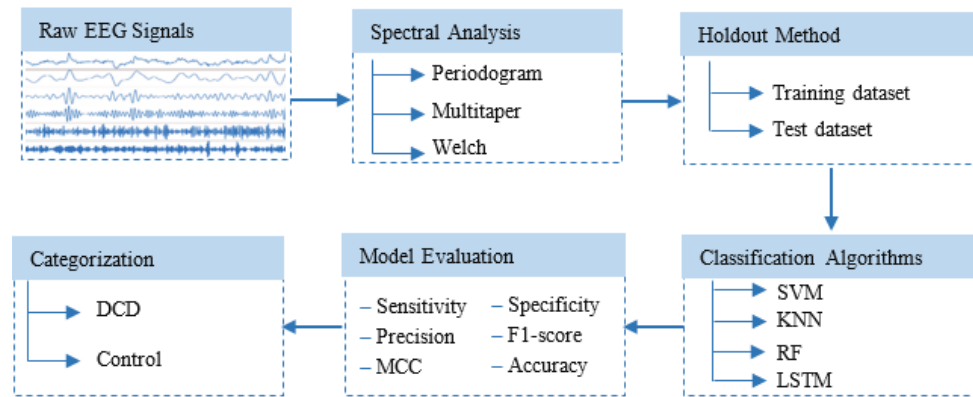


Figure A. Implementation steps of the proposed model

Purpose:

In this study, a deep learning model that efficiently combines welch spectral analysis method and LSTM deep network is presented to support expert opinion in detecting developmental coordination disorder in children from EEG signals.

Theory and Methods:

The dataset consists of EEG signals recorded from 16 children without developmental coordination disorder and 16 children with developmental coordination disorder. Three different feature vectors were created by calculating the power spectra of the frequencies between 1-49 Hz of the EEG signals with periodogram, multitaper, and welch spectral analysis methods. Using the created feature vectors, the performances of the support vector machine (SVM), random forest (RF), k-nearest neighbors (KNN) machine learning algorithms and long-short-term memory (LSTM) deep learning algorithm were compared.

Results:

The model with the highest performance is the classification model that efficiently combines the Welch spectral analysis method and the LSTM (97.20%) deep learning algorithm. The performance analysis results of the LSTM algorithm were calculated as 0.984 sensitivity, 0.959 specificity, 0.962 precision, 0.973 f1-score, 0.944 Matthews correlation coefficient, and 97.20% accuracy.

Conclusion:

Consequently, a comparative analysis of LSTM, SVM, KNN, and RF algorithms was performed using EEG signals in the early diagnosis of developmental coordination disorder. Experimental results show that the highest performance is achieved with the LSTM deep learning algorithm together with the Welch spectral analysis method. The study is a rare attempt in which a deep learning model is used in the effective diagnosis of automatic developmental coordination disorder by analyzing EEG signals and provides evidence of the superiority of deep learning algorithms over machine learning algorithms.



Elektroensefalografi (EEG) sinyallerinin güç spektral yoğunlukları kullanılarak gelişimsel koordinasyon bozukluğunun derin öğrenme modeli ile otomatik tespiti

Hanife Göker*

Gazi Üniversitesi, Sağlık Hizmetleri Meslek Yüksek Okulu, 06830, Ankara, Türkiye

Ö N E Ç I K A N L A R

- EEG sinyallerinden çocuklarda gelişimsel koordinasyon bozukluğu için otomatik erken tanı sistemi
- Gelişimsel koordinasyon bozukluğu için sınıflandırma algoritmalarının karşılaştırmalı bir analizi
- EEG sinyallerinden güç spektral yoğunluğunun hesaplanması

Makale Bilgileri

Araştırma Makalesi

Geliş: 26.04.2022

Kabul: 23.03.2024

DOI:

10.17341/gazimmfd.1109475

Anahtar Kelimeler:

Derin öğrenme,
gelişimsel koordinasyon
bozukluğu,
EEG sinyal işleme,
spektral analiz,
LSTM ağları

ÖZ

Gelişimsel koordinasyon bozukluğu, günlük aktivite ve akademik performansı önemli ölçüde engelleyen motor ve koordinasyon becerilerinin gelişiminde belirgin bir bozulma ile karakterize nöro-gelişimsel bir hastalıktır. Hastalığın doğru teşhisi kapsamlı testler ve uzun vadeli gözlemler gerektirmektedir. Bu testler ve gözlemler zaman alıcı, pahalı, eksik, yanlış ve sübjektif olabilir. EEG bu sınırlamaların üstesinden gelmek için güçlü bir adaydır. Bu çalışmada EEG sinyallerinden çocuklarda gelişimsel koordinasyon bozukluğunun tespitinde uzmanlara destek olmak amacıyla EEG tabanlı bir derin öğrenme modeli sunulmaktadır. Veriseti 16 gelişimsel koordinasyon bozukluğu olmayan ve 16 gelişimsel koordinasyon bozukluğu olan çocuktan kaydedilen EEG sinyallerinden oluşmaktadır. Periodogram, welch ve multitaper yöntemleri ile EEG sinyallerinin 1-49 hertz arasındaki frekanslarının güç spektral yoğunluk değerleri hesaplanarak, spektral analiz yöntemlerinin her biri için 49 özellik vektörü çıkarılmıştır. Daha sonra, destek vektör makinesi (SVM), rastgele orman (RF), k-en yakın komşu (kNN) ve uzun-kısa süreli bellek (LSTM) algoritmalarının performansları karşılaştırılmıştır. Deneyler sonrasında, welch ile LSTM algoritmasını bütünleştiren model, en yüksek performansı göstermiştir. Önerilen derin öğrenme modeli, %97,20 doğruluk, 0,984 duyarlılık, 0,959 özgüllük, 0,962 kesinlik, 0,973 f1-skoru ve 0,944 Matthews korelasyon katsayısı ile umut verici bir performans elde etmiştir.

Automatic detection of developmental coordination disorder from power spectral densities of electroencephalography (EEG) signals using deep learning model

H I G H L I G H T S

- Automatic early diagnosis system for developmental coordination disorder in children from EEG signals
- A comparative analysis based on machine learning and deep learning for developmental coordination disorder
- Calculation of power spectral density from EEG signals

Article Info

Research Article

Received: 26.04.2022

Accepted: 23.03.2024

DOI:

10.17341/gazimmfd.1109475

Keywords:

Deep learning,
developmental coordination
disorder,
EEG signal processing,
spectral analysis,
LSTM networks

ABSTRACT

Developmental coordination disorder is a neurodevelopmental disorder characterized by a marked deterioration in the development of motor and coordination skills that significantly impairs with daily activity and academic performance. Accurate diagnosis of the disease requires extensive testing and long-term observations. These tests and observations can be time-consuming, expensive, incomplete, inaccurate, and subjective. EEG is a strong candidate to overcome these limitations. In this study, an EEG-based deep learning model is presented to support experts in detecting developmental coordination disorder in children from EEG signals. The dataset consists of EEG signals recorded from 16 children without developmental coordination disorder and 16 children with developmental coordination disorder. By calculating the power spectral density values of frequencies between 1-49 hertz of EEG signals using periodogram, welch, and multitaper methods, 49 feature vectors were extracted for each of the spectral analysis methods. Then, the performances of support vector machine (SVM), random forest (RF), k-nearest neighbors (kNN) and long-short-term memory (LSTM) algorithms were compared. After the experiments, the model integrating welch and LSTM algorithm showed the highest performance. The proposed deep learning model achieved promising performance with 0.984 sensitivity, 0.959 specificity, 0.962 precision, 0.973 f1-score, 0.944 Matthews correlation coefficient, and 97.20% accuracy.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *gokerhanife@gazi.edu.tr / Tel: +90 505 299 8811

1. Giriş (Introduction)

Gelişimsel koordinasyon bozukluğu (GKB) motor koordinasyon problemlerini içeren nöro-gelişimsel bir hastalıktır [1]. Motor koordinasyon problemleri giyinme, yazma, yemek yeme ve öz bakım gibi günlük görevleri tamamlama becerilerine ve akademik başarılarına olumsuz etki eder [2]. GKB'nin tahmini prevalansı %2 ile %5 arasındadır [3]. Herhangi bir müdahale yapılmadığında, GKB'li çocukların tahminen %75'i bu güçlükleri ve sorunları yetişkinliğe kadar yaşamaya devam etmektedir [4]. Ayrıca GKB'li çocukların tipik gelişim gösteren akranlarına göre anksiyete ve depresyon belirtileri geliştirme riski daha yüksektir [5]. GKB fiziksel, psikolojik ve sosyal işlevsellik dahil olmak üzere birçok yaşam kalitesi alanını doğrudan etkilemektedir. Bu nedenle GKB'li çocuklar ev, okul ve topluluk ortamlarına akranlarından daha az katılmaktadır [6]. Aslında çocukların motor gelişimi zaman içinde izlendiğinde, motor gelişim sorunları erken bir aşamada fark edilebilir. Mevcut değerlendirme araçları zaman alıcıdır, uzman bir klinisyen gerektirir ve çocuklar için uzun izleme süreci sıkıcı ve zor bir durumdur. Motor gelişim sorunlarının erken bir aşamada fark edilmesi ve erken müdahale sayesinde problemin etkileri azaltılabilir [7]. Klinisyenlerin doğru tanımlayıcı tanı koymasına ve karar vermesine yardımcı olan her veri değerlidir [8].

