

## PAPER DETAILS

TITLE: Derin Öğrenme Yapilari ile Elektromanyetik Örnekleme Kalorimetresinde ?0/? Ayirt Edilmesi

AUTHORS: Gral AYDIN,Hasan SARIGL

PAGES: 1175-1180

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/2148754>



# Derin Öğrenme Yapıları ile Elektromanyetik Örneklem Kalorimetresinde $\pi^0/\gamma$ Ayırt Edilmesi

Güral Aydın<sup>1\*</sup>, Hasan Sarıgül<sup>2</sup>

<sup>1\*</sup> Hatay Mustafa Kemal Üniversitesi, Fen Edebiyat Fakültesi, Fizik Bölümü, 31034, Hatay, Türkiye, (ORCID: 0000-0002-4996-1174), gaydin@mku.edu.tr

<sup>2</sup> Hatay Mustafa Kemal Üniversitesi, Fen Edebiyat Fakültesi, Fizik Bölümü, 31034, Hatay, Türkiye, (ORCID: :0000-0002-0200-3657), mkuhasansarigul@gmail.com

(International Conference on Design, Research and Development (RDCONF) 2021 – 15-18 December 2021)

(DOI: 10.31590/ejosat.1041107)

**ATIF/REFERENCE:** Aydın, G. & Sarıgül, H. (2021). Derin Öğrenme Yapıları ile Elektromanyetik Örneklem Kalorimetresinde  $\pi^0/\gamma$  Ayırt Edilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (32), 1175-1180.

## Öz

Bu çalışmada, bir elektromanyetik örneklem kalorimetresinde nötr pion ve tek fotonun ayırt edilmesinde derin öğrenme yapay sinir ağlarının kullanılmasının ne kadar etkili olabileceği araştırılmıştır. Örneklem kalorimetresi  $9 \times 9$  matris dizini şeklinde Geant4 benzetim programı ile oluşturulmuştur. Nötr pion ve tek fotonun farklı enerjilerde kalorimetrede oluşturduğu duş görüntüleri kullanarak parçacıkların tanımlanması gerçekleştirilmiştir. İlk olarak, görüntü parametreleri kullanılarak duş görüntülerindeki farklılıklar gözlemlenmiştir. Daha sonra, derin öğrenme yapıları içerisinde duş görüntülerinin oluşturduğu topolojiler giriş parametreleri olarak kullanılarak parçacıkların ayırt edilmesine çalışılmıştır. Makine öğrenmesi ile birlikte belirtilen benzetim koşullarında oldukça yüksek seviyede sinyal verimliliği ve arkaplan reddi değerlerine ulaşılabilceği görülmüştür.

**Anahtar Kelimeler:** Yapay Sinir Ağları, Elektromanyetik Kalorimetresi, Foton Etkileşmesi, Parçacık Tanımlanması.

## Separation of $\pi^0/\gamma$ in an Electromagnetic Sampling Calorimeter with Deep Learning Structures

### Abstract

In this study, it was investigated how effective the use of deep learning artificial neural networks can be in distinguishing neutral pion and single photon in an electromagnetic sampling calorimeter. The sampling calorimeter was constructed in the form of a  $9 \times 9$  matrix array with the Geant4 simulation program. Identification of the particles was carried out by using the shower images created by the neutral pion and a single photon at different energies in the calorimeter. First, differences in shower images were observed using image parameters. Then, the topologies created by the shower images were used as input parameters in deep learning structures to distinguish the particles. It has been observed that very high signal efficiency and background rejection values can be achieved under the specified simulation conditions with machine learning.

