



ERUSLR: A new Turkish sign language dataset and its recognition using hyperparameter optimization aided convolutional neural network

Tayyip Özcan*^{ID}, Alper Baştürk^{ID}

Department of Computer Engineering, Erciyes University, Kayseri, 38039, Turkey

Highlights:

- A new sign language recognition data set called ERUSLR
- A classification model based on global / heuristic search method and GoogLeNet supported CNN
- 93.93% accuracy rate obtained by genetic algorithm based classification model

Keywords:

- Sign language recognition
- Transfer learning
- GoogLeNet
- Parameter optimization
- Global search method
- Heuristic search method

Article Info:

Research Article
Received: 02.06.2020
Accepted: 24.09.2020

DOI:

10.17341/gazimmfd.746793

Acknowledgement:

We would like to thank all participants involved in the data collection stage, especially the creation of the ERUSLR dataset.

Correspondence:

Author: Tayyip Özcan
e-mail:
tozcan@erciyes.edu.tr
phone: +90 532 764 3577

Graphical/Tabular Abstract

Sign language is an important communication tool for deaf-and-dumb people. There is a need to make provision for effective communication in the emergency departments of a hospital. Therefore, firstly, the 25 words needed in emergency services were identified, and subsequently used to create a new dataset, named Erciyes University Sign Language Recognition (ERUSLR) dataset. To classify the ERUSLR dataset, a GoogLeNet-based CNN model with global/heuristic search support is proposed as shown in Figure A. The GoogLeNet pre-trained model was used for transfer learning. A GoogLeNet-based CNN was created by replacing the last 3 layers with suitable layers that are stem from the related problem. Grid search (GS), random search (RS), and genetic algorithm (GA) were used as the parameter search method. These search methods were used to optimize the training options of the CNN including the initial learning rate, ℓ_2 regularization, and momentum parameters. The experimental results show that the GA supported model displayed a better performance.

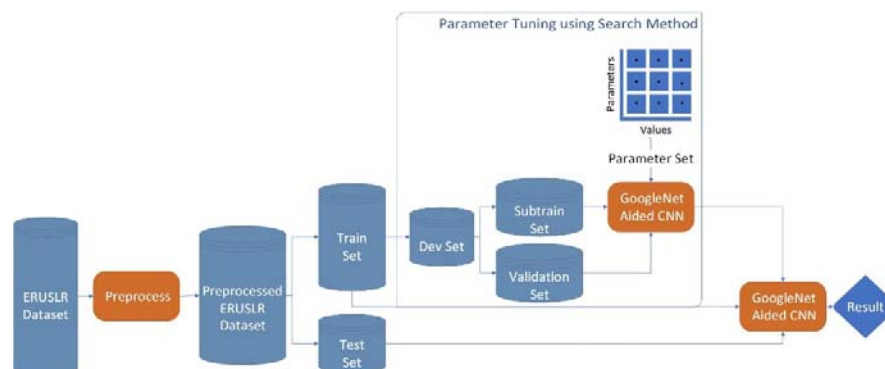


Figure A. The proposed system

Purpose: The first aim of the study is to create a new sign language recognition dataset that can be used in the hospital. The other aim involves the development of a global/heuristic search and GoogLeNet based method.

Theory and Methods:

In this study, instead of developing a CNN model from scratch, the transfer learning method, an easier and more effective approach, is selected. Consequently, a GoogLeNet based-CNN model was created by transfer learning from the GoogLeNet pre-trained model. The initial experiments with the ERUSLR dataset created in this study was performed using the GoogLeNet-based CNN model with the default parameter values. Search methods are typically used in parameter optimization to save time. In this study, GS, RS, and GA methods are used to optimize the training parameters of the GoogLeNet-based CNN model.

Results:

In the experimental studies, the GoogLeNet-based CNN model with the default parameter values recorded an accuracy rate of 88.62%. On the other hand, an accuracy rate of 93.63% was obtained with GS supported GoogLeNet-based CNN model while an accuracy rate of 89.81% was achieved with the RS supported GoogLeNet-based CNN. Finally, an accuracy rate of 93.93% was achieved with the GA supported GoogLeNet-based CNN.

Conclusion:

Transfer learning operation is an easy and effective way of building a new CNN model. Global/heuristic search-based parameter optimization is an important factor that improves classification performance.



ERUSLR: Yeni bir Türkçe işaret dili veri seti ve hiperparametre optimizasyonu destekli evrişimli sinir ağı ile tanınması

Tayyip Özcan*^{ID}, Alper Baştürk^{ID}

Erciyes Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 38039, Melikgazi, Kayseri, Türkiye

Ö N E Ç İ K A N L A R

- ERUSLR adında yeni bir işaret dili tanıma veri seti
- Global / sezgisel arama yöntemi ve GoogLeNet tabanlı CNN üzerine kurulu sınıflandırma modeli
- Genetik algoritma tabanlı sınıflandırma modeli ile % 93,93 doğruluk oranı

Makale Bilgileri

Araştırma Makalesi

Geliş: 02.06.2020

Kabul: 24.09.2020

DOI:

10.17341/gazimmfd.746793

Anahtar Kelimeler:

İşaret dili tanıma,
transfer öğrenme,
GoogLeNet,
parametre optimizasyonu,
global arama,
sezgisel arama

ÖZET

İşaret dili, dilsel ve işitsel yetilerini kaybeden konuşma ve duyma engelli bireylerin iletişimini sağlayan en önemli araçtır. Sağır ve dilsiz bireylerin anlaşılması için gerekli olan işaret dilinin bilinmediği ortamlarda ciddi sorunlar ortaya çıkabilir. Hastanelerin acil servislerine başvuran engelli bireylerin anlaşılabilmesi ise kritik sonuçlar doğurabilir. Bu çalışmada, öncelikle, hastanelerin acil servisinde sıklıkla kullanılan kelimelerle yeni bir veri seti oluşturulmuştur. 25 kelime, 49 engelli birey tarafından birden fazla tekrarlanmış ve farklı açılardan videoları kaydedilmiştir. Erciyes University Sign Language Recognition (ERUSLR) adındaki bu veri seti 13186 örnek içermektedir. ERUSLR veri seti kullanılarak bir sınıflandırma modeli oluşturmak istenmiştir. İşaret dilinin tanınması, son yıllarda sınıflandırma problemlerinde sıklıkla kullanılan evrişimli sinir ağı (CNN) ile gerçekleştirilebilmektedir. Yeni bir CNN modelinin geliştirilmesinden daha etkili olan yöntem, transfer öğrenme ile CNN modeli oluşturmaktır. Dolayısıyla, GoogLeNet ön eğitimli modelinden transfer öğrenme gerçekleştirilerek GoogLeNet tabanlı bir CNN modeli oluşturulmuştur. CNN modelinin performansını artıran bir başka etken eğitim parametrelerinin optimize edilmesidir. Global ve sezgisel arama yöntemleri, parametre optimizasyonunda kullanılan ve zamansal kazanç sağlayan metotlardır. Bu çalışmada grid arama (GS), rastgele arama (RS) ve genetik algoritma (GA) yöntemleri, GoogLeNet tabanlı CNN modelinin eğitim parametrelerini optimize etmek için kullanılmıştır. Deneysel sonuçlara göre, GA destekli GoogLeNet tabanlı CNN modeli (%93,93 ile) diğer yöntemlerden daha başarılı sonuç vermiştir.

ERUSLR: A new Turkish sign language dataset and its recognition using hyperparameter optimization aided convolutional neural network

H I G H L I G H T S

- A new sign language recognition data set called ERUSLR
- A classification model based on global / heuristic search method and GoogLeNet supported CNN
- 93.93% accuracy rate obtained by genetic algorithm based classification model

Article Info

Research Article

Received: 02.06.2020

Accepted: 24.09.2020

DOI:

10.17341/gazimmfd.746793

Keywords:

Sign language recognition,
transfer learning,
GoogLeNet,
parameter optimization,
global search,
heuristic search

ABSTRACT

Sign language is one of the most important tools of communication for deaf-and-dumb individuals who have lost their linguistic and auditory abilities. Significant problems may arise in situations where the sign language required to clearly understand deaf-and-dumb individuals is not known. More importantly, the failure to understand the disabled individuals who try to access emergency health services at a health institution may have fatal consequences. In this study, firstly, a new dataset was created with the frequently used words in the emergency department of hospitals. 25 words were repeated multiple times by 49 handicapped individuals where the videos were recorded from different angles. This dataset, named Erciyes University Sign Language Recognition (ERUSLR), contains 13186 samples. Classification experiments were performed by using the ERUSLR dataset. Sign language recognition can be realized by a convolutional neural network (CNN), which is frequently used for classification problems. Rather than developing a new CNN model, transfer learning, a more effective method, is preferred. Therefore, a GoogLeNet-based CNN model was created by transfer learning from the GoogLeNet pre-trained model. Another factor that increases the performance of a CNN model is the optimization of its training parameters. Global and heuristic search methods are typically used in parameter optimization to save time. In this study, both grid search (GS), random search (RS), and genetic algorithm (GA) methods were used to optimize the training parameters of the GoogLeNet-based CNN model. According to the experimental results, the GA supported GoogLeNet-based CNN model is more successful (with a success rate of 93.93%) than the other methods.

*Sorumlu Yazar/Corresponding Author: tozcan@erciyes.edu.tr, ab@erciyes.edu.tr / Tel: +90 532 764 3577

1. GİRİŞ (INTRODUCTION)

İnsanlar arasında iletişimin kurulabilmesi için birbirlerini anlayacakları ortak bir iletişim diline ihtiyaç vardır. Bu iletişimin sağlanması dil, vücut dili veya hissel etkileşimle gerçekleştirilebilir. Sağır ve dilsiz bireyler dilsel ve işitsel yetilerini kaybeden kişilerdir. El hareketleri, mimik veya dudak hareketlerini kullanarak aralarında iletişim kuran bu bireylerin kullandığı dil, işaret dilidir. İşaret dili kullanmak zorunda kalan bireylerin aralarında iletişim kurmasından çok daha zor olan durum, işaret dilini bilmeyen kişilerle iletişim kurmak zorunda kalmalarıdır. Bu durum işaret dili kullanmak zorunda olanlar için büyük bir sorundur. Bu problemin çözümü ve işaret dilinin anlaşılması için literatürde veri seti oluşturma ve sınıflandırma çalışmaları gerçekleştirilmektedir. Kelime düzeyinde hazırlanmış literatürde sıkça kullanılan veri setleri ve o veri setlerine ait özellikler Tablo 1 ile sunulmuştur.