GKB toplumda yüksek oranda görülmesine rağmen, motor bozukluğunun nasıl geliştiği, altında yatan nöral mekanizmalar ve etiolojisi hakkında çok az şey bilinmektedir. Bu durum GKB bulunan çocukların neden motor becerileri öğrenmekte zorlandıklarını ve en iyi müdahalenin ne olacağını anlamayı zorlaştırmaktadır [9]. GKB'nin mevcut değerlendirme yöntemleri, çocuklar bazı tasarlanmış görevleri yerine getirirken performansını puanlayan ergoterapistlerin ve fizyoterapistlerin gözlemsel analizine büyük ölçüde dayanmaktadır. Bununla birlikte, bu yöntemler pahalıdır, öznel ve daha geniş bir popülasyona yayılması kolay değildir [10]. Son yıllarda yapılan çalışmalar, nöro-görüntüleme tekniklerindeki gelişmeler GKB'nin etiolojisini açıklamaya yöneliktir. İleri nöro-görüntüleme teknikleri, beyin yapısı ve beynin işlevi hakkında ayrıntılı bilgilere ulaşılmasını ve nöral bağlantılarının daha iyi anlaşılabilmesini sağlamak amacıyla kullanılmaktadır. Ayrıca nöro-görüntüleme çalışmaları, GKB'li çocuklara uygulanan terapi amaçlı müdahalelerin seçilmesi işleminde ve bu müdahalelerin etkinliğinin değerlendirilmesi açısından da kritik önem taşımaktadır [11]. Hastalığın tespitinde uzman görüşünü desteklemek için fonksiyonel manyetik rezonans görüntüleme, manyetik rezonans görüntüleme, difüzyon tensör görüntüleme, EEG ve fonksiyonel yakın kızılötesi spektroskopisi gibi teknikler kullanılmaktadır [12]. Gelişmiş nörogörüntüleme tekniklerinin kullanımının artmasıyla birlikte, bu konuyu ele almak için birkaç manyetik rezonans görüntüleme çalışması yapılmıştır. Bu çalışmadan elde edilen bulgular, GKB bulunan çocukların işlevsel görevler esnasında beynin farklı bölgelerinin hareket geçtiğini ve normal gelişim gösteren akranlarına göre mikro yapıda farklılıkların bulunduğunu göstermektedir [9]. Ancak, bu nörogörüntüleme tekniklerden EEG, daha az maliyeti, daha az ekipman ihtiyacı, taşınabilirlik, basitlik ve noninvazivlik gibi ek avantajları nedeniyle klinikte en çok kullanılan tekniktir. EEG kullanılarak elde edilen bulgular klinikte günlük kullanım için kolaylıkla dışa aktarılabilir [13, 14]. Ayrıca bu teknik, çocuklar için manyetik rezonans görüntüleme, difüzyon tensör görüntüleme gibi diğer nörogörüntüleme tekniklerine göre daha uygulanabilir bir protokoldür [9]. Bu nedenle EEG, GKB'deki motor kontrolün ve bilişsel eksikliklerin nöro-fizyolojik temelini aydınlatmak için en yaygın olarak uygulanan yöntem olmuştur. Birçok teknikten elde edilen kanıtlardan farklı olarak EEG, en azından GKB'deki işleyen bellek görevleri sırasındaki nöral aktivite ile ilgili olarak, bulgularda tutarlılık sağlamıştır. EEG sinyalleri, GKB için bir

ön kanıt sağlasa da sinyal biyo-belirteçlerinin klinik faydasını daha iyi anlamak için yeni çalışmalar gerekmektedir [15]. GKB'nin mekanizmalarına ışık tutmak ve terapi yaklaşımlarının mantığını desteklemek için nöro-görüntüleme verilerini kullanarak geliştirilen uygulamalar önemlidir.

EEG sinyallerinden GKB'nin otomatik tanısı, diğer nörolojik hastalıkların tanısına kıyasla daha az araştırılan bir çalışma konusudur. Bununla birlikte ilgili literatürde EEG sinyalleri ve GKB arasındaki bağlantıyı araştıran çalışmalar mevcuttur. Genel olarak bu çalışmalar, GKB bulunan çocukların normal gelişim gösteren akranlarına göre benzer performans gösterdiğini ancak farklı EEG aktivasyon paternleri sergilediğini bildirmektedirler [16, 17]. Örneğin Zwicker vd. [18] tarafından yapılan çalışmada, GKB bulunan çocukların nöral bağlantılarında, nörogörüntüleme çalışmaları ile doğrulanabilecek farklılıklar olduğu rapor edilmiştir. Fong vd. [19], çalışmalarında GKB bulunan çocuklar ile tipik gelişim gösteren çocuklarda, çocukların motor performansları ile gerçek zamanlı EEG sinyalleri arasındaki ilişkiyi belirlemeyi amaçlamışlardır. 86 GKB ve 99 kontrol grubu olmak üzere toplam 185 örneklem büyüklüğü ile yaptıkları çalışmalarında, GKB bulunan çocukların motor görevler esnasındaki EEG sinyallerinin normal gelişim gösteren akranlarına göre daha düşük olduğu bulunmuştur. Tsai vd. [20], GKB bulunan çocukların kontrol grubundaki çocuklara göre tepki verme sürelerinin daha uzun ve EEG aktivasyonları daha düşük olduğunu belirtmektedir. Bununla birlikte, GKB'li çocuklar cevap verme ve değerlendirme süreçlerinde daha az çaba harcamaktadır ve yanlışları düzeltme de daha az nöral kaynağı devreye sokmaktadır [17]. Ek olarak, GKB bulunan çocuklarda sıklıkla görülen zayıf duyu-motor entegrasyonunun beyin aktivitesindeki farklılıklarla ilişkili olabileceği düşünülmektedir [21]. Mannini vd. [22], beyincikte oluşan hasar nedeniyle hareketi koordine edememe hastalığı olan ataksi, GKB ve kontrol grubunun sınıflandırılmasında gizli markov modeli ve SVM algoritmasını kullanmışlardır. Katılımcıların motorik hareket verileri sensörler yardımıyla kaydedilmiştir. Kontrol, GKB ve ataksin sınıflandırılmasında sırasıyla %80, %85,7 ve %70 doğrulukla tespit etmişlerdir. EEG sinyallerinin kullanılarak GKB'nin otomatik tanısına yönelik tek çalışmaya rastlanmıştır. Buettner vd. [23] çalışmalarında, EEG sinyallerini kullanarak GKB'nin makine öğrenmesi tabanlı tanısında hızlı Fourier dönüşümü (FFT) ve RF algoritmasını kullanarak %99,35 bir doğruluk oranı ile EEG sinyallerinden GKB'li ve normal gelişim gösteren çocukları sınıflandırdıklarını raporlamışlardır. GKB'nin tanısında EEG sinyallerinden farklı giriş verilerinin de kullanıldığı çalışmalarda mevcuttur. Cignetti vd. [24] GKB'nin tanısında fonksiyonel manyetik rezonans görüntülerini kullanmışlardır. Verilerin analizinde Fisher dönüşümünü, Bold zaman serilerini ve Çoklu Kernel Öğrenme (Multiple-Kernel Learning) algoritmasını kullanarak %57,50 doğruluk elde etmişlerdir. Li vd. [25] giriş verisi olarak 23 çocuktan ince motor görevleri esnasında kaydedilen 6000 motorik hareket görüntülerini kullanmışlardır. VGG-16 algoritması ile % 95,74 doğruluk, ResNetV2-50 %94,98 doğruluk ve DenseNet-121 ile %96,89 doğruluk elde etmişlerdir. Ayrıca EEG sinyallerinin analiz edilmesinde derin öğrenme giderek daha popüler bir yaklaşım haline gelmiştir. İlgili literatür incelendiğinde welch spektral analiz yöntemi ve LSTM derin öğrenme algoritmasının, dikkat eksikliği ve hiperaktivite bozukluğu [26], majör depresif bozukluğu [27], epilepsi nöbetleri [28], şizofreni [29], Alzheimer [30] gibi birçok nörolojik hastalıkların EEG tabanlı otomatik tespitinde yaygın olarak kullanıldığı ve başarılı sonuçlar elde ettiği görülmektedir. EEG sinyallerinden GKB'nin otomatik tanısına yönelik çalışma sayısının azlığı, GKB'nin sınıflandırılmasına yönelik çalışmaların tekrarlanması ve sonuçlarının karşılaştırılması gerektiğini de ortaya çıkarmaktadır. GKB, gelişimsel dönemin başlangıcından itibaren mevcut olmasına rağmen genellikle okul çağına kadar tespit

edilemediği ve erken müdahale için fırsatlar kaçırıldığı [31] dikkate alındığında GKB'nin zamanında ve objektif teşhisi önemlidir. Bildiğimiz kadarıyla, EEG sinyallerinden GKB'nin tanısında derin öğrenme modeli ilk kez kullanılmaktadır.

Bu çalışmada, EEG sinyallerinden GKB'nin otomatik tanısında spektral analiz yöntemlerini ve LSTM sınıflandırma algoritmasını kullanan bir derin öğrenme modeli önerilmektedir. Çalışmanın ana katkıları aşağıdaki gibidir:

- EEG sinyallerinden GKB'nin hastalığının erken tanısında welch spektral analiz metodu ve LSTM derin ağını verimli bir şekilde birleştiren otomatik sınıflandırma modeli otomatik tanı ve tedavide bu alandaki uzmanlara destek olabilir.
- En iyi sınıflandırma performansını belirlemek için periodogram, multitaper ve welch spektral analiz metotları ile hesaplanan güç spektral yoğunlukları kullanarak geleneksel makine öğrenmesi algoritmaları ile derin öğrenmesi algoritması karşılaştırılmıştır.
- EEG sinyallerinden GKB'nin erken ve objektif tanısı, erken müdahale için fırsatlar sunmaktadır.