**Keywords:** Artificial Neural Network, Electromagnetic Calorimeter, Photon Interaction, Particle Identification.

\* Sorumlu Yazar: [gaydin@mku.edu.tr](mailto:gaydin@mku.edu.tr)

## 1. Giriş

Parçacık bir kalorimetreye isabet ettiğinde çarptığı kulenin yanı sıra komşu kulelerde de enerji biriktirir. Parçacığın vuruş konumu kütle çekim merkezi metodu ile bulunabilir. Bu metoda göre parçacığın çarpması ile enerji biriktirilen kulelerin konumlarının ağırlıklı ortalaması alınarak vuruş konumu hesaplanabilir. Burada her bir kuleye verilecek olan ağırlık ilgili kulede biriken enerji olacaktır. Bu metot ile parçacığın hangi kuleye çarptığının yanı sıra kule içinde hangi konumda etki noktası oluşturduğunun bilgisi de elde edilebilir. Bu metot Denklem 1 ile verildiği gibi formül halinde gösterilebilir.

$$y_{hesap} = \frac{\sum y_i \times E_i}{\sum E_i} \quad z_{hesap} = \frac{\sum z_i \times E_i}{\sum E_i} \quad (1)$$


Burada  $y_i$  ve  $z_i$ ,  $i$ .inci kulenin merkezinin sırasıyla  $y$  ve  $z$  koordinatlarını göstermektedir.  $E_i$  ise  $i$ .inci kulede biriktirilen enerjidir. Bu formüllere göre ışın boylamasına  $x$  –  $ekseni$  doğrultusunda gönderilmiştir.

Yüksek enerjili parçacıklarının konumu bu metot ile hesaplandığında gerçek vuruş noktasının hesaplanan noktaya göre dağılımının doğrusallıktan saparak S-şeklini aldığı görülmektedir (Roy vd., 2017; Aydın vd., 2020). Bu durumun çeşitli sebepleri şöyle sıralanabilir. Kulenin merkezine yakın yerlere ait vuruşlar için ölçülen konum değeri ile gerçek konum değeri hemen hemen eşittir. Bunun sebebi, enerjinin büyük bir kısmının merkez kulede depolanmasıdır. Merkezden uzaklaştıkça, ölçülen konum değerleri gerçek konum değerlerinden daha küçük olur. Bunun sebebi, çarpma konumları merkezden uzaklaştıkça enerjinin vuruş kulesinin dışındaki kulelere eksponansiyel bir dağılım halinde birikmesidir. Bu durumda doğrusal ağırlıklar vuruş kulesine olması gerektiğinden daha fazla ağırlık verir ve konum değeri doğru hesaplanmış olmaz. Kulenin uç noktalarında, enerji komşu kulelerde hemen hemen eşit olarak dağılır ve bu durumda komşu kulelere eşit ağırlıklar verilmiş olur. Böylelikle konum değeri sınırda doğru ölçülmüş olur. Bu sorunun üstesinden gelmek için uygulanabilecek metotlardan biri kulelere verilen ağırlıkların enerji dağılımına uygun hale getirilmesidir. Bu metotlardan biri kulelere logaritmik ağırlık verilmesidir. Bu yol ile konum çözünürlüğü önemli ölçüde artırılabilir. Diğer bir metot ise doğrusal ağırlıklar ile elde edilen konum değerlerinin gerçek konum değerlerine olan bağıllığını formalizme etmek ve bunu kullanarak ölçülen konum değerini gerçek konum değerine formül yardımıyla yaklaştırmaktır. Bu yol ile de sadece doğrusal ağırlık verilerek elde edilen konum çözünürlüğü önemli ölçüde iyileştirilmiş olur. Bu yol ile elde edilen iyileştirmenin logaritmik ağırlık yolu ile elde edilen iyileştirmeye oranla daha fazla olduğu söylenebilir (Roy vd., 2017; Aydın vd., 2020).

Elektromanyetik kalorimetrelerde konum çözünürlüğü nötr pion parçacıklarını ve fotonları ayırt etmede önemlidir. Son durum fotonların yüklü leptonlardan yayılan radyasyonlar mı yoksa nötr pionların bozunumu sonucu ortaya çıkan fotonlar mı olduğunu tespit etmek için iyi bir konum çözünürlüğüne ihtiyaç vardır. Nötr pionların bozunması ile oluşan fotonlar arasındaki açı ile kalorimetrenin geometrik yapısı arasındaki uyumluluk son durum fotonların kaynağını belirlemede ayrıca önemlidir. Eğer foton bozunum sonucu ortaya çıkmamış ise kalorimetrede tek etki noktası meydana getirecektir ve enerji önemli oranda etki

noktasına yakın kulede depolanacaktır. Bozunum sonrası iki foton ortaya çıkacağından ve bu iki foton iki etki noktası oluşturacağından enerjinin farklı kulelerde paylaşılması önemli oranda artacaktır.