Tablo 1. Literatürde sıklıkla kullanılan kelime düzeyinde işaret dili tanıma veri setleri

(Word level sign language recognition datasets which are frequently used in literature)

| Veri seti | Ülke | Sınıf | Katılımcı | Örnek |
|----------------|------------|-------|-----------|-------|
| DGS Kinect 40 | Almanya | 40 | 15 | 3000 |
| GSL 20 | Yunanistan | 20 | 6 | 840 |
| Boston ASL LVD | ABD | 3300 | 6 | 9800 |
| PSL Kinect 30 | Polonya | 30 | 1 | 300 |
| PSL ToF 84 | Polonya | 84 | 1 | 1680 |
| LSA64 | Arjantin | 64 | 10 | 3200 |
| DEVISIGN-D | Çin | 500 | 8 | 6000 |

German Sign Language (DGS) Kinect 40 veri seti [1] Cooper vd. tarafından Kinect kamera kullanılarak hazırlanmış Almanca kelimeler içeren kelime düzeyinde bir veri setidir. Bu veri seti 40 sınıf içermekte olup 15 gönüllünün katılımıyla oluşturulmuştur. Her bir örnek her katılımcı tarafından 5'er kez tekrar edilmiştir. Toplamda 3000 örnek içeren DGS Kinect 40 veri seti [1, 2] çalışmalarında, önerilen yöntemlerin test edilmesinde kullanılmıştır. Cooper vd. [1] çalışmasında geliştirilen bir diğer veri seti Greek Sign Language (GSL) veri setidir. GSL veri seti, 6 gönüllünün katılımıyla 20 sınıf üzerinden toplamda 840 örnekle oluşturulmuştur. [1, 2] çalışmalarında, DGS Kinect 40 veri setiyle birlikte GSL 20 veri seti de kullanılmıştır.

American Sign Language Lexicon Video Dataset (ASLLVD) veri seti [3] Athitsos vd. tarafından geliştirilen bir diğer kelime düzeyinde veri setidir. 3300'den fazla sınıf içeren bu veri setinde toplamda 6 gönüllü ve 9800 örnek bulunmaktadır. Bu veri seti kullanılarak yapılan çalışmaların bazıları [4-6] olarak sıralanabilir. Neidle vd. [4] ASLLVD'yi daha ön plana çıkararak bir bilgisayar görü uygulaması sunmuşlardır. Burada, dilbilim sözcüklere ait işaretlerde başlangıç ve bitiş el işaretleri arasındaki geçiş olasılıklarını modelleyen sistem kullanmışlardır. Bir diğer çalışmada, Kim vd. [5] geliştirmiş oldukları sistemle el takibi ve el poz tahmini gerçekleştirmişlerdir. Önerdikleri yöntemi

ASLLVD veri seti ile test etmişlerdir. Metaxas vd. [6], gelişmiş öğrenme yöntemlerini özelliklerle birleştiren karma bir yapı kullanarak işaretleri tanıma üzerine çalışma yapmıştır. Polish Sign Language (PSL) Kinect 30 veri seti [7] Oszust ve Wysocki tarafından oluşturulmuştur. 30 kelime, 1 katılımcı tarafından 10'ar kez tekrarlanarak 300 örneklilikte bir veri seti geliştirilmiştir. Oszust ve Wysocki 2014 yılında gerçekleştirdikleri çalışmalarında [8] tam kelime modeli ve veri odaklı alt dizi modelini kullanarak sınıflandırma yapmış ve çalışmalarını PSL Kinect 30 veri seti ile test etmişlerdir. Bir diğer çalışmada [9], dinamik zaman atlama ile en yakın komşu tekniği ile saklı Markov modelleri bu veri setinin sınıflandırılmasında kullanılmıştır.

Argentinian Sign Language veri seti (LSA64) [10] 10 katılımcı ile oluşturulmuş toplamda 3200 örnek içeren kelime düzeyinde bir veri setidir. Veri seti oluşturulurken 64 sınıf için her katılımcı 5'er kez tekrar yapmıştır. [11-13] çalışmalarında LSA64 veri seti farklı metodların performanslarını analiz etmek için kullanılmıştır.

DEVISIGN-G veri seti [14] 36 sınıf için 8 gönüllüden kaydedilen 432 örnekten oluşmaktadır. El segmentasyonu üzerine çalışmasını geliştiren Zheng ve Liang [15, 14] çalışmasındaki başarı oranlarını geride bırakmıştır.

Literatürde son yıllarda farklı problemler [16-21] için derin öğrenme metodları yaygın olarak kullanılmıştır. Derin öğrenme yöntemlerinin başarılı sonuçlar vermesi işaret dili tanıma üzerine çalışma gerçekleştirecek araştırmacıların dikkatini çekmiş ve bu alanda çalışmalar [22-24] gerçekleştirilmiştir. Bir derin öğrenme yöntemi olan evrişimli sinir ağı (CNN) [25], sınıflandırma problemlerinde sıklıkla kullanılan bir yöntemdir. Ön eğitilmiş CNN modeli kullanılarak sınıflandırma, özellik çıkarma ve transfer öğrenme gerçekleştirilebilir. CNN için yeni bir model geliştirmekten daha kolay ve etkili yöntemlerden birisi transfer öğrenme ile model oluşturmaktır. [26] çalışmasında transfer öğrenme ile model geliştirilmiş ve başarılı sonuçlar elde edilmiştir. CNN gibi bir derin öğrenme modelinin başarısını etkileyen en önemli etkenlerden bir başkası hiperparametrelerinin optimize edilmesidir. Bu parametrelerin optimizasyonunda sezgisel algoritmaların kullanıldığı [27-32] gibi global arama yöntemleri de kullanılabilir. Grid arama (GS) ve rastgele arama (RS) yöntemleri sıklıkla kullanılan global arama yöntemleridir ve parametre optimizasyonunda sıklıkla kullanılmaktadır [27, 33-35]. Bu çalışmada öncelikle hastane ortamında kullanılmak üzere kelime düzeyinde yeni bir veri seti geliştirilmiştir. Erciyes University Sign Language Recognition (ERUSLR) adındaki bu yeni veri seti, 25 kelime (sınıf) için 49 gönüllünün katılımıyla toplamda 13186 örnekten oluşmaktadır. Gönüllülerin tamamı engelli bireylerden seçilerek, örnekler anlaşılır düzeyde kaydedilmiştir. Çalışmanın devamında, örnekler ön işleme tabii tutulmuştur. Burada, video formatındaki örnekler öncelikle çerçevelere ayrılmış daha sonra bu çerçeveler sıralı şekilde birleştirilerek sıralı tekil imge haline getirilmiştir.

Sınıflandırmalarda renklerin etkisi olmayıp sadece hareket odaklı olduğu için ön işleme aşamasının son kısmında RGB formatındaki tekil imgeler gri tonlama haline dönüştürülmüştür. Daha sonraki aşamada eğitim setinden türetilen geliştirme seti ve GoogLeNet tabanlı CNN kullanılarak parametre ayarlama işlemi gerçekleştirilmiştir. Parametre ayarlaması için GS ve RS global arama yöntemleri olarak, genetik algoritma (GA) sezgisel arama algoritması olarak kullanılmıştır. GS ve RS yöntemlerinin yerel minimuma takılma riski olsa da derin öğrenme modelinin parametre optimizasyonunda zamansal maliyeti düşürmek için sıklıkla kullanılmaktadır. GS, RS ve GA yöntemleri kullanılarak elde edilen optimale yakın parametre seti ile eğitim verisi kullanılarak GoogLeNet destekli CNN modeli eğitilip ve çıktı olarak elde edilen eğitim modeli test verisi ile test edilerek sistemin performans analizi gerçekleştirilmiştir. Yapılan deneysel çalışmalarda GA destekli GoogLeNet tabanlı CNN modeli ile %93,93 doğruluk oranı elde edilirken GS destekli GoogLeNet tabanlı CNN modeli ile %93,63 doğruluk oranı elde edilmiştir. Diğer taraftan, RS destekli GoogLeNet tabanlı CNN ile %89,81 ve sadece varsayılan parametrelerin kullanıldığı GoogLeNet destekli CNN ile %88,62 başarı oranları elde edilmiştir.

Bu çalışmanın ana katkıları şu şekilde sıralanabilir:

- ERUSLR adında hastane ortamında kullanılan genel kullanıma açık işaret dili tanıma veri seti oluşturulmuştur.
- Global ve sezgisel arama yöntemi destekli, GoogLeNet tabanlı CNN kullanan bir sistem geliştirilmiştir.
- GA destekli GoogLeNet tabanlı CNN ile %93,93 doğruluk oranı ile en başarılı sonuç elde edilmiştir.

Bu çalışmanın ilerleyen bölümleri şu şekilde düzenlenmiştir. Bölüm 2'de yeni geliştirilen ERUSLR veri seti hakkında detaylı bilgi verilecektir. Bölüm 3'te önerilen yöntem açıklanacak olup Bölüm 4'te yöntemin uygulanması ile yapılan deneysel çalışmalar ve elde edilen sonuçlar sunulacaktır. Bölüm 5 ile bu çalışmanın değerlendirilmesi yapılacak ve gelecek çalışmalardan bahsedilecektir.

2. ERUSLR VERİ SETİ (ERUSLR DATASET)

İşaret dilinin anlaşılmasının en önemli olduğu durumlardan bir tanesi hastane ortamlarıdır. Bu çalışmada, hastanın şikayetini anlatabilmesi için zaman kavramının önemli olduğu hastane ortamında, konuşma engelli bireylerin sıklıkla ihtiyaç duyabileceği 25 kelime belirlenmiş ve sadece engelli bireylerden alınan farklı sayıda örneklerle ERUSLR veri seti oluşturulmuştur. 25 sınıf üzerinden 49 katılımcıyla oluşturulan veri seti, toplamda 13186 örnek içermektedir. ERUSLR veri seti oluşturulurken alınan örnekler 3 farklı açıdan (karşıdan (F), sağdan (R), ve soldan (L)) kaydedilmiştir (Şekil 1 ile gösterildiği gibi). ERUSLR veri setindeki 49 gönüllünün yer aldığı bazı örnek çerçeveler Şekil 2 ile sunulmuştur.

Veri setinde bulunan sınıflar ve bu sınıflara ait İngilizce karşılığı ile örnek sayıları Tablo 2 ile gösterildiği gibidir.

Tablodan görüleceği üzere her bir sınıf için örnek sayısı farklıdır. Örnek sayısında dengeli dağılıma sahip olmayan bu veri seti için farklı tipte eğitim-test verisi ayırma teknikleriyle performans analizleri gerçekleştirilebilir.



Şekil 1. Üç farklı açıdan alınan örnekler (Samples from three different angles)

3. METODOLOJİ (METHODOLOGY)

Bu çalışmada, yeni geliştirilen ERUSLR veri seti, GS, RS ve GA yöntemleri ile transfer öğrenme destekli CNN kullanılarak sınıflandırılmıştır. Deneysel çalışmalar için kullanılan bu yöntem Şekil 3 ile gösterildiği gibidir.