2. Materyal ve Metot (Material and Method)


2.1. Önerilen Metot (Proposed method)

Çalışmada GKB'nin otomatik tanısında kullanılmak üzere EEG tabanlı derin öğrenme modeli önerilmektedir. periodogram, multitaper ve welch spektral analiz yöntemleri ile 1-49 hertz arasındaki frekanslarına ait güç yoğunlukları değerleri hesaplanarak öznitelik vektörleri oluşturulmuştur. Oluşturulan öznitelik vektörleri kullanarak EEG tabanlı GKB'nin sınıflandırılmasında LSTM, SVM, kNN ve RF sınıflandırma algoritmalarının performansları karşılaştırılmıştır. Önerilen modelin uygulama süreci Şekil 1'de verilmiştir:

2.2 Veriseti (Dataset)

Bu çalışmada, Vařeka vd. [32] tarafından 7-10 yaşlarında 21 erkek ve 11 kadın olmak üzere 32 (16 GKB olmayan (kontrol grubu) ve 16 GKB) okul çocuğundan kaydedilen EEG sinyalleri kullanılmıştır. Bilgilendirilmiş onam katılımcıların yasal varisleri tarafından imzalanmıştır. Tüm çocuklar sağ elini kullanmaktadır. Deneysel prosedürde katılımcı ses geçirmez bir kabine alınmıştır ve her katılımcıya bir kulaklık verilmiştir. Verilerin toplanması sırasında çocuklardan duydukları ses ve ekranda gördükleri resimlere göre diğer düğmelerden bir düğmeye basarak bir uyarana yanıt vermeleri istenmiştir. Ekranda gösterilen resimler, doğru sesleriyle ve bazen

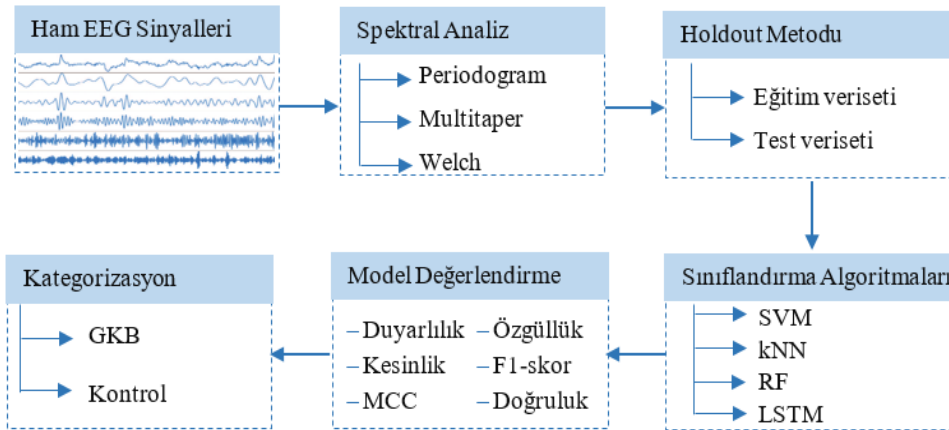
yanlış seslerle ilişkilendirilen kedi, köpek ve keçi olmak üzere üç hayvandır. Böylece ilk düğme havlayan bir köpeğe, ikinci miyavlayan kediyeye ve diğer düğme ise köpek miyavlaması gibi yanlış hayvanla ilişkili yanlış sese aittir. EEG sinyalleri Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1 ve O2 bölgelerine yerleştirilmiş 19 elektrotlu BrainAmp DC cihazı ile 1 kilohertz örnekleme frekansı kullanılarak kaydedilmiştir. Bununla birlikte orijinal verisinde ham EEG sinyalleri 0,1 ve 250 hertz kesme frekanslarına sahip bir analog bant geçiren filtre kullanılarak filtrelenmiştir. Şekil 2'de uluslararası 10-20 sistemine göre elektrotların yerleşim düzeni ve etiketleri gösterilmektedir [32].



Şekil 2. Uluslararası 10-20 sisteminde elektrotların etiketleri (The labels of electrodes at the international 10-20 system)

2.3. Sinyal İşleme (Signal Processing)

Sinyal işleme basamağında öznitelik çıkarımı ve veri artırımı gerçekleştirilmiştir. Öznitelik çıkarımı ham EEG sinyalleri üzerinde boyut azaltmak amacıyla yapılmıştır. Öznitelik çıkarımı sadece boyut azaltma yaparak arama uzayını küçültmek ile kalmaz, aynı zamanda işlem karmaşıklığını da azaltarak sınıflandırma kalitesini de artırır. EEG sinyallerinin 1-49 hertz arasındaki frekanslarına ait güç yoğunluk değerlerinin hesaplanmasında periodogram, multitaper ve welch olmak üzere üç farklı spektral analiz yöntemi kullanılmıştır.



Şekil 1. Önerilen modelin uygulama süreci (Implementation process of the proposed model)

2.3.1. Spektral analiz (Spectral analysis)

Spektral analiz yöntemleri, durağan rastgele ve sonlu uzunluğa sahip bir sinyalin frekans bandı üzerinde nasıl dağıldığını göstermektedir. Sinyallerin gücünün frekans uzayındaki dağılımını belirlemek ve karakteristiğini yorumlamak amacıyla uygulanmaktadır. Spektral analizde sinyale ait tekrarlanan ve gizli olan davranışların ortaya çıkarılması amaçlanmaktadır [33]. Güç spektral yoğunluğu, bir sinyalin frekans aralığı üzerindeki güç dağılımını tanımlar. Güç spektral yoğunluğunu tahmin etmek için periodogram, welch ve multitaper spektral analiz yöntemleri yaygın olarak kullanılmaktadır. Bu çalışmada, üç farklı spektral analiz yönteminin kullanıldığı üç deney gerçekleştirilmiştir. Başka bir deyişle, deney 1’de periodogram yöntemi kullanılarak 49 öznitelik, deney 2’de welch yöntemi kullanılarak 49 öznitelik ve deney 3’de multitaper yöntemi kullanılarak 49 öznitelik çıkarılmıştır ve bu öznitelik çıkarma yöntemlerinin performansları karşılaştırılmıştır. Spektral analiz yöntemleriyle öznitelik çıkarma işleminde, EEG sinyalleri için güç spektral yoğunlukları 1-49 hertz (yaklaşık 50 hertz) arasındaki frekans değerlerine kadar [26, 34-36] anlamlı öznitelikler çıkardığı görülmektedir. Bu çalışmada, bu nedenle EEG sinyallerinin 1-49 hertz arasındaki frekanslarına ait güç yoğunluk değerleri her bir deneyde farklı spektral analiz yöntemi ile hesaplanarak, her bir deney için ayrı ayrı 49 öznitelik vektörü oluşturulmuştur.

2.3.1.1. Periodogram metodu (Periodogram method)

Periodogram yöntemi, spektral analiz yöntemlerinin en basit halidir. Periodogram, doğrudan EEG sinyallerine uygulanır. Bunun nedeni, EEG sinyali hakkında bir varsayım olmamasıdır. Periodogram yöntemi, sinyallerin güç spektral yoğunluklarının çıkarılmasının en temel şeklidir [37].

$$\hat{\vartheta}_{(w)} = \frac{1}{N} \left| \sum_{t=1}^N y(t) e^{-j\omega t} \right|^2 \quad (1)$$

Eş. 1’deki $\vartheta(w)$ güç spektral yoğunluğunu, N sinyalin örnek sayısını, w’da güç spektral yoğunluğu olan frekansını ifade etmektedir.

2.3.1.2. Multitaper metodu (Multitaper method)

Multitaper metodu, bir sinyalde bulunan bilgiyi frekans uzayına taşıyarak güç spektral yoğunluğunu elde etmek için kullanılır. Güç spektral yoğunluğu, bir sinyalin ortalama gücünün, sinyaldeki belirli frekans değerlerine dağıtılmasıyla oluşturulur [38]. Multitaper yönteminde güç spektral yoğunluğunun hesaplanması Eş. 2’de verilmiştir [39].

$$\hat{\vartheta}_{(w)} = \left| \sum_{n=1}^K h_{K-n} y(n) e^{-j\omega n} \right|^2 \quad (2)$$

Eş. 2’deki K kullanılacak filtre sayısını ve h_{K-n} filtre dürtüsünü (filter impulse) ifade etmektedir.