Görelilik olarak düşük enerjilerde, bozunum sonucu ortaya çıkan fotonların oluşturacağı yanal düş görüntüsü tek fotonun oluşturacağı görüntüye göre daha geniş olacaktır. Dolayısıyla, düş görüntülerini karşılaştırarak nötr pion ve tek fotonu ayırt etmek mümkün olabilmektedir. Bu amaçla farklı görüntü parametreleri kullanılabilir. Bu parametreleri oluşturmada temel ilke ilk olarak enerjinin en büyük oranda depolandığı kuleyi tespit etmek ve bu kulenin etrafında yer alan dizin şeklinde kule matrisinde depolanan toplam enerjiyi belirlemektir. En çok enerji depolanan kulenin enerjisinin bu kule etrafında yer alan kule dizininde depolanan toplam enerjiye oranı düş görüntüsünü ortaya çıkarmada kullanılacak bir parametredir. Merkez kule etrafında oluşturulacak kule dizini  $3 \times 3$  boyutlarında seçilerek görüntü parametreleri  $S1/S9$  elde edilebilir. Bu parametrelerle oluşturulacak düş görüntüsü bozunum sonucu ortaya çıkan fotonlar ve tek foton için önemli farklılıklar gösterecektir. Görelilik olarak yüksek enerjilerde bozunum sonucu ortaya çıkan fotonlar arasındaki açı daha küçük olacağından düş görüntüleri çok ayırt edici olmayacaktır (Roy vd., 2016). Bu sorunun üstesinden gelebilmek için düş görüntülerindeki farklı topolojileri esas alarak ışın parçacıklarını ayırt etme işlemi gerçekleştirilebilir. Tek fotonun oluşturacağı görüntüde düş homojen olarak dağılacak olmasına rağmen bozunum sonucu ortaya çıkacak fotonların oluşturacağı görüntüde düş daha eliptik bir görüntüye sahip olacağı söylenebilir. Bu bozunum sonucu ortaya çıkan fotonların iki farklı etki noktası oluşturacağından dolayıdır.  $\pi^0$  bozunumuna ait topoloji Şekil 1’de gösterilmiştir.




Şekil 1:  $\pi^0$  bozunumuna ait topoloji için bir örnek.

Bu çalışmanın amacı, ilk olarak görüntü parametreleri ile düş görüntüleri oluşturmak ve bu sayede parçacıkları ayırt etmede ne kadar etkili olabileceğini görmektir. İkinci aşamada amaç yapay sinir ağlarını (YSA) ve parçacıkların oluşturacağı görüntülerdeki farklı topolojileri kullanarak parçacıkların ayırt edilmesini sağlamaktır. Derin öğrenme yapay sinir ağları hakkında ayrıntılı bilgi bu makalede Materyal ve Metot bölümü içerisinde açıklanmaktadır. 3. Bölümde Sonuçlar ve Tartışma yer alacaktır. Sonuç ise 4. Bölümde verilecektir.

## 2. Materyal ve Metot

Bu çalışmada kullanılan elektromanyetik örnekleme kalorimetresinin aktif malzemesi olarak  $PbWO_4$  inorganik sentilasyon malzemesi seçilmiştir.  $PbWO_4$  yüksek yoğunluklu ( $\rho = 8.28 \text{ g/cm}^3$ ) ve hızlı bozunma sabitine (80% oranında 25 ns) sahip bir sentilasyon malzemesidir (Diemoz vd., 2007). Bu