Önerilen yöntemde öncelikli olarak ERUSLR veri seti ön işlemden geçirilmektedir. Bu aşamada, video formatında olan örnekler öncelikle çerçevelere ayrılmakta ve daha sonra çerçeveler sıralı bir şekilde tekil imgeyi oluşturmaktadır. Bu aşamada gerçekleştirilen son işlem, RGB formatındaki tekil imgeyi gri formata dönüştürmektir. Ön işlem aşamasına ait örnek bir çalışma Şekil 4 ile gösterildiği gibidir.

Daha sonraki aşamada, ön işlemden geçirilmiş ERUSLR veri seti %70'i eğitim %30'u test verisi olacak şekilde rastgele ayrılır. Sonra, eğitim setinin %50'si kullanılarak geliştirme seti elde edilir. Parametre ayarlama, özellik çıkarma gibi işlemler için kullanılan geliştirme seti [36], bu çalışmada CNN eğitim ayarlarında yer alan ilk öğrenme oranı, ℓ_2 düzenleme ve momentum parametrelerinin ayarlanması için kullanılmıştır. Bir sonraki aşamada, geliştirme seti %70'i alt eğitim %30'u doğrulama verisi olacak şekilde ayrılır. Parametre ayarlama aşamasında çalıştırılan yöntemde göre GS için oluşturulan parametre setinden gelen veya rastgele oluşturulan veya GA ile üretilen olası ilk öğrenme oranı, ℓ_2 düzenleme ve momentum değerleri ile alt eğitim verisi GoogLeNet destekli CNN'e girdi olarak verilir. Eğitim sonucunda oluşan eğitilmiş model, doğrulama verisi ile test edilir ve Eş. 1 ile hesaplanan doğrulama hatası çıktı olarak saklanır. Parametre setinden gelen tüm olası ilk öğrenme oranı, ℓ_2 düzenleme ve momentum değerleri için bu işlem tekrarlanır. En düşük doğrulama hatasını veren parametre değerleri ve eğitim seti GoogLeNet destekli CNN'e girdi olarak verilir ve nihai eğitilmiş model elde edilir. Nihai eğitilmiş model, test seti ile test edilir ve Eş. 2 kullanılarak sistemin performansı doğruluk kriteri üzerinden sonuç olarak sunulur.



15

Şekil 2. ERUSLR veri setinde yer alan katılımcılar (Subjects in the ERUSLR dataset)

Tablo 2. ERUSLR veri setinde yer alan sınıflar ve örnek sayıları (Classes and sample counts of the ERUSLR dataset)

| No | Sınıf | Sınıf (İngilizce) | Örnek Sayısı |
|----|-----------------|-------------------|--------------|
| 1 | Ağız | Mouth | 621 |
| 2 | Ağrı | Pain | 393 |
| 3 | Alerji | Allergy | 564 |
| 4 | Astım | Asthma | 555 |
| 5 | Ateş | Fever | 416 |
| 6 | Baş Ağrısı | Headache | 607 |
| 7 | Baş Dönmesi | Dizziness | 373 |
| 8 | Beyin | Brain | 549 |
| 9 | Böbrek | Kidney | 616 |
| 10 | Boğaz | Throat | 571 |
| 11 | Bulantı | Nausea | 617 |
| 12 | Grip | Flu | 573 |
| 13 | Halsizlik | Weakness | 520 |
| 14 | İlaç | Medicine | 549 |
| 15 | Kalp | Heart | 445 |
| 16 | Kan | Blood | 526 |
| 17 | Karın | Abdomen | 554 |
| 18 | Kemik | Bone | 542 |
| 19 | Kusmak | Spew | 623 |
| 20 | Nabız | Pulse | 522 |
| 21 | Nefes | Breath | 361 |
| 22 | Şeker Hastalığı | Diabetes | 634 |
| 23 | Tansiyon | Blood pressure | 426 |
| 24 | Terlemek | Exude | 530 |
| 25 | Yara | Wound | 499 |

$$Hata = 1 - \left(\frac{\text{Doğrulama seti doğru tahmin sayısı}}{\text{Doğrulama seti tüm örnek sayısı}} \right) \quad (1)$$

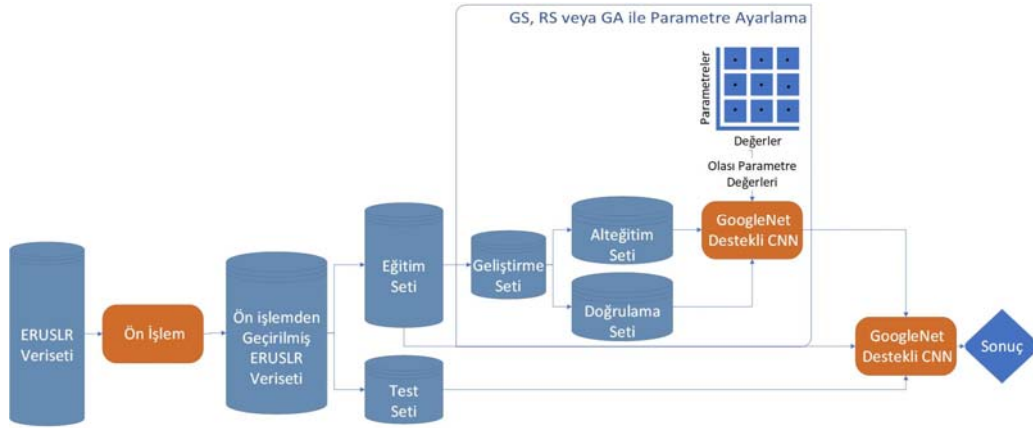
$$Doğruluk = 1 - \left(\frac{\text{Test seti doğru tahmin sayısı}}{\text{Test seti tüm örnek sayısı}} \right) \quad (2)$$

Önerilen yöntemde kullanılan hiperparametre arama yöntemleri alt bölüm 3.1 ile, transfer öğrenme destekli evrişimli sinir ağı alt bölüm 3.2 ile sunulmuştur.

3.1. Hiperparametre Ayarlama Yöntemleri (Hyperparameter Tuning Methods)

3.1.1. Grid arama yöntemi (Grid search method (GS))

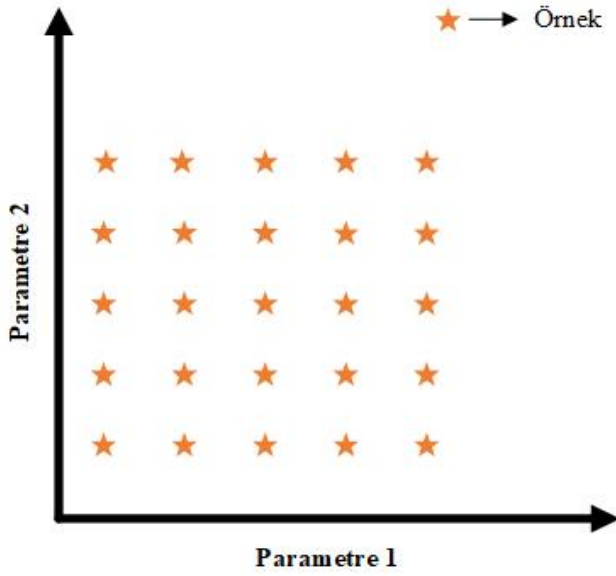
GS, bir modelin parametrelerini optimize etmek için kullanılan global bir arama yöntemidir. Bu yöntemle, modelin tüm parametrelerini optimize etmeye çalışmak oldukça zaman alan bir süreç olabilir. Bunun yerine, sonuca doğrudan etki edip performansı ciddi bir şekilde etkileyecek önemli parametreler üzerinde arama yapılabilir. Her bir parametre için olası farklı değerler belirlenir ve bu değerlerin tüm kombinasyonları (Şekil 5 örneğinde olduğu gibi) ilgili model için çalıştırılır. Performans kriterine göre en iyi sonucu veren parametre seti belirlenmiş olur. GS yöntemi, optimizasyon sürecinde zamansal fayda sağlamakla birlikte bütün arama uzayının eşit aralıklarla aranmasını sağlar. Bu avantajların yanında, sadece yerel en iyiyi bulma riski GS'nin dezavantajıdır.



Şekil 3. ERUSLR veri setini sınıflandırmak için önerilen yöntem (Proposed method for classifying the ERUSLR data set)



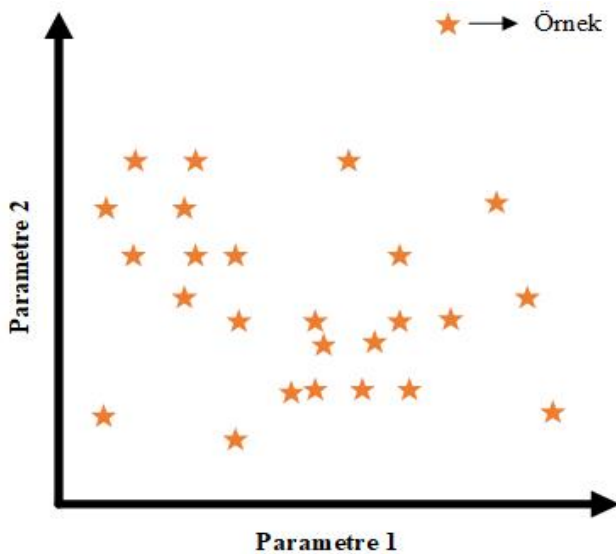
Şekil 4. Bir örnek üzerinde ön işleme çalışması (Pre-processing on a sample)



Şekil 5. GS için arama uzayındaki parametre setleri
(Parameter sets in the search space for grid search)

3.1.2. Rastgele arama yöntemi (Random search method (RS))

RS, GS yönteminde olduğu gibi bir modelin parametrelerini optimize etmede kullanılan global bir arama yöntemidir. Optimize edilecek parametrelerin alt ve üst sınırları belirlenir. Daha sonra her bir koşma için rastgele belirlenmiş parametre seti ile model eğitilip performans çıktısı alınır. Arama uzayında rastgele belirlenmiş parametre setleriyle (Şekil 6 örneğinde olduğu gibi) yapılan RS yöntemi ile zamansal kazanç sağlanabilir. Ayrıca global en iyiyi bulma ihtimali düşük de olsa vardır. Buna karşılık olarak parametre setleri rastgele seçildiğinden dolayı aramalar belirli noktalara sıkışıp arama uzayının her bölgesinde arama gerçekleştirilemeyebilir.



Şekil 6. RS için arama uzayındaki parametre setleri
(Parameter sets in the search space for random search)

3.1.3. Genetik algoritma (Genetic algorithm (GA))

GA, 1975'te John Holland ve arkadaşları tarafından önerilen sezgisel bir arama algoritmasıdır [37]. Kromozomlar genel çözümleri ifade ederken, GA'nın temel amacı en iyi uygunluk değerini veren gen dizilişinin bulunmasıdır. Durdurma kriteri sağlanana kadar algoritma olası çözümleri test etmeye ve en uygun sonucu veren gen dizilişini aramaya devam eder. GA'ya ait temel adımlar Algoritma 1 ile sunulmuştur.