2.3.1.3. Welch metodu (Welch method)

Welch metodunda, sinyalin üst üste binen pencerelerinin periodogramlarının ağırlıklı toplamını bulan parametrik olmayan bir hesaplama şeklidir. Bu yaklaşımda sinyal, örtüşen segmentler oluşturmak için pencerelenir. Daha sonra her segment için ayrı Fourier dönüşümünün kare boyutu belirlenir. Son olarak, ayrılan her segment için ortalama güç spektral yoğunlukları alınarak welch periodogramları oluşturulur [40]. Tüm verinin tek bir periodogram kestirimine göre, iyileştirilmiş periyodogramların ortalaması varyansı azaltmaktadır. Segmentin uzunluğu arttıkça güç spektral yoğunluğu daha düz (smooth) olmaktadır [41]. Welch yönteminde güç spektral yoğunluğunun hesaplanması Eş. 3’de verilmiştir [42].

$$\hat{I}_{xx}^W(\omega) = \frac{1}{P} \sum_{p=0}^{P-1} \hat{I}_{xx}^p(\omega). \quad (3)$$

Eş. 3’de, P pencerelenmiş segmentlerin sayısını, $\hat{I}_{xx}^p(\omega)$ pencereli segment başına hesaplanan periodogramı ve $\hat{I}_{xx}^W(\omega)$ periodogramların ortalamasını göstermektedir. Bu çalışmada, welch metodu periodogram ve multitaper yöntemlerine kıyasla daha yüksek bir performans elde etmiştir. Welch metodunun daha az varyansa sahip olması, daha az işlem yükü getirmesi, daha yumuşak bir spektrum oluşturması, giriş verileri hakkında herhangi bir varsayımda bulunmaması, her türlü sinyale uygulanabilir olması ve yüksek performans sağlaması gibi avantajları nedeniyle oldukça popüler bir spektral analiz metodudur [40-42].

2.3.2. Veri artırımı (Amplifying augmentation)

Derin öğrenme algoritmalarının performansı veri miktarı arttıkça daha fazla iyileşir. Bu nedenle, veri artırımı (amplifying augmentation) metodu kullanılarak öznitelik vektör sayıları artırılmıştır. Veri artırımı yapılmasının temel amacı modeli yeterince veri ile destekleyerek daha isabetli tahminler yapmasını sağlamaktır. Veri artırımı modelin ezberleme (overfitting) problemini ortadan kaldırır. Veri artırımı metodu kullanılarak veriler 0,98 ve 1,02 faktörleriyle çarpılmıştır. Böylece veri sayısı üç kat artırılmıştır. Bu çarpmalar, elektrot-doku empedansı gibi faktörlere bağlı olarak beyin dalgalarının genliğinde meydana gelen varyasyonları temsil etmektedir [43, 44].

2.4. Verisetinin Eğitim ve Test Verisetlerine Ayrılması (Splitting Dataset into Training and Testing)

EEG veriseti eğitim ve test verisetlerine ayrılırken Holdout metodu kullanılmıştır. Holdout metodunda, belirli bir oranda örnek test veriseti olarak ayrılır, geriye kalan veriler eğitim veriseti olarak kullanılmaktadır. Model eğitim veriseti kullanılarak eğitilir ve test veriseti kullanılarak modelin performansı değerlendirilir. Holdout yöntemi, büyük bir veri kümesine sahip olduğunuzda kullanışlıdır. Eğer her sınıfı temsil eden veri sayısı var ve veriseti dengeli dağılımı ise bu yöntem kullanılabilir [45]. Çalışmada her sınıfa ait temsil sayısı yeterli ve dengeli dağılmaktadır. Veriseti 32 kişiden 19 kanal ile dinlenme durumunda kaydedilen EEG sinyallerini içermektedir (32 kişi x 19 kanal x 1 dinlenme durumu= 608). Çalışmada veri artırımı metodu kullanılmış ve veri sayısı üç kat artırılmıştır. Sonuç olarak verisetindeki toplam veri sayısı 1824’dür. Verisetinin 1/3’ü test veriseti (608) ve 2/3’ü eğitim veriseti (1216) olarak belirlenmiştir. Veriseti eğitim ve test verisetlerine ayrıldıktan sonra test veriseti dışarda tutularak model eğitim veriseti ile eğitilmiştir. Test için ayrılan 1/3’lük veri (608) ile SVM, kNN, RF ve LSTM sınıflandırma algoritmaları kullanılarak model kontrol edilmiştir.

2.5. Sınıflandırma (Classification)

Sınıflandırma benzer özelliklerdeki verilerin önceden etiketlenmiş veri gruplarından hangisine ait olduğunun tahmin edilmesi işlemidir. Çalışmada periodogram, multitaper ve welch spektral analiz yöntemleri kullanılarak EEG sinyallerinin 1-49 hertz arasındaki frekanslarına ait güç yoğunluk değerleri hesaplanarak öznitelik vektörü oluşturulmuştur. Bu öznitelik vektörleri kullanılarak derin öğrenme ve makine öğrenmesi sınıflandırma algoritmaları çalıştırılmıştır. Çalışmada performansları karşılaştırılan sınıflandırma algoritmaları seçiminde literatürde yaygın olarak kullanılan SVM, kNN ve RF makine öğrenmesi algoritmaları ve LSTM derin öğrenme sınıflandırma algoritması kullanılmıştır. Çalışmada en yüksek başarımları gösteren LSTM derin ağı algoritmasıdır. Bu nedenle, bu algoritmanın matematiksel temelleri 2.5.1’de verilmiştir.

2.5.1. LSTM derin ağı (LSTM deep network)

Uzun-kısa süreli hafıza ağları, yinelenen sinir ağlarının (Recurrent Neural Network-RNN) özel bir türüdür. RNN, ağıın mevcut ve gelecekteki girdiler üzerindeki performansını iyileştirmek için geçmişin bilgilerini kullanan bir derin öğrenme ağı yapısıdır. Ağı gizli durumlardan ve geri beslemeli döngülerden oluşmaktadır. Döngü yapısı, ağıın geçmiş bilgileri gizli durumda saklamasına ve diziler üzerinde çalışmasına izin vermektedir. Bu nedenle RNN uzun vadeli dizi bağımlılığı ve gerileyen gradyan sorununu ele alamamaktadır. RNN'ler büyük verilerde gördüklerini unutabilir, bir başka deyişle kısa süreli bir hafızaya sahip olurlar [46]. LSTM hücreleri sadece şimdiki girişleri işlemez hafızasında tuttuğu geçmiş verileri de işlemektedir. Geçmiş durumları hatırlamak ve bu durumların kullanılıp kullanılmayacağına karar vermek için LSTM hücresi kapı birimleri içerir. Bu kapılar, giriş kapısı (input gate), yedekleme kapısı (candidate gate), unutma kapısı (forget gate) ve çıkış kapısıdır (output gate). LSTM yapısı içerisindeki bu kapılar hangi girdinin hatırlanması veya unutulması gerektiğini belirlemektedir. Gelen girdi önemsizse unutulur, önemliyse bir sonraki aşamaya aktarılır. Böylece LSTM algoritması gerileyen gradyan sorununun ve uzun vadeli dizi bağımlılığının üstesinden gelir [47]. Bu nedenle LSTM derin öğrenme modeli son yıllarda sinyal analizinde yoğun olarak kullanılmaktadır. LSTM kısa ve uzun süreli hafıza birimlerine sahip olduğundan sinyal sınıflandırma çalışmalarında diğer yöntemlere göre daha başarılı sonuçlar göstermektedir [46]. Şekil 3'de LSTM hücresi gösterilmiştir:

Giriş kapısı, önceki katmanlardan verileri toplamaktadır. Yedekleme kapısı, aktivasyon fonksiyonuna (sigmoid) göre yeni katsayıyı hesaplar ve unutma fonksiyonunun yeni durumunu belirler. Unutma fonksiyonu önceki hücre durumlarının ne derece kullanılacağını belirtir. 0 unutma anlamındadır, 1 tüm veri kullanılacağını gösterir ve 0 ile 1 arasındaki değer önceki hücre durumlarını belli derece kullanılacağını göstermektedir [48]. Şekil 3'de sunulan LSTM hücresindeki tüm kapıların davranışını tanımlayan eşitlikler (Eş. 4-Eş. 10) verilmiştir [49]:

$$i_t = \sigma(W_{hi}h_{t-1} + W_{xi}x_t + b_i) \quad (4)$$

$$f_t = \sigma(W_{hf}h_{t-1} + W_{xf}x_t + b_f) \quad (5)$$

$$o_t = \sigma(W_{ho}h_{t-1} + W_{xo}x_t + b_o) \quad (6)$$

$$C_t = \tanh(W_{hc}h_{t-1} + W_{xc}x_t + b_c) \quad (7)$$

$$C_t = \sigma(f_t \otimes C_{t-1} + i_t \otimes C_t) \quad (8)$$

$$h_t = \tanh(C_t) \otimes o_t \quad (9)$$

$$y_t = h_t \quad (10)$$

W, önceki gizli katman ile mevcut gizli katman arasındaki yinelenen bağlantıdır. U, girdileri gizli katmana bağlayan ağırlık matrisidir. C, mevcut girdiye ve önceki gizli duruma göre hesaplanan aday bir gizli durumdur. C, önceki belleğin unutma kapısı ile çarpımı ve yeni hesaplanan gizli durumun giriş kapısı ile çarpılmasının bir kombinasyonu olan birimin dahili belleğidir.