sintilatörün yüksek yoğunluğu ve küçük Moilere yarıçapı kompakt kalorimetrelerin kurulmasına olanak sağlamaktadır. Soğurucu madde olarak ise 20 mm kalınlığında demir kullanılmıştır. Sintilasyon malzemesinin kalınlığı ise 5 mm'dir. Kalorimetre Geant4 benzetim programı (Agostinelli vd., 2003; Allison vd., 2006; Allison vd., 2016) ile oluşturulmuştur. Kalorimetre  $9 \times 9$  matris dizini şeklinde 12 mm x 12 mm yanal alana sahip soğurucu ve sintilasyon malzemesinin sıralı bir şekilde yerleştirildiği kulelerden meydana gelmiştir. Her bir kule 20 katmana sahiptir. Gama ışınları üç farklı enerjide (50, 80 ve 140 GeV) kalorimetrenin merkez kulesine düzgün dağıtılarak gönderilmiştir ( $-10 \text{ mm} < Z < +10 \text{ mm}$ ). Nötr pionun kalorimetreden 2.5 m uzaklıkta iki gamaya bozunduğu varsayılmıştır. Her bir kulede depolanan enerji her bir etkileşme adımıyla sintilatörlerde ortaya çıkan enerji toplanarak elde edilmiştir. Her bir olay için ilk olarak en çok enerji depolanan kule belirlenmiş ve bu kulenin etrafındaki  $3 \times 3$  dizin şeklindeki kulelerde depolanan toplam enerji belirlenmiştir.  $3 \times 3$  dizin halinde kule diyagramı Şekil 2'de gösterilmiştir. Bu sayede S1/S9 görüntü parametreleri hesaplanarak duş görüntüleri oluşturulmuştur. Her bir olayın sonunda  $3 \times 3$  dizini içerisinde yer alan her bir kulede depolan enerji daha sonra derin öğrenme yapay sinir ağlarında kullanılmak üzere kaydedilmiştir.



Şekil 2:  $3 \times 3$  dizin şeklinde kuleler açık gri ile en çok enerji depolanan kule ise koyu gri renkte gösterilmiştir.

Çalışmanın 2. Aşamasında YSA kullanılarak parçacık ayırt edilmesi sağlanmıştır. Nötr pion ve tek fotonun oluşturacağı duş görüntülerine ait farklı topolojilerin YSA ile parçacık tanımlanmasında ne kadar kullanışlı olduğu ilgi çekicidir. Bu analizde YSA içerisinde giriş parametreleri olarak  $9 \times 9$  kule dizininde en çok enerji depolanan merkez kule etrafında yer alan  $3 \times 3$  dizin şeklindeki kule matrisinde yer alan her bir kulede depolanan enerji kullanılmıştır. Böylelikle, her bir olay için YSA 9 giriş etiketine sahiptir.

YSA ile yapılan analizde bir derin öğrenme arayüzü olan ve Python ile yazılan Keras (Keras, 2021) kullanılmıştır. Keras, bir açık-kaynak makine öğrenme platformu olan Tensorflow (Tensorflow, 2021) üzerinden çalışmaktadır. Tensorflow yüksek döngü hızına sahip ve derin öğrenmede gerekli yapıtaşlarına sahiptir. Keras, model ve katmanlara dayalı bir yapıya sahiptir. Keras içerisinde tanımlanabilen ardışık (sequential) modeli katmanların doğrusal olarak dizilmesini sağlayan bir modeldir. Bu modelde her bir katman bir giriş ve bir de çıkış içeren bir yapıya sahiptir. Böyle bir modelde, giriş etiketlerini içeren bir giriş katmanı, saklı katmanlar ve çıkış katmanı tanımlanabilmektedir.

Keras, farklı aktivasyon seçenekleri sunmaktadır. Bunlardan bazıları şöyledir: relu, sigmoid, softmax, softplus, softsign, tanh, selu, elu ve exponential fonksiyonlar. YSA için ilk önceleri ve uzun bir zaman varsayılan aktivasyon fonksiyonu olarak sigmoid e-ISSN: 2148-2683

ve tanh fonksiyonları kullanılmıştır. Modern derin öğrenme yapay sinir ağlarında ise reLU fonksiyonu kullanılmaya başlanmıştır. Bu çalışmada relu (rectified linear unit) doğrusal aktivasyon fonksiyonu saklı katmanlar için kullanılmıştır. Bu fonksiyon sıfırdan küçük değerler için 0 değerlerini vermekte öte yandan sıfırdan büyük değerler için doğrusal yanıt vermektedir. Fonksiyon Denklem 2 ile gösterilmektedir.

$$g(z) = \max(0, z) \quad (2)$$

Bu fonksiyonun exponansiyel fonksiyonlara göre bir üstünlüğü daha az hesap zamanı gerektirmesidir. Diğer bir üstünlüğü ise doğrusal olmayan fonksiyonların sebep olduğu gradyan kaybolma etkisini ortadan kaldırmasıdır (Glorot vd., 2011).