Algoritma 1:

Adım 1: Başlangıç popülasyonu ve kontrol parametrelerinin belirlenmesi

Adım 2: Uygunluk değeri hesaplama

Tekrarla

Adım 3: Seleksiyon

Adım 4: Çaprazlama

Adım 5: Mutasyon

Durdurma kriteri sağlanana kadar


Algoritmanın ilk adımında, GA'nın mutasyon oranı, çaprazlama oranı, jenerasyon sayısı ve popülasyon büyüklüğü olan kontrol parametreleri ile başlangıç popülasyonu oluşturulur. Bir sonraki aşamada popülasyondaki her bir olası çözüm için uygunluk değeri hesaplanmaktadır. Daha sonra durdurma kriteri sağlanana kadar Adım 3, 4, 5 sırasıyla tekrarlanır. Adım 3 ile popülasyonda kaliteli çözümlerin artması, kalitesiz çözümlerin azalmasını sağlayan seleksiyon işlemi gerçekleştirilir. Rulet tekeri, sıralama ve turnuva en temel seleksiyon operatörleri arasında yer almaktadır. Adım 4'te çaprazlama işlemi ile yüksek kaliteye sahip bireylerden daha iyi bireylerin elde edilmesi amaçlanmaktadır. Son adım olan Adım 5 ile genetik çeşitliliğin sağlandığı mutasyon işlemi gerçekleştirilmektedir.

3.2. Transfer Öğrenme Destekli Evrişimli Sinir Ağı (Transfer Learning Aided Convolutional Neural Network)

3.2.1. Evrişimli sinir ağı (Convolutional neural network (CNN))


Evrişimli sinir ağı (CNN), bir görüntüyü girdi olarak alıp, kendi mimarisıyla çıkardığı özellikleri kullanarak görüntüyü anlamlandıran derin öğrenme metodudur [25]. Nesne tanıma, sınıflandırma gibi temel işlevleri olan CNN yapısı son yıllarda popüler kullanıma sahiptir. CNN, genellikle evrişim, ortaklama, düzleştirme ve tam bağlantı katmanlarına sahiptir. Örnek bir CNN mimarisi Şekil 7 ile sunulmuştur.

Evrişim katmanı, evrişim işleminin gerçekleştirildiği katmandır. Burada, girdi filtreden geçirilir ve elde edilen çıktı, özellik haritası veya aktivasyon haritası olarak adlandırılır [25]. Örnek bir evrişim işlemi Şekil 8 ile gösterilmiştir. Burada 2 boyutlu imge, evrişim çekirdeği olarak adlandırılan filtre ile çarpım işlemine uğradıktan sonra evrişmiş imge ortaya çıkmaktadır. Genellikle evrişim katmanından sonra kullanılan ortaklama katmanı ile mevcut



Şekil 7. Örnek bir CNN mimarisi (A sample architecture of CNN)

girdinin özelliklerini koruyarak daha küçük bir matris elde etmek amaçlanmaktadır. Maksimum ve ortalama ortaklama sıklıkla kullanılan ortaklama tipleridir [38]. Maksimuma ortaklama için işlem süreci Şekil 9 ile sunulduğu gibidir. Burada, 2x2'lik bloklar halinde imge ayrılır ve her bir bloktaki en büyük sayı alınarak ortaklama işlemi gerçekleştirilmiştir olur.



Şekil 8. Örnek bir evrişim işlemi (An example for convolution process)



Şekil 9. Örnek bir maksimuma ortaklama işlemi (An example for max pooling process)

Düzleştirme katmanı kendinden önceki matris formatındaki verileri tam bağlantı katmanına beslemek için hazırlar. CNN mimarisinin sonlarına doğru kullanılan tam bağlantı katmanı tüm nöronların önceki tüm girişe bağlı olduğu katmandır. Düzleştirme katmanından alınan veriler sinir ağı yoluyla eğitilir ve öğrenme işlemi gerçekleştirilir.

3.2.2. Transfer öğrenme (Transfer learning)

Bir sınıflandırma probleminin çözümü için yeni bir CNN mimarisi oluşturmak zahmetli ve zaman isteyen bir süreçtir. Bunun yerine ön eğitilmiş modellerden faydalanmak, yeni bir mimari kurmaya nazaran daha etkili bir yöntemdir. AlexNet

[25], GoogLeNet [39], ResNet50 [40], vb. modeller ön eğitilmiş model olarak adlandırılmaktadır. Ön eğitilmiş modeller kullanılarak sınıflandırma, özellik çıkarma veya transfer öğrenme gerçekleştirilebilir.

Transfer öğrenme, ön eğitilmiş modelin mimarisinden belirli bir katmana kadar olan kısmının atılarak, atılan katmanların yerine probleme uygun olan katmanların eklenmesiyle oluşmaktadır. Böylelikle ön eğitilmiş modelin düşük ve orta seviyeli özellik çıkarma katmanları transfer edilmiş olup, yüksek seviyeli özellik çıkarması mimariye sonradan eklenen ve ilgili sınıflandırma problemine uygun olarak seçilen katmanlarla gerçekleştirilir [41]. Örnek bir transfer öğrenme süreci adımları Şekil 10 ile gösterildiği gibidir. Bu çalışmada, 22 katman derinliğe sahip ve kullanımı popüler olan GoogLeNet ön eğitilmiş model kullanılarak transfer öğrenme gerçekleştirilmiştir.

4. DENEYSEL ÇALIŞMALAR (EXPERIMENTAL STUDIES)

GS, RS ve GA yöntemleri kullanılarak parametre ayarlaması ile transfer öğrenme destekli CNN kullanılarak sınıflandırma çalışmasının gerçekleştirildiği bu çalışmada ERUSLR veri seti üzerinde deneysel çalışmalar gerçekleştirilmiş ve sonuçlar detaylı bir şekilde sunulmuştur.

4.1. Deneysel Kurulum (Experimental Setup)

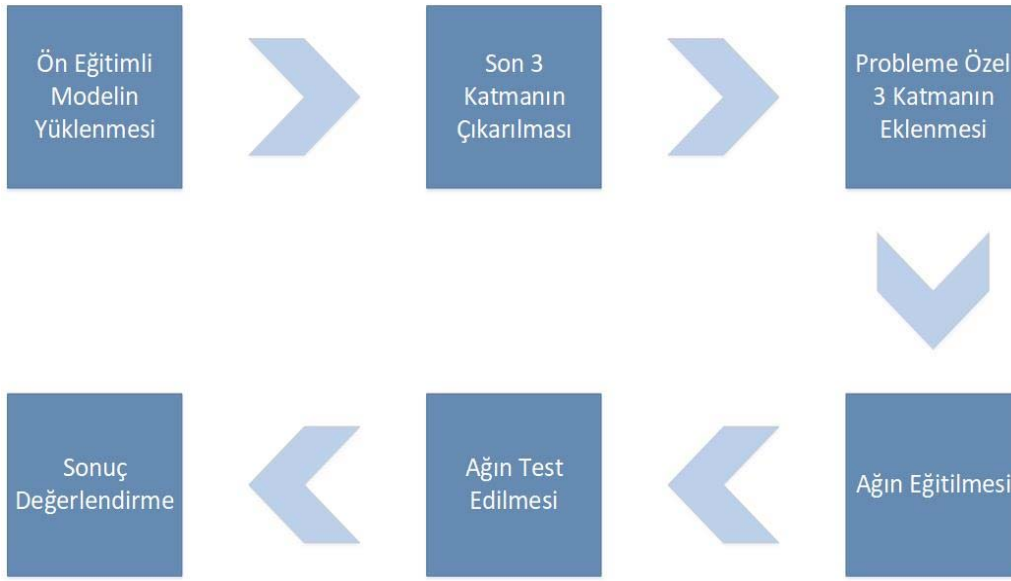
Deneysel kurulum, donanımsal kurulum ve parametre kurulumu olmak üzere iki alt başlıkta ele alınmıştır.

4.1.1. Donanımsal kurulum (Hardware setup)

Hem görsel veri üzerinde gerçekleştirildiği hem de veri setindeki büyük örnek sayısından dolayı bütün deneysel çalışmalar için 11 GB Ram destekli NVIDIA GTX 1080 Ti Turbo donanımı kullanılmıştır. Önerilen yöntem, Matlab 2019b platformunda koşulmuştur.

4.1.2. Parametre kurulumu (Parameter setup)

Önerilen yöntemde, parametre ayarlaması için GS, RS ve GA yöntemleri kullanılmıştır. GS için kullanılacak ilk öğrenme oranı (ILR), ℓ_2 düzenleme (ℓ_2R) ve momentum



Şekil 10. Örnek bir transfer öğrenme süreci adımları [38] (An example for main steps of transfer learning process)

(M) parametre değerleri Tablo 3 ile gösterilmiştir. RS yönteminde seçilecek ilk öğrenme oranı, ℓ_2 düzenleme ve momentum değerlerinin alt sınırı sırasıyla 0,001, 0,00001 ve 0,75 iken üst sınırı sırasıyla 0,01, 0,001 ve 0,95'tir. RS için kullanılan alt ve üst sınırlar GA için de kullanılmıştır. GA'da mutasyon oranı 0,20, çaprazlama oranı 0,80, popülasyon sayısı 5 ve iterasyon sayısı 25 olarak ayarlanmıştır. CNN modelinin eğitim parametreleri ayarında ilk öğrenme oranı, ℓ_2 düzenleme ve momentum parametrelerinin dışında var olan minibatch boyutu değeri 32 ve maksimum epok değeri 100 olarak seçilmiştir. CNN'in eğitiminde momentumlu stokastik gradyan inişi yöntemi kullanılmıştır.

Tablo 3. GS için kullanılan parametre değerleri
(Parameter values used in grid search)

| Parametre | Değerler | | | | |
|-----------|----------|--------|--------|-------|-------|
| ILR | 0,001 | 0,003 | 0,005 | 0,007 | 0,01 |
| ℓ_2R | 0,00001 | 0,0005 | 0,0001 | 0,005 | 0,001 |
| M | 0,75 | 0,80 | 0,85 | 0,90 | 0,95 |

4.2. Deneysel Sonuçlar (Experimental Results)

Bu çalışmada önerilen yöntem ERUSLR veri seti ile test edilmiştir. Önerilen yöntemde GS, RS ve GA yöntemleri sistemdeki CNN modelinin eğitim parametrelerini optimize etmek için kullanılmıştır. Tablo 4 incelendiğinde GS için oluşabilecek tüm parametre seti kombinasyonları ve bu parametre setlerine ait doğrulama hataları sunulmuştur. 0,3201 doğrulama hatasını veren parametre değerleri GS sonucunda hafızada tutulan en iyi parametre değerleridir. RS için oluşan rastgele parametre setleri ve bu parametre setlerine ait doğrulama hataları Tablo 5 ile sunulmuştur. Tablo 5 incelendiğinde 0,3208 doğrulama hatasını veren parametre değerleri RS sonucunda hafızada tutulan en iyi

parametre değerleridir. parametre optimizasyonu için GA koşuturulduğunda 0,3237 doğrulama hatasını veren parametre seti çıktı olarak verilmiştir. Bu parametre değerleri sırasıyla ILR = 0,0019, ℓ_2R = 0,00097 ve M = 0,85 olarak elde edilmiştir.