2.6. Modelin Değerlendirilmesi (Model Evaluation)

Modelin performansının test edilmesinde kullanılan en temel başarımlar ölçütleri duyarlılık, doğruluk, kesinlik, f1 skor, Matthews korelasyon katsayısı (MCC) ve özgüllük değerleridir. Bu değerler doğru sınıfa ve yanlış sınıfa dahil edilen örnek sayılarına göre hesaplanmaktadır. Doğru pozitif (TP) ve doğru negatif (TN) değerleri sınıfları doğru etiketlenen örneklerin sayılarını gösterirken yanlış pozitif (FP) ve yanlış negatif (FN) değerleri sınıfları yanlış etiketlenen örneklerin sayılarını göstermektedir [50]. Bu değerler karışıklık matrisini oluşturmaktadır. Karışıklık matrisindeki bu değerler kullanılarak model başarımlarını hesaplanmaktadır. Çalışmada önerilen modelin performansının test edilmesinde kullanılan model başarımlar kriterleri verilmiştir (Eş. 11- Eş. 16):

$$\text{Doğruluk (Accuracy)} = (TN + TP) / (TN + FP + TP + FN) \quad (11)$$

$$\text{Duyarlılık (Recall)} = TP / (FN + TP) \quad (12)$$

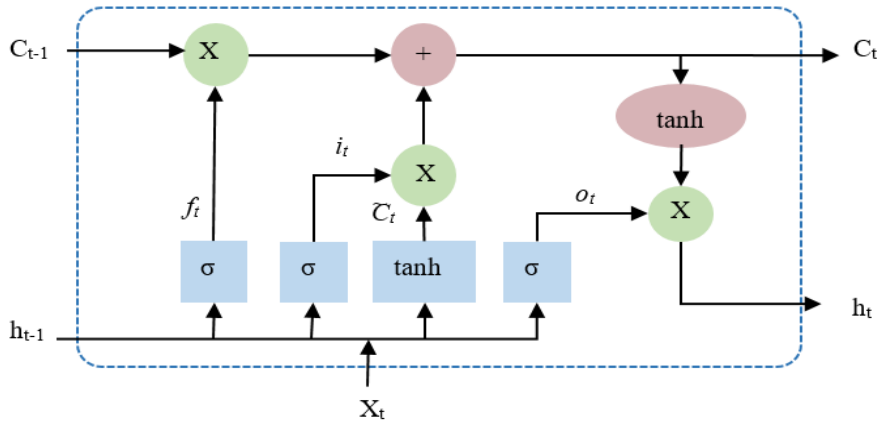
$$\text{Kesinlik (Precision)} = TP / (FP + TP) \quad (13)$$

$$\text{F1 skoru (F1-score)} = 2 \times \text{Duyarlılık} \times \text{Kesinlik} / (\text{Duyarlılık} + \text{Kesinlik}) \quad (14)$$

$$\text{MCC} = (TP \times TN - FN \times FP) / \sqrt{(FP + TP) \times (TN + FN) \times (FN + TP) \times (TN + FP)} \quad (15)$$

$$\text{Özgüllük (Specificity)} = TN / (TN + FP) \quad (16)$$

Bu değerlerin 1'e yakın olması geliştirilen modelin tesadüfi bir sonuç elde etmediğini ve sistemin başarısının yüksek olduğunu göstermektedir.



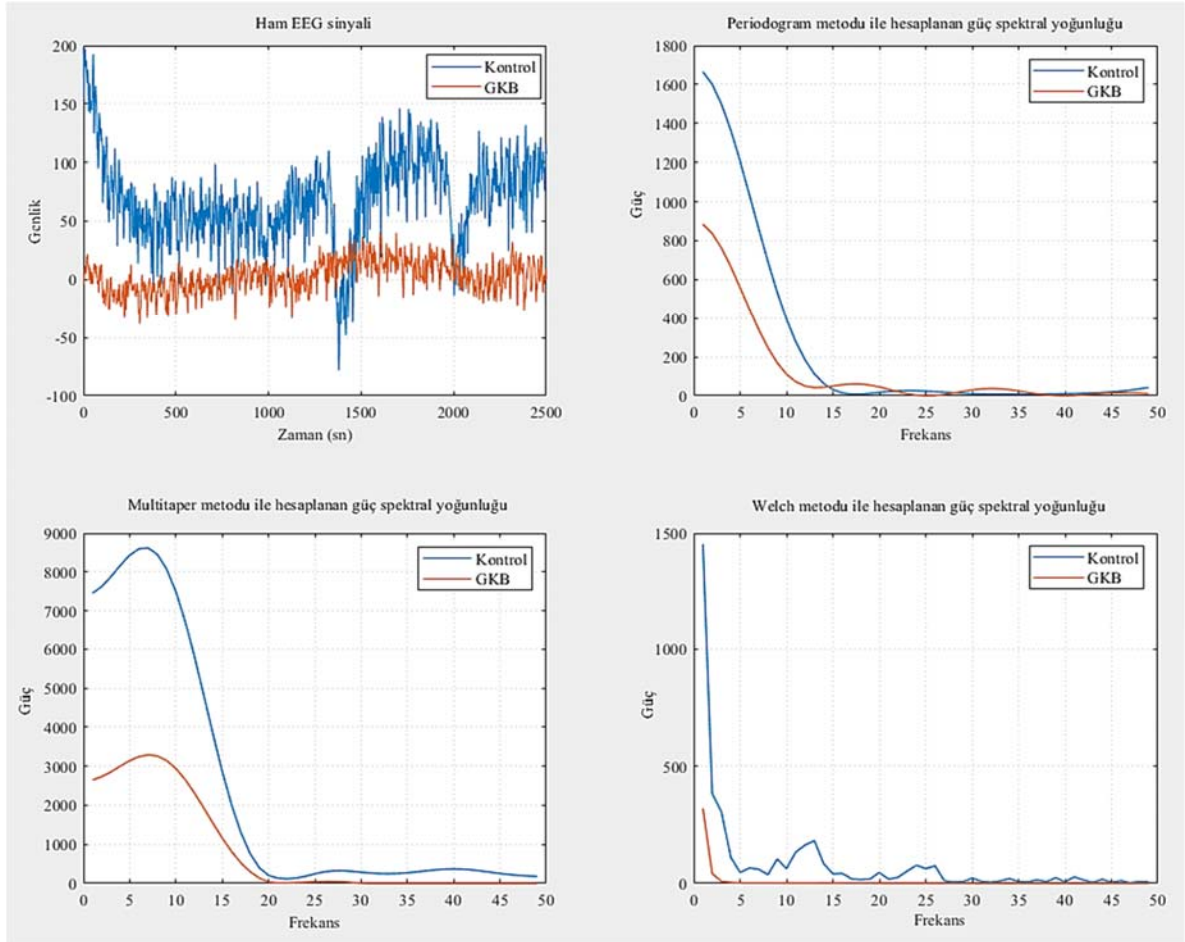
Şekil 3. LSTM bloğunun yapısı (Structure of the LSTM block)

3. Deneysel Sonuçlar (Experimental Results)

Bu çalışmada, EEG sinyallerinin farklı spektral analiz yöntemleri ile hesaplanan güç spektral yoğunlukları kullanılarak GKB'nin otomatik tespitine yönelik SVM, kNN ve RF makine öğrenmesi algoritmaları ve LSTM derin öğrenme algoritmasının performansları karşılaştırılmıştır. 16 kontrol ve 16 GKB'li olmak üzere 32 okul çağındaki çocuklardan kaydedilen EEG sinyallerinin 1-49 hertz arasındaki frekanslarına ait güç spektral yoğunlukları periodogram, welch ve multitaper spektral analiz yöntemleri kullanılarak hesaplanmıştır. Welch metodunda pencere uzunluğu, veri boyutunun $\frac{1}{4}$ ' ü, "noverlap" parametresi pencere uzunluğunun $\frac{1}{2}$ 'si kadar seçilmiştir. GKB'li ve kontrol gruplarına ait ham 10 saniyelik EEG sinyalleri, periodogram, multitaper ve welch metodları kullanılarak elde edilen güç spektral yoğunlukları Şekil 4'de verilmiştir:

Çalışmada periodogram, welch ve multitaper metodları kullanılarak üç ayrı deney gerçekleştirilmiştir. Tüm deneylerde LSTM hiperparametreleri sırasıyla "MaxEpochs" değeri 1000, "MiniBatchSize" değeri 384, "InitialLearnRate" 0,001, "SequenceLength" 1000 ve "GradientThreshold" 1 olarak seçilmiştir. Optimizasyon yöntemi olarak ise adam yöntemi kullanılmıştır. SVM algoritmasının "KernelFunction" değeri "rbf" ve kNN algoritmasının k değeri 3 olarak seçilmiştir. Farklı spektral analiz yöntemleri kullanılarak performansları karşılaştırılan makine öğrenmesi ve derin öğrenme sınıflandırma algoritmalarına ait karışıklık matrisinde yer alan parametreler Tablo 1'de verilmiştir.

Tablo 1 incelendiğinde tüm deneylerde doğru olarak sınıflandırılan veri sayısının en yüksek olduğu sınıflandırma algoritmasının LSTM derin ağı algoritması olduğu görülmektedir. LSTM algoritmasına ait



Şekil 4. Ham EEG sinyalleri ve güç spektral yoğunluk değerleri (The raw EEG signals and power spectral density values)

Tablo 1. Güç spektral yoğunluk değerlerine göre sınıflandırma algoritmalarının karışıklık matrisi
(Confusion matrix of classification algorithms according to power spectral density values)

Deneyler	Etiket	RF			kNN			SVM			LSTM		
		GKB	Kontrol	TP+TN	GKB	Kontrol	TP+TN	GKB	Kontrol	TP+TN	GKB	Kontrol	TP+TN
Deney 1 (Periodogram)	GKB	273	21	554	256	38	554	264	30	554	279	15	568
	Kontrol	33	281	554	26	288	554	34	280	554	25	289	568
Deney 2 (Multitaper)	GKB	269	10	584	260	19	576	266	13	569	277	2	588
	Kontrol	14	315	584	13	316	576	26	303	569	18	311	588
Deney 3 (Welch)	GKB	295	26	560	278	43	543	272	49	515	309	12	591
	Kontrol	22	265	560	22	265	543	44	243	515	5	282	591

karışıklık matrisi incelendiğinde, Deney 1’de doğru sınıflandırılan toplam örnek sayısının (TP+TN) 568, Deney 2’de doğru sınıflandırılan toplam örnek sayısının 588 ve Deney3’de doğru sınıflandırılan toplam örnek sayısının 591’dir. Welch metodu kullanılarak çıkarılan öznelik vektörleri ile LSTM derin öğrenme ağının kullanıldığı Deney 3 sonuçları, en yüksek doğru sınıflandırılan örnek sayısına sahiptir.