YSA içinde çıkış katmanı için aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır. Bu fonksiyon Denklem 3 ile gösterilmektedir.

$$\text{sigmoid}(x) = 1/(1 + \exp(-x)) \quad (3)$$

Fonksiyon özellikle -5'ten küçük sayılar için 0'a yakın sonuçlar vermekte ve büyük sayılar için ise (5'ten büyük) 1' yakın değerler vermektedir. Fonksiyonun sonucu daima 0 ile 1 arasında değerler taşımaktadır. Çıkış katmanı 1 nörona sahip olarak tanımlanmış ve beklenen değerler 0 veya 1 olarak belirtilmiştir. Dolayısıyla iki çıkış sınıfına uygun olarak tahminler elde edilmiştir. Bu sınıflardan biri tek fotonu yani sinyali diğeri ise nötr pionu yani arkaplanı temsil etmektedir. Her bir test aşamasında her bir sınıfın olasılığı 0 ile 1 arasında elde edilmiştir. Program sonucunda elde edilen tahmini değerler 0,5'den büyük ise sinyal olarak aksi durumda arkaplan olarak kabul edilmiştir.


YSA en iyileme algoritması olarak geniş verilerde etkili olan stokastik gradyan azalan metodunu kullanan ADAM (Adaptive Moment Estimation) algoritması kullanılmıştır (Kingma ve Ba, 2017). SDG metodunun derin öğrenme uygulamalarında başarılı sonuçlar verdiği gösterilmiştir (Hinton ve Salakhutdinov, 2006; Hinton vd., 2012; Deng vd., 2013; Graves vd., 2013; Krizhevsky vd., 2017). Diğer taraftan, olasılık kayıplarını belirlemek üzere gerçek sonuçlar ve tahmin edilen sonuçlar arasında crossentropy metriğini içeren binarycrossentropy sınıfı kullanılmıştır. Programda, giriş parametre seti eğitim sürecinde 0 ile 1 arasında değerler almak üzere ölçeklendirilmiştir. Bu amaç için "MinMaxScaler" metodu kullanılmıştır. Bu metot, Denklem 4 ile verildiği gibi formülize edilir.

$$X_{\text{norm}} = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (4)$$


Burada  $\min(X)$  ve  $\max(X)$ , veri setinde yer alan sırasıyla en küçük ve en büyük değerdir.

### 3. Araştırma Sonuçları ve Tartışma


Nötr pion ve tek fotona ait duş görüntüleri 50, 80, 140 ve 180 GeV ışın enerjileri için Şekil 3, 4, 5 ve 6 ile gösterilmiştir. Şekillerden görüldüğü üzere 50 ve 80 GeV ışın enerjilerinde duş görüntülerine bakıldığında duş parametrelerinin belli derecede parçacıkları ayırt etme duyarlılığında olduğu söylenebilir. 80 GeV 'in üzerinde ışın enerjisinde bu duyarlılığın kaybolduğu da açıkça görülmektedir.




Şekil 3: 50 GeV ışın enerjisinde görüntü parametrelerine bağlı olarak sinyal ve arkaplan dağılımları.



Şekil 6: 180 GeV ışın enerjisinde görüntü parametrelerine bağlı olarak sinyal ve arkaplan dağılımları.



Şekil 4: 80 GeV ışın enerjisinde görüntü parametrelerine bağlı olarak sinyal ve arkaplan dağılımları.



Şekil 5: 140 GeV ışın enerjisinde görüntü parametrelerine bağlı olarak sinyal ve arkaplan dağılımları.

Her bir enerji değerinde sinyal verimliliğine bağlı olarak arkaplan ret oranları çıkarılmıştır ve Tablo 1'de gösterilmiştir. Tablodan görüldüğü üzere ışın enerjisi ile birlikte arkaplan reddi oldukça düşmektedir.