GS yöntemiyle elde edilen en iyi parametre seti ile eğitim verisi kullanılarak eğitilen GoogLeNet tabanlı CNN modeli ile test verisi üzerinde %93,63 doğruluk oranı elde edilmiştir. İlgili modelin test verisi üzerindeki karmaşıklık matrisi Şekil 11 ile gösterilmiştir.

RS yöntemiyle elde edilen en iyi parametre seti ile eğitim verisi kullanılarak eğitilen GoogLeNet tabanlı CNN modeli ile test verisi üzerinde %89,81 doğruluk oranı elde edilmiştir. İlgili modelin test verisi üzerindeki karmaşıklık matrisi Şekil 12 ile gösterilmiştir.

GA yöntemiyle elde edilen en iyi parametre seti ile eğitim verisi kullanılarak eğitilen GoogLeNet tabanlı CNN modeli ile test verisi üzerinde %93,93 doğruluk oranı elde edilmiştir. İlgili modelin test verisi üzerindeki karmaşıklık matrisi Şekil 13 ile gösterilmiştir.

Herhangi bir global arama yöntemi kullanılmadan sadece varsayılan eğitim parametre değerlerini kullanarak eğitilen GoogLeNet tabanlı CNN modeli ile test verisi üzerinde %88,62 doğruluk oranı elde edilmiştir. İlgili modelin test verisi üzerindeki karmaşıklık matrisi Şekil 14 ile gösterilmiştir.

GoogLeNet tabanlı CNN modeli ile GS, RS ve GA destekli GoogLeNet tabanlı CNN modelleri için kullanılan eğitim parametreleri değeri ve bu parametreler sonucunda elde edilen doğruluk oranları Tablo 6 ile gösterildiği gibidir. Tabloya göre GA destekli GoogLeNet tabanlı CNN en başarılı sonucu vermiştir.

Tablo 4. GS yönteminde belirlenen parametre değerleri ve hesaplanan doğrulama hataları
(Parameter values and validation errors determined in grid search method)

| No | ILR | ℓ_2R | M | H | No | ILR | ℓ_2R | M | H | No | ILR | ℓ_2R | M | H |
|----|-------|-----------|------|--------|----|-------|-----------|------|--------|-----|-------|-----------|------|--------|
| 1 | 0,001 | 0,00001 | 0,75 | 0,3691 | 43 | 0,003 | 0,00500 | 0,85 | 0,3576 | 85 | 0,007 | 0,00050 | 0,95 | 0,9517 |
| 2 | 0,001 | 0,00001 | 0,80 | 0,4232 | 44 | 0,003 | 0,00500 | 0,90 | 0,3518 | 86 | 0,007 | 0,00010 | 0,75 | 0,3497 |
| 3 | 0,001 | 0,00001 | 0,85 | 0,3857 | 45 | 0,003 | 0,00500 | 0,95 | 0,4845 | 87 | 0,007 | 0,00010 | 0,80 | 0,3439 |
| 4 | 0,001 | 0,00001 | 0,90 | 0,4009 | 46 | 0,003 | 0,00100 | 0,75 | 0,3684 | 88 | 0,007 | 0,00010 | 0,85 | 0,3771 |
| 5 | 0,001 | 0,00001 | 0,95 | 0,3035 | 47 | 0,003 | 0,00100 | 0,80 | 0,3605 | 89 | 0,007 | 0,00010 | 0,90 | 0,4247 |
| 6 | 0,001 | 0,00050 | 0,75 | 0,3958 | 48 | 0,003 | 0,00100 | 0,85 | 0,3583 | 90 | 0,007 | 0,00010 | 0,95 | 0,5083 |
| 7 | 0,001 | 0,00050 | 0,80 | 0,4110 | 49 | 0,003 | 0,00100 | 0,90 | 0,3360 | 91 | 0,007 | 0,00500 | 0,75 | 0,4196 |
| 8 | 0,001 | 0,00050 | 0,85 | 0,3850 | 50 | 0,003 | 0,00100 | 0,95 | 0,3800 | 92 | 0,007 | 0,00500 | 0,80 | 0,4420 |
| 9 | 0,001 | 0,00050 | 0,90 | 0,3619 | 51 | 0,005 | 0,00001 | 0,75 | 0,3785 | 93 | 0,007 | 0,00500 | 0,85 | 0,4470 |
| 10 | 0,001 | 0,00050 | 0,95 | 0,3331 | 52 | 0,005 | 0,00001 | 0,80 | 0,3901 | 94 | 0,007 | 0,00500 | 0,90 | 0,5811 |
| 11 | 0,001 | 0,00010 | 0,75 | 0,3973 | 53 | 0,005 | 0,00001 | 0,85 | 0,3720 | 95 | 0,007 | 0,00500 | 0,95 | 0,7931 |
| 12 | 0,001 | 0,00010 | 0,80 | 0,3915 | 54 | 0,005 | 0,00001 | 0,90 | 0,3951 | 96 | 0,007 | 0,00100 | 0,75 | 0,3922 |
| 13 | 0,001 | 0,00010 | 0,85 | 0,3821 | 55 | 0,005 | 0,00001 | 0,95 | 0,4650 | 97 | 0,007 | 0,00100 | 0,80 | 0,3828 |
| 14 | 0,001 | 0,00010 | 0,90 | 0,3720 | 56 | 0,005 | 0,00050 | 0,75 | 0,3857 | 98 | 0,007 | 0,00100 | 0,85 | 0,3634 |
| 15 | 0,001 | 0,00010 | 0,95 | 0,3273 | 57 | 0,005 | 0,00050 | 0,80 | 0,3518 | 99 | 0,007 | 0,00100 | 0,90 | 0,4146 |
| 16 | 0,001 | 0,00500 | 0,75 | 0,4146 | 58 | 0,005 | 0,00050 | 0,85 | 0,3821 | 100 | 0,007 | 0,00100 | 0,95 | 0,9517 |
| 17 | 0,001 | 0,00500 | 0,80 | 0,3836 | 59 | 0,005 | 0,00050 | 0,90 | 0,4124 | 101 | 0,010 | 0,00001 | 0,75 | 0,3886 |
| 18 | 0,001 | 0,00500 | 0,85 | 0,3764 | 60 | 0,005 | 0,00050 | 0,95 | 0,4463 | 102 | 0,010 | 0,00001 | 0,80 | 0,3598 |
| 19 | 0,001 | 0,00500 | 0,90 | 0,3670 | 61 | 0,005 | 0,00010 | 0,75 | 0,3634 | 103 | 0,010 | 0,00001 | 0,85 | 0,3879 |
| 20 | 0,001 | 0,00500 | 0,95 | 0,3944 | 62 | 0,005 | 0,00010 | 0,80 | 0,3381 | 104 | 0,010 | 0,00001 | 0,90 | 0,4470 |
| 21 | 0,001 | 0,00100 | 0,75 | 0,3893 | 63 | 0,005 | 0,00010 | 0,85 | 0,3691 | 105 | 0,010 | 0,00001 | 0,95 | 0,9531 |
| 22 | 0,001 | 0,00100 | 0,80 | 0,3468 | 64 | 0,005 | 0,00010 | 0,90 | 0,3526 | 106 | 0,010 | 0,00050 | 0,75 | 0,3518 |
| 23 | 0,001 | 0,00100 | 0,85 | 0,3641 | 65 | 0,005 | 0,00010 | 0,95 | 0,4585 | 107 | 0,010 | 0,00050 | 0,80 | 0,3446 |
| 24 | 0,001 | 0,00100 | 0,90 | 0,3706 | 66 | 0,005 | 0,00500 | 0,75 | 0,4456 | 108 | 0,010 | 0,00050 | 0,85 | 0,4167 |
| 25 | 0,001 | 0,00100 | 0,95 | 0,3360 | 67 | 0,005 | 0,00500 | 0,80 | 0,3547 | 109 | 0,010 | 0,00050 | 0,90 | 0,4996 |
| 26 | 0,003 | 0,00001 | 0,75 | 0,3619 | 68 | 0,005 | 0,00500 | 0,85 | 0,3792 | 110 | 0,010 | 0,00050 | 0,95 | 0,9517 |
| 27 | 0,003 | 0,00001 | 0,80 | 0,3720 | 69 | 0,005 | 0,00500 | 0,90 | 0,5213 | 111 | 0,010 | 0,00010 | 0,75 | 0,3655 |
| 28 | 0,003 | 0,00001 | 0,85 | 0,3338 | 70 | 0,005 | 0,00500 | 0,95 | 0,6301 | 112 | 0,010 | 0,00010 | 0,80 | 0,3778 |
| 29 | 0,003 | 0,00001 | 0,90 | 0,3684 | 71 | 0,005 | 0,00100 | 0,75 | 0,3800 | 113 | 0,010 | 0,00010 | 0,85 | 0,3843 |
| 30 | 0,003 | 0,00001 | 0,95 | 0,3742 | 72 | 0,005 | 0,00100 | 0,80 | 0,3259 | 114 | 0,010 | 0,00010 | 0,90 | 0,5501 |
| 31 | 0,003 | 0,00050 | 0,75 | 0,3627 | 73 | 0,005 | 0,00100 | 0,85 | 0,3439 | 115 | 0,010 | 0,00010 | 0,95 | 0,9531 |
| 32 | 0,003 | 0,00050 | 0,80 | 0,3670 | 74 | 0,005 | 0,00100 | 0,90 | 0,4348 | 116 | 0,010 | 0,00500 | 0,75 | 0,4859 |
| 33 | 0,003 | 0,00050 | 0,85 | 0,4182 | 75 | 0,005 | 0,00100 | 0,95 | 0,4535 | 117 | 0,010 | 0,00500 | 0,80 | 0,4492 |
| 34 | 0,003 | 0,00050 | 0,90 | 0,3201 | 76 | 0,007 | 0,00001 | 0,75 | 0,3785 | 118 | 0,010 | 0,00500 | 0,85 | 0,5032 |
| 35 | 0,003 | 0,00050 | 0,95 | 0,3396 | 77 | 0,007 | 0,00001 | 0,80 | 0,3526 | 119 | 0,010 | 0,00500 | 0,90 | 0,6128 |
| 36 | 0,003 | 0,00010 | 0,75 | 0,3879 | 78 | 0,007 | 0,00001 | 0,85 | 0,3410 | 120 | 0,010 | 0,00500 | 0,95 | 1,0000 |
| 37 | 0,003 | 0,00010 | 0,80 | 0,3699 | 79 | 0,007 | 0,00001 | 0,90 | 0,4218 | 121 | 0,010 | 0,00100 | 0,75 | 0,3396 |
| 38 | 0,003 | 0,00010 | 0,85 | 0,3627 | 80 | 0,007 | 0,00001 | 0,95 | 0,9517 | 122 | 0,010 | 0,00100 | 0,80 | 0,4037 |
| 39 | 0,003 | 0,00010 | 0,90 | 0,3713 | 81 | 0,007 | 0,00050 | 0,75 | 0,3915 | 123 | 0,010 | 0,00100 | 0,85 | 0,3915 |
| 40 | 0,003 | 0,00010 | 0,95 | 0,3901 | 82 | 0,007 | 0,00050 | 0,80 | 0,4117 | 124 | 0,010 | 0,00100 | 0,90 | 0,5912 |
| 41 | 0,003 | 0,00500 | 0,75 | 0,3699 | 83 | 0,007 | 0,00050 | 0,85 | 0,3987 | 125 | 0,010 | 0,00100 | 0,95 | 0,9517 |
| 42 | 0,003 | 0,00500 | 0,80 | 0,3482 | 84 | 0,007 | 0,00050 | 0,90 | 0,3605 | | | | | |