Sınıflandırma algoritmalarına ait karışıklık matrisinden elde edilen bu niceliklerle duyarlılık, özgüllük, kesinlik, f1- skoru, MCC ve doğruluk model başarımları ölçütleri hesaplanmaktadır. Modellerin performansları, bu başarımları ölçütleri kullanılarak değerlendirilmektedir. Deneylere göre, makine öğrenmesi ve derin öğrenme sınıflandırma algoritmalarının performans sonuçları Tablo 2’de verilmiştir:

Tablo 2’de doğruluk oranları incelendiğinde en yüksek başarımları Welch metodu ile elde edilen güç spektral yoğunluğu değerlerinin kullanıldığı LSTM sınıflandırma algoritmasına aittir. Deney 3’te LSTM algoritmasına ait performans analizi sonuçları 0,984 duyarlılık, 0,959 özgüllük, 0,962 kesinlik, 0,973 f1 skoru, 0,944 MCC ve %97,20 doğruluk olarak hesaplanmıştır. Model başarımları ölçütlerine ait değerlerin 1’e yakın olması gerekir. Bu değerlerin 1’e yakın olması modelin tesadüfi bir başarıya sahip olmadığını göstermektedir [51]. Sınıflandırma modellerinin eğitim süreleri ve test sürelerinin karşılaştırma süreleri Tablo 3’de verilmiştir:

LSTM derin öğrenme algoritması deneylerde en yüksek başarımları gösteren algoritmadır. Tablo 3’de sınıflandırma modellerinin eğitim süreleri ve test süreleri incelendiğinde, beklenen bir şekilde LSTM derin öğrenme algoritmasının diğer geleneksel makine öğrenmesi

algoritmalarına kıyasla daha uzun olduğu görülmektedir. LSTM derin öğrenme algoritmasının deneylerdeki eğitim süreleri incelendiğinde; periodogram spektral analiz metodu ile çıkarılan öznelik vektörlerinin kullanıldığı deney 1’de 1550,2239 saniye, multitaper metodu ile çıkarılan öznelik vektörlerinin kullanıldığı deney 2’de 1314,6602 saniye ve welch metodu ile çıkarılan öznelik vektörlerinin kullanıldığı deney 3’de ise 1354,9500 saniyedir. Deneylerde LSTM derin öğrenme algoritmasının eğitim ve test süreleri arasındaki farklılığın düşük düzeyde olduğu görülmektedir. Welch ve LSTM derin öğrenmesi yaklaşımının, periodogram ve multitaper spektral yaklaşımlarına göre daha yüksek başarımları elde ettiği dikkate alındığında, eğitim ve test sürelerindeki bu farklılıkların çok yüksek olmaması nedeniyle rahatlıkla göz ardı edilebileceği söylenebilir. Şekil 5’de spektral analiz yöntemlerine göre makine öğrenmesi ve derin öğrenme sınıflandırıcılarının doğruluk oranları verilmiştir.

Derin öğrenme modeli olan LSTM algoritması, üç spektral analiz yönteminde de en yüksek başarımları göstermiştir. LSTM derin öğrenme ağının yüksek sınıflandırma başarımlarında, veri sayısının yüksek olması önemli bir etmendir. RF, kNN ve SVM makine öğrenmesi algoritmalarının başarımları LSTM derin öğrenme algoritmasına göre sınıflandırmada yetersiz kalmıştır.

4. Tartışma (Discussion)

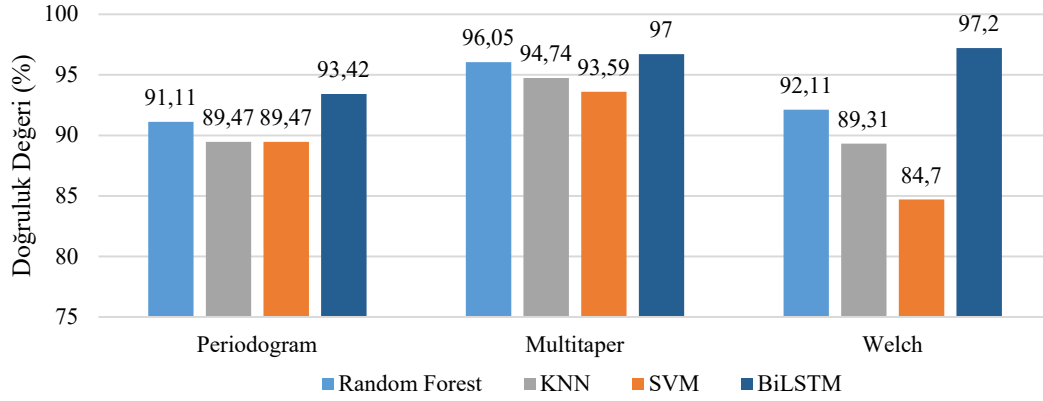
Bu çalışmada, EEG sinyallerinden GKB’nin otomatik tanısında Welch spektral analiz yöntemi ile LSTM sınıflandırma algoritmasını kullanan bir derin öğrenme modeli geliştirilmiştir. GKB’nin tanısının mevcut değerlendirilmesinde manuel testler veya önceden tasarlanmış görevleri yerine getirirken çocukların performanslarının puanlanması

Tablo 2. Sınıflandırma algoritmalarının performansları (Performance of classification algorithms)

Deneyler	Sınıflandırma modelleri	Model performans değerlendirme					
		Duyarlılık	Özgüllük	Kesinlik	F1- skoru	MCC	Doğruluk
Deney 1 (Periodogram)	RF	0,892	0,930	0,928	0,910	0,823	91,11
	kNN	0,907	0,883	0,870	0,888	0,789	89,47
	SVM	0,885	0,903	0,898	0,891	0,789	89,47
	LSTM	0,917	0,950	0,949	0,933	0,868	93,42
Deney 2 (Multitaper)	RF	0,950	0,969	0,964	0,957	0,920	96,05
	kNN	0,952	0,943	0,931	0,942	0,894	94,74
	SVM	0,911	0,958	0,953	0,931	0,872	93,59
	LSTM	0,939	0,993	0,992	0,965	0,935	96,71
Deney 3 (Welch)	RF	0,930	0,910	0,919	0,924	0,841	92,11
	kNN	0,926	0,860	0,866	0,895	0,788	89,31
	SVM	0,860	0,832	0,847	0,854	0,693	84,70
	LSTM	0,984	0,959	0,962	0,973	0,944	97,20

Tablo 3. Sınıflandırma modellerinin eğitim ve test sürelerinin karşılaştırılması (Comparison of training and testing times of classification models)

Deneyler	Sınıflandırma modelleri	Eğitim Süresi (saniye) (Verilerin 2/3’ü)	Test Süresi (saniye) (Verilerin 1/3’ü)
Deney 1 (Periodogram)	RF	0,7442	0,0796
	kNN	0,1897	0,0968
	SVM	8,4148	0,0757
	LSTM	1550,2239	0,5813
Deney 2 (Multitaper)	RF	0,3771	0,0494
	kNN	0,0847	0,0686
	SVM	9,6542	0,0561
	LSTM	1314,6602	0,3821
Deney 3 (Welch)	RF	1,5738	0,1457
	kNN	0,3229	0,1252
	SVM	9,9217	0,0856
	LSTM	1354,9500	0,4248



Şekil 5. Sınıflandırma algoritmalarının doğruluk performansı (Accuracy performance of the classification algorithms)

gibi geleneksel yöntemler kullanılmaktadır. Manuel testler daha ucuz ve daha hızlı olmasına karşın güvenilir teşhisler sunmak için yeterince doğru değildir. Önceden tasarlanmış görevleri yerine getirirken çocukların performanslarının puanlanması ise deneyimli uygulayıcılar için bile oldukça zaman alıcıdır ve minimum 90 dakikalık bir süre içermektedir [23]. Ayrıca uygulayıcıların gözlemsel analizine büyük ölçüde dayanmaktadır, pahalıdır, öznel ve daha geniş bir popülasyona yayılması kolay değildir [10]. Bu çalışmada GKB'nin tanısının otomatik değerlendirilebilme için girdi verisi olarak EEG sinyalleri kullanılmıştır. GKB'nin tanısına yönelik ilgili çalışmalar incelendiğinde girdi verisi olarak motorik hareket verileri [22], fonksiyonel manyetik rezonans görüntüleri [24], motor hareket görevi sırasında kaydedilen görüntüler [25], görsel, motor, algısal-motor ve genel performans kapsayan ölçek verileri [52] ve EEG sinyallerinin [23] kullanıldığı görülmektedir. Ancak, EEG sinyallerinin kaydedilmesi daha az maliyetlidir, basittir ve bu sinyallerin kaydedilmesi için daha az donanım ihtiyacı vardır. Bu nedenle EEG diğer nörogörüntüleme yöntemlerine göre klinikte en çok kullanılan tekniktir [13].