Tablo 1: Farklı ışın enerjileri için sinyal verimliliğine bağlı olarak arkaplan ret yüzdelik değerleri. Sonuçlar görüntü parametreleri kullanılarak elde edilmiştir.

| Işın Enerjisi (GeV) | Arkaplan reddi %                  |                                   |                                   |
|---------------------|-----------------------------------|-----------------------------------|-----------------------------------|
|                     | $\epsilon_{\text{sinyal}} = 50\%$ | $\epsilon_{\text{sinyal}} = 80\%$ | $\epsilon_{\text{sinyal}} = 90\%$ |
| 50                  | 100                               | 100                               | 100                               |
| 80                  | 100                               | 83.2                              | 71.5                              |
| 140                 | 80.2                              | 44.9                              | 36.5                              |
| 180                 | 68.4                              | 36.6                              | 28.9                              |

Bir sonraki aşamada YSA kullanılarak sinyal ve arkaplan ayırt edilmeye çalışılmıştır. Bu aşamada,  $3 \times 3$  matris formunda kulelerden elde edilen enerji değerleri YSA'nda giriş parametreleri olarak kullanılmıştır. Tek bir dosya her iki sınıftan parametreleri içerecek şekilde oluşturulmuştur. Her bir sınıf için etiket değerleri 0 ve 1 olarak tanımlanmıştır. Eğitim sürecinde veri setinin %30'u doğrulama için ayrılmıştır. Tahmin etme sürecinde her bir sınıf için her test aşamasında olasılık değerleri elde edilmiştir. Eğitim ve tahmin etme süreçleri her bir ışın enerjisi için ayrı ayrı olarak gerçekleştirilmiştir. Tablo 2'de verildiği gibi 9 farklı model ile bu süreçler gerçekleştirilmiştir.

Tablo 2: Sinyal ayırt etmede kullanılan makine öğrenmesine ait farklı yapılar.

| Model no | # katman sayısı | # her bir katmandaki nöron sayısı |
|----------|-----------------|-----------------------------------|
| #1       | 1               | 30                                |
| #2       | 1               | 60                                |
| #3       | 1               | 120                               |
| #4       | 1               | 180                               |
| #5       | 2               | 30                                |
| #6       | 2               | 60                                |
| #7       | 2               | 120                               |
| #8       | 2               | 180                               |
| #9       | 3               | 30                                |
| #10      | 3               | 60                                |
| #11      | 3               | 120                               |
| #12      | 3               | 180                               |

Her bir model farklı enerjiler için test edilmiştir. 180 GeV ışın enerjisi hariç modellere göre sonuçların çok büyük farklılıklar göstermediği görülmüştür. Ancak, 180 GeV ışın enerjisinde katman sayısı 1'den fazla olduğunda arkaplan reddinin önemli ölçüde azaldığı belirlenmiştir. Tablo 3'te katman ve nöron sayıları ile birlikte minimum ve maksimum verimlilik değerleri verilmektedir.

Tablo 3: Farklı ışın enerjileri için YSA ile elde edilen minimum ve maksimum verimlilik değerleri. Burada, örnek olarak (K2N120), katman sayısının 2 ve nöron sayısının 120 olduğunu belirtmektedir.

| Işın Enerjisi (GeV) | $\epsilon_{\text{sinyal}}(\%)$ |               |
|---------------------|--------------------------------|---------------|
|                     | Minimum                        | Maksimum      |
| 80                  | 98.7(K2N12)                    | 99.4 (K2N60)  |
| 140                 | 94.4(K1N18)                    | 98.1 (K3N30)  |
| 180                 | 81.4 (K2N30)                   | 98.4 (K3N120) |
|                     | Arkaplan reddi %               |               |
|                     | Minimum                        | Maksimum      |
| 80                  | 96.5(K3N12)                    | 99.6 (K1N180) |
| 140                 | 88.3(K3N12)                    | 94.1 (K2N30)  |
| 180                 | 57.7(K3N12)                    | 96.9 (K1N30)  |