Tablo 5. RS yönteminde belirlenen parametre değerleri ve hesaplanan doğrulama hataları
(Parameter values and validation errors determined in random search method)


| No | ILR | ℓ_2R | M | H | No | ILR | ℓ_2R | M | H | No | ILR | ℓ_2R | M | H |
|----|--------|-----------|------|--------|----|--------|-----------|------|--------|-----|--------|-----------|------|--------|
| 1 | 0,0045 | 0,00047 | 0,76 | 0,3764 | 43 | 0,0094 | 0,00053 | 0,85 | 0,4290 | 85 | 0,0019 | 0,00077 | 0,78 | 0,3727 |
| 2 | 0,0055 | 0,00083 | 0,85 | 0,3612 | 44 | 0,0036 | 0,00033 | 0,85 | 0,3922 | 86 | 0,0084 | 0,00094 | 0,95 | 0,9517 |
| 3 | 0,0018 | 0,00070 | 0,93 | 0,3345 | 45 | 0,0036 | 0,00093 | 0,84 | 0,3432 | 87 | 0,0079 | 0,00097 | 0,85 | 0,3663 |
| 4 | 0,0100 | 0,00033 | 0,86 | 0,3720 | 46 | 0,0093 | 0,00004 | 0,86 | 0,5061 | 88 | 0,0018 | 0,00092 | 0,81 | 0,3691 |
| 5 | 0,0092 | 0,00004 | 0,76 | 0,3590 | 47 | 0,0080 | 0,00081 | 0,80 | 0,3317 | 89 | 0,0061 | 0,00074 | 0,82 | 0,3713 |
| 6 | 0,0022 | 0,00019 | 0,77 | 0,3706 | 48 | 0,0081 | 0,00084 | 0,87 | 0,4074 | 90 | 0,0063 | 0,00028 | 0,94 | 0,4766 |
| 7 | 0,0040 | 0,00056 | 0,89 | 0,3973 | 49 | 0,0011 | 0,00087 | 0,90 | 0,4110 | 91 | 0,0049 | 0,00008 | 0,89 | 0,3533 |
| 8 | 0,0069 | 0,00039 | 0,86 | 0,3893 | 50 | 0,0059 | 0,00013 | 0,81 | 0,3295 | 92 | 0,0052 | 0,00022 | 0,88 | 0,3208 |
| 9 | 0,0080 | 0,00012 | 0,77 | 0,3720 | 51 | 0,0018 | 0,00029 | 0,94 | 0,3562 | 93 | 0,0015 | 0,00022 | 0,82 | 0,3944 |
| 10 | 0,0022 | 0,00079 | 0,89 | 0,3778 | 52 | 0,0057 | 0,00074 | 0,77 | 0,3208 | 94 | 0,0053 | 0,00047 | 0,80 | 0,3677 |
| 11 | 0,0099 | 0,00068 | 0,93 | 0,5263 | 53 | 0,0077 | 0,00086 | 0,76 | 0,3670 | 95 | 0,0078 | 0,00096 | 0,77 | 0,3720 |
| 12 | 0,0029 | 0,00089 | 0,93 | 0,3785 | 54 | 0,0084 | 0,00003 | 0,91 | 0,4275 | 96 | 0,0014 | 0,00018 | 0,79 | 0,3547 |
| 13 | 0,0035 | 0,00086 | 0,85 | 0,3345 | 55 | 0,0019 | 0,00097 | 0,84 | 0,3590 | 97 | 0,0050 | 0,00007 | 0,90 | 0,3583 |
| 14 | 0,0057 | 0,00091 | 0,80 | 0,3482 | 56 | 0,0047 | 0,00047 | 0,86 | 0,3396 | 98 | 0,0091 | 0,00050 | 0,89 | 0,4254 |
| 15 | 0,0066 | 0,00077 | 0,89 | 0,3518 | 57 | 0,0060 | 0,00032 | 0,76 | 0,3612 | 99 | 0,0011 | 0,00003 | 0,77 | 0,3800 |
| 16 | 0,0070 | 0,00054 | 0,77 | 0,3886 | 58 | 0,0088 | 0,00081 | 0,75 | 0,3547 | 100 | 0,0057 | 0,00053 | 0,78 | 0,3533 |
| 17 | 0,0049 | 0,00066 | 0,86 | 0,3994 | 59 | 0,0051 | 0,00005 | 0,79 | 0,3951 | 101 | 0,0025 | 0,00061 | 0,88 | 0,3374 |
| 18 | 0,0046 | 0,00056 | 0,95 | 0,4376 | 60 | 0,0058 | 0,00084 | 0,81 | 0,3677 | 102 | 0,0019 | 0,00045 | 0,93 | 0,3324 |
| 19 | 0,0041 | 0,00068 | 0,93 | 0,4297 | 61 | 0,0061 | 0,00097 | 0,83 | 0,4037 | 103 | 0,0049 | 0,00070 | 0,77 | 0,3929 |
| 20 | 0,0049 | 0,00049 | 0,84 | 0,3901 | 62 | 0,0025 | 0,00047 | 0,94 | 0,3605 | 104 | 0,0070 | 0,00038 | 0,86 | 0,3576 |
| 21 | 0,0045 | 0,00026 | 0,76 | 0,3432 | 63 | 0,0088 | 0,00085 | 0,85 | 0,4001 | 105 | 0,0081 | 0,00061 | 0,87 | 0,4484 |
| 22 | 0,0067 | 0,00004 | 0,82 | 0,3619 | 64 | 0,0064 | 0,00057 | 0,95 | 0,5061 | 106 | 0,0088 | 0,00086 | 0,88 | 0,4211 |
| 23 | 0,0071 | 0,00011 | 0,81 | 0,3526 | 65 | 0,0047 | 0,00047 | 0,83 | 0,3475 | 107 | 0,0055 | 0,00009 | 0,91 | 0,3980 |
| 24 | 0,0095 | 0,00009 | 0,86 | 0,3807 | 66 | 0,0046 | 0,00043 | 0,91 | 0,3670 | 108 | 0,0022 | 0,00008 | 0,93 | 0,3547 |
| 25 | 0,0079 | 0,00029 | 0,76 | 0,3482 | 67 | 0,0094 | 0,00047 | 0,93 | 0,9272 | 109 | 0,0013 | 0,00052 | 0,83 | 0,3518 |
| 26 | 0,0055 | 0,00059 | 0,87 | 0,3583 | 68 | 0,0092 | 0,00011 | 0,88 | 0,4189 | 110 | 0,0091 | 0,00092 | 0,81 | 0,3850 |
| 27 | 0,0030 | 0,00002 | 0,94 | 0,3663 | 69 | 0,0035 | 0,00009 | 0,76 | 0,3648 | 111 | 0,0082 | 0,00083 | 0,87 | 0,3792 |
| 28 | 0,0040 | 0,00055 | 0,91 | 0,3417 | 70 | 0,0033 | 0,00041 | 0,75 | 0,3684 | 112 | 0,0055 | 0,00035 | 0,89 | 0,3526 |
| 29 | 0,0083 | 0,00011 | 0,87 | 0,3987 | 71 | 0,0056 | 0,00057 | 0,80 | 0,3850 | 113 | 0,0053 | 0,00084 | 0,82 | 0,3482 |
| 30 | 0,0023 | 0,00060 | 0,85 | 0,3879 | 72 | 0,0065 | 0,00082 | 0,77 | 0,3922 | 114 | 0,0084 | 0,00072 | 0,81 | 0,4448 |
| 31 | 0,0061 | 0,00050 | 0,92 | 0,3893 | 73 | 0,0061 | 0,00095 | 0,84 | 0,3857 | 115 | 0,0016 | 0,00064 | 0,80 | 0,3684 |
| 32 | 0,0079 | 0,00005 | 0,76 | 0,3273 | 74 | 0,0070 | 0,00004 | 0,84 | 0,3490 | 116 | 0,0067 | 0,00020 | 0,85 | 0,3598 |
| 33 | 0,0092 | 0,00071 | 0,93 | 0,9517 | 75 | 0,0057 | 0,00071 | 0,87 | 0,3814 | 117 | 0,0053 | 0,00073 | 0,82 | 0,3872 |
| 34 | 0,0086 | 0,00088 | 0,90 | 0,4131 | 76 | 0,0084 | 0,00017 | 0,79 | 0,3821 | 118 | 0,0042 | 0,00010 | 0,94 | 0,3864 |
| 35 | 0,0050 | 0,00050 | 0,92 | 0,3583 | 77 | 0,0051 | 0,00045 | 0,90 | 0,3850 | 119 | 0,0021 | 0,00090 | 0,92 | 0,3259 |
| 36 | 0,0056 | 0,00056 | 0,95 | 0,4333 | 78 | 0,0078 | 0,00086 | 0,88 | 0,3836 | 120 | 0,0011 | 0,00031 | 0,86 | 0,4102 |
| 37 | 0,0051 | 0,00070 | 0,92 | 0,4124 | 79 | 0,0097 | 0,00028 | 0,77 | 0,3735 | 121 | 0,0030 | 0,00072 | 0,81 | 0,3576 |
| 38 | 0,0049 | 0,00002 | 0,90 | 0,3720 | 80 | 0,0088 | 0,00089 | 0,85 | 0,3915 | 122 | 0,0090 | 0,00006 | 0,76 | 0,3706 |
| 39 | 0,0028 | 0,00085 | 0,81 | 0,3706 | 81 | 0,0098 | 0,00085 | 0,87 | 0,4052 | 123 | 0,0014 | 0,00069 | 0,94 | 0,3562 |
| 40 | 0,0046 | 0,00009 | 0,83 | 0,3259 | 82 | 0,0064 | 0,00062 | 0,91 | 0,3922 | 124 | 0,0047 | 0,00032 | 0,94 | 0,4420 |
| 41 | 0,0083 | 0,00052 | 0,87 | 0,4174 | 83 | 0,0037 | 0,00071 | 0,93 | 0,3619 | 125 | 0,0038 | 0,00070 | 0,88 | 0,3381 |
| 42 | 0,0078 | 0,00084 | 0,92 | 0,4268 | 84 | 0,0040 | 0,00046 | 0,85 | 0,4268 | | | | | |