GKB'li çocuklar, aynı izleme görevini gerçekleştirirken, tipik çocuklardan farklı beyin bölgelerini etkinleştirmektedir. Aynı yaşta ki akranlarına göre GKB'li çocukların sinir ağlarında ve beyin aktivasyon modellerinde farklılıklar bulunmaktadır [53]. GKB'li çocuklar cevap verme ve değerlendirme süreçlerinde daha az çaba harcamaktadır ve yanlışları düzeltmede daha az nöral kaynağı kullanmaktadır [20]. EEG sinyalleri ve GKB arasındaki bağlantıyı araştıran çalışmalar incelendiğinde, GKB'li çocukların EEG değerlerinin akranlarına göre daha düşük olduğu belirtilmektedir [19]. Bu çalışmada da GKB'li ve kontrol grubundaki çocukların hem EEG sinyalleri hem de spektral analiz yöntemleri ile EEG sinyallerinden çıkarılan güç spektral yoğunluğu değerlerini gösteren grafikler incelendiğinde, GKB'li çocukların EEG sinyallerinin GKB'li olmayan akranlarına göre daha düşük olduğu görülmektedir.

GKB'nin otomatik tanısına yönelik bu çalışmada, EEG sinyallerinin güç spektral yoğunlukları kullanılarak welch spektral analiz yöntemi ve LSTM derin öğrenme ağı tabanlı bir yöntem kullanılmıştır. Kullanılan yöntemler incelendiğinde; Buettner vd. [23], bildiri çalışmalarında GKB'nin tanısında geleneksel yöntemlerin aksine, bu iki grup arasındaki beyin aktivitelerinin farklı olması nedeni ile EEG kayıtlarını kullanan makine öğrenmesi tabanlı bir yaklaşım sunmuşlardır. GKB'li ve normal gelişim gösteren çocukları FFT ve RF algoritması kullanılarak %99,35 bir doğruluk oranı ile sınıflandırmışlardır. GKB'nin otomatik tanısına ilişkin EEG

kayıtlarının kullanıldığı başka bir çalışmaya rastlanmamıştır. İlgili literatürde, EEG kayıtlarının kullanıldığı makine öğrenmesi veya derin öğrenme tabanlı başka bir çalışmaya rastlanmaması GKB'nin sınıflandırılmasına yönelik çalışmaların tekrarlanması ve sonuçlarının karşılaştırılması gerektiğini de ortaya çıkarmaktadır. Motorik hareket verilerini kullanan makine öğrenmesi tabanlı bir çalışma Mannini vd. [22] tarafından yapılmıştır. Katılımcıların motorik hareket verileri sensörler yardımıyla kaydedilmiştir. Ataksi, GKB ve kontrol grubunun sınıflandırılmasında SVM algoritmasını kullanmışlardır. Algoritmaya ait doğruluk değeri %85,7'dir. Lalanne vd. [52] giriş verisi olarak görsel, motor, algısal-motor ve genel performans kapsayan ölçek verilerini kullanarak GKB'nin alt tiplerini sınıflandırmışlardır. Verilerin analizinde RF algoritması ile %92,4 doğruluk ve Kısmi En Küçük Kareler Ayırım Analizi ile %91,7 doğruluk elde etmişlerdir. GKB, gelişimsel dönemin başlangıcından itibaren mevcut olmasına rağmen genellikle okul çağına kadar tespit edilememektedir [31]. Bu nedenle GKB'nin zamanında ve objektif tanısı önemlidir. Bu çalışmada da en yüksek doğruluk oranı Welch spektral analiz yöntemi ile LSTM derin öğrenme ağı ile %97,20 olarak hesaplanmıştır. Önerilen modelin performansı oldukça yüksektir. Çalışmada derin öğrenme algoritmasının kullanılması bu başarının temel nedenidir. Derin öğrenme modellerinin makine öğrenmesi modellerine göre, özellikle EEG sinyalleri gibi, veri sayısının çok fazla olduğu durumlarda daha fazla performans gösterdiği bilinmektedir. Veri sayısı çok fazla olduğunda makine öğrenmesi algoritmaları yetersiz kalmaktadır. Bununla birlikte, modelin başarısının deney paradigması ve prosedürü, örneklem sayısı, kullanılan metotlar ve algoritmalar gibi birçok parametre ile ilişkili olduğu unutulmamalıdır.

6. Sonuçlar (Conclusions)

Sonuç olarak, GKB'nin erken tanısında EEG sinyallerini kullanarak welch özellik çıkarımı ve LSTM derin ağını etkili bir şekilde birleştiren bir derin öğrenme modeli önerilmektedir. Çalışmada GKB'nin sınıflandırılmasında periodogram, multitaper ve welch spektral analiz metotları ile hesaplanan güç spektral yoğunlukları kullanılarak üç ayrı deney gerçekleştirilmiştir. Deneylerde ilk olarak bu spektral analiz yöntemleri ile EEG sinyallerinin 1-49 hertz arasındaki frekanslarına ait güç yoğunlukları değerleri hesaplanarak öznel vektörleri oluşturulmuştur. Oluşturulan öznel vektörleri kullanılarak EEG tabanlı GKB'nin sınıflandırılmasında LSTM derin öğrenme algoritması ile SVM, kNN ve RF makine öğrenmesi algoritmalarının karşılaştırmalı analizi yapılmıştır. Önerilen yöntem EEG sinyallerini analiz ederek GKB'nin otomatik olarak teşhis

edilmesinde derin öğrenme modelinin kullanıldığı nadir bir girişimdir. Deneysel sonuçlar, Welch yöntemi spektral analiz yöntemi ile birlikte LSTM derin öğrenme algoritması ile en yüksek performansın elde edildiğini göstermektedir. LSTM algoritmasına ait performans analizi sonuçları 0,984 duyarlılık değeri, 0,959 özgülük değeri, 0,962 kesinlik değeri, 0,973 f1 skoru, 0,944 MCC değeri ve %97,20 doğruluk değeri olarak hesaplanmıştır. Bu değerlerin 1'e yakın olması modelin tesadüfi bir başarıya sahip olmadığını göstermektedir. Çalışma GKB'yi sınıflandırma görevlerinde derin öğrenme algoritmalarının makine öğrenmesi algoritmalarına göre üstünlüğüne dair kanıt sağlamaktadır. Önerilen modelin uzman görüşünü destekleyeceği ve farklı biyomedikal sinyallere uygulanarak yüksek performans gösterebileceği düşünülmektedir. Derin öğrenme modelleri EEG sinyallerini sınıflandırma uygulamalarında muazzam bir yeteneğe sahiptir ve kullanımı umut vadetmektedir.

Kaynaklar (References)

1. Fogel, Y., Stuart, N., Joyce, T., Barnett, A. L., Relationships between motor skills and executive functions in developmental coordination disorder (DCD): A systematic review. *Scandinavian Journal of Occupational Therapy*, 30 (3), 344-356, 2023.
2. Sumner, E., Hutton, S. B., Kuhn, G., Hill, E. L., Oculomotor atypicalities in developmental coordination disorder. *Developmental Science*, 21 (1), e12501, 2018.
3. Lingam, R., Hunt, L., Golding, J., Jongmans, M., Emond, A., Prevalence of developmental coordination disorder using the DSM-IV at 7 years of age: A UK population-based study. *Pediatrics*, 123 (4), e693-e700, 2009.
4. Kirby, A., Williams, N., Thomas, M., Hill, E. L., Self-reported mood, general health, wellbeing and employment status in adults with suspected DCD. *Research in Developmental Disabilities*, 34 (4), 1357-1364, 2013.
5. Draghi, T. T. G., Cavalcante Neto, J. L., Rohr, L. A., Jelsma, L. D., Tudella, E., Symptoms of anxiety and depression in children with developmental coordination disorder: a systematic review. *Jornal de Pediatria*, 96, 08-19, 2020.
6. Nobre, G. C., Ramalho, M. H. D. S., Ribas, M. D. S., Valentini, N. C., Motor, physical, and psychosocial parameters of children with and without developmental coordination disorder: A comparative and associative study. *International Journal of Environmental Research and Public Health*, 20 (4), 2801, 1-13, 2023.
7. Brons, A., de Schipper, A., Mironcika, S., Toussaint, H., Schouten, B., Bakkes, S., Kröse, B., Assessing children's fine motor skills with sensor-augmented toys: machine learning approach. *Journal of Medical Internet Research*, 23 (4), e24237, 2021.
8. Baxter, P., Distinguishing ataxia from developmental coordination disorder. *Developmental Medicine & Child Neurology*, 62 (1), 11-11, 2020.
9. Brown-Lum, M., Zwicker, J. G. Brain imaging increases our understanding of developmental coordination disorder: a review of literature and future directions. *Current Developmental Disorders Reports*, 2, 131-140, 2015.
10. Li, R., Fu, H., Zheng, Y., Lo, W. L., Yu, J. J., Sit, C. H., Chi, Z., Song, Z., Wen, D., Automated fine motor evaluation for developmental coordination disorder. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27 (5), 963-973, 2019.
11. Yıldırım, C., Acar, G., Polat, M. G., Mete, E., Kaygusuz, R., Neuroimaging in developmental coordination disorder. *Turkish Journal of Neurology*, 27 (1), 5-16, 2021.
12. Brady, D., Leonard, H. C., Developmental coordination disorder. Chapter in the *Oxford Handbook of Developmental Cognitive Neuroscience*, 2019.
13. Aslan, Z., Migraine detection from EEG signals using tunable Q-factor wavelet transform and ensemble learning techniques. *Physical and Engineering Sciences in Medicine*, 44 (4), 1201-1212, 2021.
14. Gomez-Pilar, J., Garcia-Azorin, D., Gomez-Lopez-de-San-Roman, C., Guerrero, Á. L., Hornero, R., Exploring EEG spectral patterns in episodic and chronic migraine during the interictal state: determining frequencies of interest in the resting state. *Pain Medicine*, 21 (12), 3530-3538, 2020.
15. Hyde, C., Fuelscher, I., Williams, J., Neurophysiological approaches to understanding motor control in DCD: current trends and future directions. *Current Developmental Disorders Reports*, 6 (2), 78-86, 2019.
16. De Castelnaud, P., Albaret, J. M., Chaix, Y., Zanone, P. G., A study of EEG coherence in DCD children during motor synchronization task. *Human Movement Science*, 27 (2), 230-241, 2008.
17. Albaret, J. M., Chaix, Y., Neurobiological bases and neurophysiological correlates of developmental coordination disorders. *Neurophysiologie Clinique= Clinical Neurophysiology*, 42 (1-2), 11-17, 2011.
18. Zwicker, J. G., Missiuna, C., Boyd, L. A., Neural correlates of developmental coordination disorder: a review of hypotheses. *Journal of Child Neurology*, 24 (10), 1273-1281, 2009.
19. Fong, S. S., Chung, J. W., Cheng, Y. T., Yam, T. T., Chiu, H. C., Fong, D. Y., Cheung, C.Y., Yuen L., Yu, E. Y., Hung, Y. S., Macfarlane, D. J., Ng, S. S., Attention during functional tasks is associated with motor performance in children with developmental coordination disorder: A cross-sectional study. *Medicine*, 95 (37), 1-8, 2016.
20. Tsai, C. L., Wang, C. H., Tseng, Y. T., Effects of exercise intervention on event-related potential and task performance indices of attention networks in children with developmental coordination disorder. *Brain and Cognition*, 79 (1), 12-22, 2012.
21. Piek, J. P., Dyck, M. J., Sensory-motor deficits in children with developmental coordination disorder, attention deficit hyperactivity disorder and autistic disorder. *Human movement science*, 23 (3-4), 475-488, 2004.
22. Mannini, A., Martinez-Manzanera, O., Lawerman, T. F., Trojaniello, D., Della Croce, U., Sival, D. A., Mautris, N. M., Sabatini, A. M. Automatic classification of gait in children with early-onset ataxia or developmental coordination disorder and controls using inertial sensors. *Gait & Posture*, 52, 287-292, 2017.
23. Buettner, R., Buechele, M., Grimmeisen, B., Ulrich, P., Machine learning based diagnostics of developmental coordination disorder using electroencephalographic data. *Proceedings of the 54th Hawaii International Conference on System Sciences*, 3426-3435, 2021.
24. Cignetti, F., Nemmi, F., Vaugoyeau, M., Girard, N., Albaret, J. M., Chaix, Y., Péran, P., Assaiante, C., Intrinsic cortico-subcortical functional connectivity in developmental dyslexia and developmental coordination disorder. *Cerebral Cortex Communications*, 1 (1), tgaa011, 2020.
25. Li, R., Fu, H., Zheng, Y., Lo, W. L., Jane, J. Y., Sit, C. H., Chi, Z., Song, Z., Wen, D., Automated fine motor evaluation for developmental coordination disorder. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27 (5), 963-973, 2019.
26. Tosun, M., Effects of spectral features of EEG signals recorded with different channels and recording statuses on ADHD classification with deep learning. *Physical and Engineering Sciences in Medicine*, 44 (3), 693-702, 2021.
27. Saeedi, A., Saeedi, M., Maghsoudi, A., Shalhaf, A., Major depressive disorder diagnosis based on effective connectivity in EEG signals: A convolutional neural network and long short-term memory approach. *Cognitive Neurodynamics*, 15 (2), 239-252, 2021.
28. Singh, K., Malhotra, J., Two-layer LSTM network-based prediction of epileptic seizures using EEG spectral features. *Complex & Intelligent Systems*, 1-14, 2022.
29. Nikhil Chandran, A., Sree Kumar, K., Subha, D. P., EEG-based automated detection of schizophrenia using long short-term memory (LSTM) network. In *Advances in Machine Learning and Computational Intelligence* (pp. 229-236). Springer, Singapore, 2021.
30. Göker, H., Welch spectral analysis and deep learning approach for diagnosing Alzheimer's disease from resting-state EEG recordings. *Traitement du Signal*, 40 (1), 257-264, 2023.
31. Blank, R., Barnett, A. L., Cairney, J., Green, D., Kirby, A., Polatajko, H., Rosenblum, S., Smits-Engelsman, B., Sugden, D., Wilson, P., Vinçon, S. International clinical practice recommendations on the definition, diagnosis, assessment, intervention, and psychosocial aspects of developmental coordination disorder. *Developmental Medicine & Child Neurology*, 61 (3), 242-285, 2019.
32. Vařeka, L., Brůha, P., Mouček, R., Mautner, P., Čepička, L., Holečková, I., Developmental coordination disorder in children—experimental work and data annotation. *GigaScience*, 6 (4), gix002, 2017.
33. Zhang, Z., Spectral and time-frequency analysis. In *EEG Signal Processing and Feature Extraction*, 89-116, Springer, Singapore, 2019.
34. Yuvaraj, R., Murugappan, M., Palaniappan, R., The effect of lateralization of motor onset and emotional recognition in PD patients using EEG. *Brain Topography*, 30, 333-342, 2017.

35. Manshouri, N., Maleki, M., Kayikcioglu, T., An EEG-based stereoscopic research of the PSD differences in pre and post 2D&3D movies watching. *Biomedical Signal Processing and Control*, 55, 101642, 2020.
36. Kasim, Ö., Tosun, M., Biometric Authentication from Photic Stimulated EEG Records. *Applied Artificial Intelligence*, 35 (15), 1407-1419, 2021.
37. Li, M. W., Geng, J., Hong, W. C., Zhang, L. D., Periodogram estimation based on LSSVR-CCPSO compensation for forecasting ship motion. *Nonlinear Dynamics*, 97 (4), 2579-2594, 2019.
38. Lepage, K. Q., Jain, S., Kvavilashvili, A., Witcher, M., Vijayan, S., Unsupervised multitaper spectral method for identifying REM sleep in intracranial EEG recordings lacking EOG/EMG data. *Bioengineering*, 10 (9), 1009, 1-17, 2023.
39. Güneç, K., Kasım, Ö., Tosun, M., Büyükköroğlu, E., Estimation of pain threshold from EEG signals of subjects in physical therapy using long-short-term memory deep learning model. *Uludağ University Journal of the Faculty of Engineering*, 26 (2), 447-460, 2021.
40. Francis, M.N., Keran, M.P., Chetan, R., Krupa, B.N., EEG-controlled robot navigation using Hjorth parameters and Welch-PSD. *International Journal of Intelligent Engineering and Systems*, 14 (4), 231-240, 2021.
41. Jin, X., Wang, Y., Hong, W., Power spectrum estimation method based on Matlab. In *Proceedings of the 3rd International Conference on Vision, Image and Signal Processing*, 1-5, 2019.
42. Welch, P., The use of fast Fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms. *IEEE Transactions on Audio and Electroacoustics*, 15 (2), 70-73, 1967.
43. Lashgari, E., Liang, D., Maoz, U., Data augmentation for deep-learning-based electroencephalography. *Journal of Neuroscience Methods*, 108885, 2020.
44. Sakai, A., Minoda, Y., Morikawa, K., Data augmentation methods for machine-learning-based classification of bio-signals. In *2017 10th Biomedical Engineering International Conference (BMEiCON)*, 1-4, IEEE, 2017.
45. Atrey, K., Singh, B. K., Bodhey, N. K., Pachori, R. B., Mammography and ultrasound based dual modality classification of breast cancer using a hybrid deep learning approach. *Biomedical Signal Processing and Control*, 86, 104919, 2023.
46. Nath, D., Singh, M., Sethia, D., Kalra, D., Indu, S., An efficient approach to EEG-based emotion recognition using LSTM network, 16th IEEE International Colloquium on Signal Processing & Its Applications, Langkawi Island, Malaysia, 88-92, 2020.
47. Hatipoğlu A., Güneri Y., Yılmaz E., A comparative predictive maintenance application based on machine and deep learning. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 39 (2), 1037-1048, 2024.
48. Deepika, D., Rekha, G., Highly accurate EEG signal classification using multiple feature extraction and LSTM networks. *Journal of Biomedical Photonics & Engineering*, 010304, 1-10, 2024.
49. Liu, G., Guo, J., Bidirectional LSTM with attention mechanism and convolutional layer for text classification. *Neurocomputing*, 337, 325-338, 2019.
50. Kadiroğlu Z., Deniz E., Şenyiğit A., A comparison of deep learning models for pneumonia detection from chest x-ray images, *Journal of the Faculty of Engineering and Architecture of Gazi University* 39 (2), 729-740, 2024.
51. Göker, H., Tosun, M., Fast Walsh-Hadamard transform and deep learning approach for diagnosing psychiatric diseases from electroencephalography (EEG) signals. *Neural Computing and Applications*, 35 (32), 23617-23630, 2023.
52. Lalanne, C., Falissard, B., Golse, B., Vaivre-Douret, L., Refining developmental coordination disorder subtyping with multivariate statistical methods. *BMC Medical Research Methodology*, 12 (1), 1-14, 2012.
53. Zwicker, J. G., Missiuna, C., Harris, S. R., Boyd, L. A., Brain activation of children with developmental coordination disorder is different than peers. *Pediatrics*, 126 (3), e678-e686, 2010.