| | | | | | | | | | | | | | | | | | | | | | | | | | | |
|-----------------|-------------|---------------------|------|--------|-------|------|------------|-------------|-------|--------|-------|---------|------|-----------|------|------|-----|-------|-------|--------|-------|-------|-----------------|----------|----------|------|
| Doğru sınıf | Agiz | 172 | 1 | | | | 2 | 5 | 2 | | 1 | | 1 | 2 | | | | | | | | | | | | |
| | Agri | 1 | 110 | | | 2 | | | | | | 2 | | | 2 | | 1 | | | | | | | | | |
| | Alerji | 1 | | 159 | 1 | | | | 1 | | | 3 | 1 | | | 1 | | | 2 | | | | | | | |
| | Astim | | | | 158 | | 4 | | 1 | | | | | | 2 | | | | 1 | | | | | | | |
| | Ates | | | 1 | 118 | | | | | | | | | 1 | | 2 | 2 | 1 | | | | | | | | |
| | Bas_Agrisi | 1 | | | | 168 | 3 | 1 | 1 | 3 | 2 | | 2 | | 1 | | | | | | | | | | | |
| | Bas_Donmesi | | | 2 | 3 | 1 | 103 | | | | 1 | 1 | | | | 1 | | | | | | | | | | |
| | Beyin | 1 | | | | 2 | | 160 | | 2 | | | | | | | | | | | | | | | | |
| | Bobrek | 2 | | | | | | 180 | | 2 | | | 1 | | | | | | | | | | | | | |
| | Bogaz | 2 | | | | 1 | | | 159 | 5 | | | | | 4 | | | | | | | | | | | |
| | Bulanti | 1 | | | | | | 3 | 1 | 167 | | | | 2 | 11 | | | | | | | | | | | |
| | Grip | 2 | | | | 1 | | | 1 | 167 | | | | | 1 | | | | | | | | | | | |
| | Halsizlik | | 1 | | 2 | 4 | | | 1 | 1 | 142 | 1 | 1 | | 2 | | | | 1 | | | | | | | |
| | Ilac | 1 | | 2 | | | 2 | | 3 | | | 152 | 2 | 2 | 1 | | | | | | | | | | | |
| | Kalp | 1 | | | | | | | | | 3 | 122 | 1 | 2 | 1 | | 3 | | | | | | | | | |
| | Kan | 2 | 1 | 1 | | | | | 1 | 1 | | | 149 | 2 | 1 | | | | | | | | | | | |
| | Karin | | | 1 | | | | 2 | 1 | 9 | | | | 152 | | 1 | | | | | | | | | | |
| | Kemik | | | | 4 | | | | 2 | 2 | 1 | 3 | | | 144 | 1 | 3 | | 3 | | | | | | | |
| | Kusmak | 2 | | | | | | | 7 | | | | | 3 | | 174 | | 1 | | | | | | | | |
| | Nabiz | | | | 1 | | | | | | | | | | | | 151 | 1 | 1 | | | | | | | |
| Nefes | 3 | | | | | 1 | | 1 | 1 | | 1 | | | 1 | | 100 | | | | | | | | | | |
| Seker_Hastaligi | | | 6 | 1 | | | | | | | | 1 | 1 | 1 | | | 179 | 1 | | | | | | | | |
| Tansiyon | | | 2 | 1 | | | | | | | | | 5 | 1 | | | | 119 | | | | | | | | |
| Terlemek | | | | | | | | | | 3 | | | | | | | 1 | 155 | | | | | | | | |
| Yara | | | | 1 | | | | | | | 1 | | 4 | | | | | | 144 | | | | | | | |
| | | Agiz | Agri | Alerji | Astim | Ates | Bas_Agrisi | Bas_Donmesi | Beyin | Bobrek | Bogaz | Bulanti | Grip | Halsizlik | Ilac | Kalp | Kan | Karin | Kemik | Kusmak | Nabiz | Nefes | Seker_Hastaligi | Tansiyon | Terlemek | Yara |
| | | Tahmin edilen sınıf | | | | | | | | | | | | | | | | | | | | | | | | |


Şekil 11. GS destekli modelin karmaşıklık matrisi (Confusion matrix of grid search supported model)

| | | | | | | | | | | | | | | | | | | | | | | | | | | | |
|-------------|-----------------|---------------------|------|------|--------|-------|------|------------|-------------|-------|--------|-------|---------|------|-----------|------|------|-----|-------|-------|--------|-------|-------|-----------------|----------|----------|------|
| Doğru sınıf | Agiz | 148 | 1 | 2 | | 3 | 1 | 3 | 6 | 2 | 6 | | 2 | | 1 | 10 | 1 | | | | | | | | | | |
| | Agri | 1 | 108 | | 1 | | 2 | | | | 1 | | | | 2 | | | | | | | | 3 | | | | |
| | Alerji | | | 138 | 6 | | | | | | 1 | | | | | 2 | 22 | | | | | | | | | | |
| | Astim | | | | 162 | | | 1 | | | | | | | | | 1 | | | | | 2 | | | | | |
| | Ates | | | | 2 | 116 | | | | | | | 1 | 2 | | 1 | | | | 2 | | | | | 1 | | |
| | Bas_Agrisi | | | | | | 163 | 5 | 4 | 3 | 2 | 1 | 2 | | | | | | | 1 | | | | 1 | | | |
| | Bas_Donmesi | 1 | | | | | 2 | 101 | 2 | | | | 2 | | | | | 3 | 1 | | | | | | | | |
| | Beyin | 1 | | | | | 1 | | 156 | | | | | 3 | | | | 4 | | | | | | | | | |
| | Bobrek | | | | 1 | | | | | 175 | | 1 | | | | | | | | 6 | | | | | | | 2 |
| | Bogaz | 3 | | | | 4 | | | | 1 | 149 | 6 | | | | | | | 3 | 3 | 4 | | 1 | | | | |
| | Bulanti | | | | 3 | | | | | 2 | | 160 | 1 | | | | | | 15 | 3 | | | 1 | | | | |
| | Grip | 5 | | | | | | | 2 | 3 | 1 | | 156 | | | | | | 1 | 3 | 1 | 1 | | | | | |
| | Halsizlik | | | | 4 | 4 | | | | 1 | | | | 135 | 1 | | | | 1 | 5 | 1 | 2 | 1 | | | | 1 |
| | Ilac | 1 | | 1 | 2 | | | 2 | 1 | 3 | | 6 | 1 | 142 | 2 | 2 | | | | 1 | 1 | 1 | | | | | |
| | Kalp | | | | | | | | 4 | | | | | | | | 123 | | | 3 | 1 | 2 | | | | | |
| | Kan | 3 | | 2 | 2 | | | | 1 | 3 | 1 | 1 | 2 | | | 1 | 134 | 3 | | 2 | 1 | | | | | | 2 |
| | Karin | | | | | | | | | | | 3 | | | | | | 163 | | | | | | | | | |
| | Kemik | | | | 3 | | | | | | | | 1 | 2 | | 2 | | | | 151 | 2 | 1 | | 1 | | | 2 |
| | Kusmak | | | | | | | | | | | | 20 | 3 | | | | | 14 | | 150 | | | | | | |
| | Nabiz | | | 2 | 4 | | | | | 1 | | | | | | | | | | 1 | | 148 | | | | | 1 |
| | Nefes | | | | 2 | | | 1 | | | | | 2 | | 2 | | | | | 1 | | | 100 | | | | |
| | Seker_Hastaligi | | | 5 | 5 | | 3 | | | 1 | | | | | | | 4 | | | 3 | | | | 167 | | | 2 |
| | Tansiyon | | | | 2 | | | | | | | | | | | 1 | | | 7 | 5 | | | | | 111 | | 2 |
| | Terlemek | | | | | | | | 1 | | | | | 1 | | | | | | | | | 1 | 1 | | | 155 |
| | Yara | | | | | 4 | | | | | | | | | | | | 1 | | | | 3 | | | | | 142 |
| | | | Agiz | Agri | Alerji | Astim | Ates | Bas_Agrisi | Bas_Donmesi | Beyin | Bobrek | Bogaz | Bulanti | Grip | Halsizlik | Ilac | Kalp | Kan | Karin | Kemik | Kusmak | Nabiz | Nefes | Seker_Hastaligi | Tansiyon | Terlemek | Yara |
| | | Tahmin edilen sınıf | | | | | | | | | | | | | | | | | | | | | | | | | |

Şekil 12. RS destekli modelin karmaşıklık matrisi (Confusion matrix of random search supported model)



Şekil 13. GA destekli modelin karmaşıklık matrisi (Confusion matrix of GA supported model)



Şekil 14. Global arama destekli modelin karmaşıklık matrisi (Confusion matrix of global search unsupported model)

Tablo 6. Arama yöntemi destekli / destekli parametre seçimi ve doğruluk oranları (Search method supported / unsupported parameter selection and accuracy rates)

| Metot | ILR | ℓ ₂ R | M | Doğruluk (%) |
|-----------------------------|--------|------------------|------|--------------|
| GS + GoogLeNet destekli CNN | 0,0030 | 0,00050 | 0,90 | 93,63 |
| RS + GoogLeNet destekli CNN | 0,0057 | 0,00074 | 0,77 | 89,81 |
| GA + GoogLeNet destekli CNN | 0,0019 | 0,00097 | 0,85 | 93,93 |
| GoogLeNet destekli CNN | 0,0100 | 0,00010 | 0,90 | 88,62 |

5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, öncelikle, hastane ortamında kullanılan kelimeleri içeren ERUSLR adında yeni bir veri seti oluşturulmuştur. Bu veri setinin sınıflandırılması için literatürde sıklıkla kullanılan ve bir derin öğrenme metodu olan CNN kullanılması amaçlanmıştır. Yeni bir CNN modelinin geliştirilmesi zorlu bir süreç gerektirdiğinden GoogLeNet ön eğitilmiş model kullanılarak transfer öğrenme destekli bir CNN modeli oluşturulmuştur. GoogLeNet tabanlı CNN modelinin başarımını artırmak için eğitim parametrelerini optimize etmek bu çalışmanın bir diğer amacı olmuştur. Global arama algoritmalarından en yaygın kullanılan GS ve RS yöntemleri ile yaygın kullanılan sezgisel arama yöntemlerinden GA, GoogLeNet tabanlı CNN modelinin eğitim parametrelerini optimize etmek için kullanılmıştır. Eğitim parametreleri arama yöntemleriyle optimize edilmiş CNN modelinin başarımları doğruluk oranı kriterine göre incelenmiştir. Elde edilen deneysel sonuçlar incelendiğinde, GA yöntemi destekli GoogLeNet tabanlı CNN modelinin başarımı diğer arama yöntemi destekli GoogLeNet tabanlı CNN modellerine göre daha yüksektir. Arama yöntemleri kullanılmadan sadece varsayılan eğitim parametreleri kullanılarak gerçekleştirilen çalışmanın başarımı, arama yöntemi destekli modellere göre daha düşük kalmıştır.

Gelecek çalışmalar için parametre optimizasyonunda farklı global ve sezgisel arama yöntemlerinin kullanılması ve performans kıyaslaması amaçlanmaktadır. Bunun yanında, GoogLeNet dışında farklı ön eğitilmiş modeller kullanılarak transfer öğrenme gerçekleştirip performans analizi yapılabilir. Ayrıca, önerilen metodun farklı veri setleriyle test edilmesi bir diğer gelecek çalışma planıdır.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Sosyal ve Beşerî Bilimler Etik Kurulu'ndan 113 nolu başvuru ile 25.12.2018'de izin alınarak oluşturulan ERUSLR, hastane ortamında kullanılmak üzere geliştirilen ve genel kullanıma açılan bir veri setidir. Bu veri setinin oluşumunda gönüllü olan değerli katılımcılara ve veri setinin toplanmasında yardımcı olan Gamze Korkmaz ve Nergis Baktır'a teşekkür ederiz.

KAYNAKLAR (REFERENCES)

1. Ong E.J., Cooper H., Pugeault N., Bowden R., Sign language recognition using sequential pattern trees, Conference on Computer Vision and Pattern Recognition, Washington-USA, 2200–2207, 16-21 Haziran, 2012.
2. Ong E.J., Koller O., Pugeault N., Bowden R., Sign spotting using hierarchical sequential patterns with temporal intervals, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Washington-USA, 1923–1930, 23-28 Haziran, 2014.
3. Athitsos V., Neidle C., Sclaroff S., Nash J., Stefan A., Yuan Q., Thangali A., The american sign language

lexicon video dataset, 2008 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, Alaska-USA, 1–8, 23-28 Haziran, 2008.

4. Neidle C., Thangali A., Sclaroff S., Challenges in development of the american sign language lexicon video dataset(asllvd)corpus, Proc.5th Workshop on the Representation and Processing of Sign Languages: Interactions between Corpus and Lexicon, Language Resources and Evaluation Conference (LREC) 2012, İstanbul-Turkey, 1-8, 23-27 Mayıs 2012.
5. Kim J.H., Kim N., Park H., Park J.C., Enhanced sign language transcription system via hand tracking and pose estimation, Journal of Computing Science and Engineering, 10 (3), 95–101, 2016.
6. Metaxas D., Dilsizian M., Neidle C., Scalable ASL sign recognition using model-based machine learning and linguistically annotated corpora, 8th Workshop on the Representation & Processing of Sign Languages: Involving the Language Community, Language Resources and Evaluation Conference, Miyazaki-Japan, 1-5, 12 Mayıs, 2018.
7. Oszust M., Wysocki M., Polish sign language words recognition with Kinect, 2013 6th International Conference on Human System Interactions (HSI), Gdansk-Poland, 219–226, 6-8 Haziran, 2013.
8. Oszust M. ve Wysocki M., Some Approaches to Recognition of Sign Language Dynamic Expressions with Kinect, Advances in Intelligent Systems and Computing, vol 300, Hippe Zdzisaw S., Springer Cham, 75-86, 2014.
9. Kapuscinski T., Oszust M., Wysocki M., Warchol D., Recognition of hand gestures observed by depth cameras, International Journal of Advanced Robotic Systems, 12 (4), 36, 1-15, 2015.
10. Ronchetti F., Quiroga F., Estrebow C.A., Lanzarini L.C., Rosete A., LSA64: an Argentinian sign language dataset, CACIC 2016, Roma-Italy, 1-10, 3-7 Ekim, 2016.
11. Ronchetti F., Thesis Overview: Dynamic Gesture Recognition and its Application to Sign Language, Journal of Computer Science and Technology, 17, 1–10, 2017.
12. Konstantinidis D., Dimitropoulos K., Daras P., Sign Language Recognition based on Hand and Body Skeletal Data, 3DTV-Conference: The True Vision - Capture, Transmission and Display of 3D Video (3DTV-CON), Haziran, 1–4, 2018.
13. Masood S., Srivastava A., Thuwal H.C., Ahmad M., Real-Time Sign Language Gesture (Word) Recognition from Video Sequences Using CNN and RNN, Intelligent Engineering Informatics, Springer Singapore, 623–632, 2018.
14. Chai X., Wang H., Chen X., The devisign large vocabulary of chinese sign language database and baseline evaluations, Technical report VIPL-TR-14-SLR-001. Key Lab of Intelligent Information Processing of Chinese Academy of Sciences (CAS), Institute of Computing Technology, 2014.

15. Zheng L., Liang B., Sign language recognition using depth images, 14th International Conference on Control, Automation, Robotics and Vision (ICARCV), Phuket-Thailand, 1-6, 13-15 Kasım, 2016.
16. Yıldız O., Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study, Journal of the Faculty of Engineering and Architecture of Gazi University, 34 (4), 2241–2260, 2019.
17. Basturk, A., Sarikaya Basturk N., Qurbanov O., A comparative performance analysis of various classifiers for finger print recognition, Omer Halisdemir Universitesi Muhendislik Bilimleri Dergisi, 7, 504 – 513, 2018.
18. Badem H., Basturk A., Caliskan A., Yuksel M.E., A new efficient training strategy for deep neural networks by hybridization of artificial bee colony and limited-memory BFGS optimization algorithms, Neurocomputing, 266, 506 – 526, 2017.
19. Arı A., Hanbay D., Tumor detection in MR images of regional convulsive neural networks, Journal of the Faculty of Engineering and Architecture of Gazi University, 34 (3), 1395 – 1408, 2019.
20. Yuksel M.E., Basturk N.S., Badem H., Caliskan A., Basturk A., Classification of high resolution hyperspectral remote sensing data using deep neural networks, Journal of Intelligent & Fuzzy Systems, 34, 2273–2285, 2018.
21. Badem H., Basturk A., Caliskan A., Yuksel M.E., A new hybrid optimization method combining artificial bee colony and limited-memory BFGS algorithms for efficient numerical optimization, Applied Soft Computing, 70, 826 – 844, 2018.
22. Maraqa M., Abu-Zaiter R., Recognition of Arabic Sign Language (ArSL) using recurrent neural networks, 2008 First International Conference on the Applications of Digital Information and Web Technologies (ICADIWT), Ostrava-Czech Republic, 478–481, 4-6 Ağustos, 2008.
23. Flores C.J.L., Cutipa A.G., Enciso R.L., Application of convolutional neural networks for static hand gestures recognition under different invariant features, International Conference on Electronics, Electrical Engineering and Computing (INTERCON), Cuzco-Peru, 1–4, 15-18 Ağustos, 2017.
24. Alashhab S., Gallego A.J., Lozano M.Á., Hand Gesture Detection with Convolutional Neural Networks, International Symposium on Distributed Computing and Artificial Intelligence, 45–52, Springer, 2018.
25. Krizhevsky A., Sutskever I., Hinton G.E., ImageNet Classification with Deep Convolutional Neural Networks, NIPS, 1106–1114, 2012.
26. Cote-Allard U., Fall C.L., Campeau-Lecours A., Gosselin C., Laviolette F., Gosselin B., Transfer learning for sEMG hand gestures recognition using convolutional neural networks, 2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Banff-Canada, 1663–1668, 5-8 Ekim, 2017.
27. Sanchez-Illana A., Pérez-Guaita D., Cuesta-García D., Sanjuan-Herráez J.D., Vento, M. Ruiz-Cerdá J.L., Quintas G., Kuligowski J., Model selection for within-batch effect correction in UPLC-MS metabolomics using quality control-Support vector regression, Analyticachimicaacta, 1026, 62–68, 2018.
28. Ozcan, T., Basturk, A., Transfer learning-based convolutional neural networks with heuristic optimization for hand gesture recognition, Neural Computing and Applications, 31 (12), 8955–8970, 2019.
29. Chen P., Xie Y., Jin P., Zhang D., A wireless sensor data-based coalmine gas monitoring algorithm with least squares support vector machines optimized by swarm intelligence techniques, International Journal of Distributed Sensor Networks, 14 (5), 1–21, 2018.
30. Stoean R., Analysis on the potential of an EA-surrogate modelling tandem for deep learning parameter optimization: an example for cancer classification from medical images, Neural Computing and Applications, 1-10, 2018.
31. Rubio G., Pomares H., Rojas I., Herrera L.J., A heuristic method for parameter selection in LS-SVM: Application to time series prediction, International Journal of Forecasting, 27 (3), 725 – 739, 2011.
32. Klein A., Falkner S., Bartels S., Hennig P., Hutter F., Fast bayesian optimization of machine learning hyperparameters on large datasets, arXiv, preprint arXiv:1605.07079, 1-9, 2016.
33. Hinz T., Navarro-Guerrero N., Magg S., Wermter S., Speeding up the hyperparameter optimization of deep convolutional neural networks, International Journal of Computational Intelligence and Applications, 17 (02), 1-15, 2018.
34. Kousias K., Riegler M., Alay Ö., Argyriou A., HINDSIGHT: An R-based framework towards long short term memory (LSTM) optimization, Proceedings of the 9th ACM Multimedia Systems Conference, Amsterdam-Netherlands, 381–386, 12-15 Haziran, 2018.
35. Czuszynski K., Ruminski J., Kwasniewska A., Gesture recognition with the linear optical sensor and recurrent neural networks, IEEE Sensors Journal, 18 (13), 5429–5438, 2018.
36. Ng, A., Machine Learning Yearning, deeplearning.ai., 2018.
37. Holland, J.H., 1992. Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence, A Bradford Book.
38. Ozcan T., Basturk, A., Static Image-Based Emotion Recognition Using Convolutional Neural Network, Signal Processing and Communications Applications Conference (SIU), Sivas-Turkey, 1–4, 24-26 Nisan, 2019.
39. Szegedy C., Liu W., Jia Y., Sermanet P., Reed S.E., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A., Going Deeper with Convolutions, CoRR, 1409.4842, 1-12, 2014.

40. He K., Zhang X., Ren S., Sun J., Deep Residual Learning for Image Recognition, CoRR, 1512.03385, 1-12, 2015.
41. Ozcan T., Basturk A., Lip Reading Using Convolutional Neural Networks with and without Pre-Trained Models, Balkan Journal of Electrical and Computer Engineering, 7 (2), 195–201, 2019.