Buna göre bütün ışın enerji değerleri birlikte ele alındığında en iyi modelin belirlenmesine çalışılmıştır. Elde edilen sonuçlara göre sinyal verimliliği ve arkaplan reddi birlikte değerlendirildiğinde 1 katmanlı 120 nöronlu yapının en iyi sonuçları verdiği görülmüştür. Bu parametreler ile birlikte en iyi sonuçlara yol açan diğer parametreler Tablo 4'te gösterilmiştir. Ayrıca şunu da belirtmek gerekir ki 180 GeV ışın enerjisi hariç

sınıflandırma çıkışı olarak elde edilen olasılık değeri 0,5'den büyükse sinyal aksi durumda arkaplan kabul edilerek yapılmıştır. 180 GeV ışın enerjisinde ise bunun çok iyi sonuçlar vermediği ancak olasılık değeri 1'e eşit olduğunda sinyal olarak tanımlanmasının oldukça iyi değerler verdiği görülmüştür. Dolayısıyla en yüksek ışın enerjisinde sınıflandırma diğerlerinden farklı olarak olasılık değerinin 1'e eşit olup olmadığına bakılarak yapılmıştır.


Tablo 4: En iyi sonuçları sağlayan makine öğrenmesi parametreleri.

| Parametre                 | Value |
|---------------------------|-------|
| Katman Sayısı             | 1     |
| Nöron Sayısı              | 120   |
| Öğrenme hızı              | 0.01  |
| Yığın boyutu (batch size) | 32    |
| #devir (epoch)            | 200   |

Model #3'e göre elde edilen sinyal verimliliği ve arkaplan reddi değerleri Tablo 5 ile verilmiştir. Her iki değerinde oldukça iyi olduğu görülmektedir. Dolayısıyla makine öğrenmesinin yukarıda belirtilen koşullarda sinyal arkaplan ayırt edilmesinde kullanılabileceği ve benzer uygulamalarda test edilebileceği sonucu ortaya çıkmaktadır. Epoch sayısına göre 140 GeV ışın enerjisine ait eğitim kaybı ve doğrulama kaybı değerlerinin değişimi Şekil 7 ile gösterilmiştir. Şekilden doğrulama sürecindeki kaybın eğitim sürecindeki kayıp ile önemli oranda uyumlu olduğu gözükmemektedir.

Tablo 5: YSA ile ulaşılan sinyal verimliliği ve arkaplan reddi değerleri.

| Işın Enerjisi (GeV) | Sinyal verimliliği ve arkaplan reddi |                    |
|---------------------|--------------------------------------|--------------------|
|                     | $\epsilon_{\text{sinyal}}(\%)$       | Arkaplan reddi (%) |
| 50                  | 90.1                                 | 100                |
| 80                  | 99.2                                 | 99.1               |
| 140                 | 97.6                                 | 92.3               |
| 180                 | 94.3                                 | 92.2               |



Şekil 7: Devir (epoch) sayısına bağlı olarak eğitim ve doğrulama süreçlerindeki kayıp değerleri (loss value). Dağılım 140 GeV ışın enerjisi ve Model 3 için elde edilmiştir.

#### 4. Sonuç

Bu çalışmada derin öğrenme yapay sinir ağı ile bir örneklem kalorimetresinde  $\pi^0/\gamma$  ayrımının ne kadar başarılı olabileceği araştırılmıştır. Örneklem kalorimetresinde tek fotonun ve  $\pi^0$  bozunumu ile ortaya çıkan iki fotonun oluşturduğu düş görüntüleri karşılaştırılmıştır. İlk olarak görüntü parametreleri kullanılarak ulaşılabilir sinyal verimliliği ve arkaplan reddi değerleri belirlenmiştir. Görüntü parametreleri kalorimetrede en çok enerji depolanan kule ve etrafındaki  $3 \times 3$  matris şeklindeki kule dizisinde depolanan toplam enerji kullanılarak elde edilmiştir. Matris dizini şeklindeki kulelerde depolanan enerji değerleri derin öğrenme yapay sinir ağı içerisinde giriş parametreleri olarak kullanılmış ve sinyal-arkaplan sınıflandırılması yapılmıştır. YSA ile başka bir düzeltmeye gerek kalmadan elde edilen verimlilik değerlerinin görüntü parametreleri ile elde edilenlere göre oldukça iyi olduğu tespit edilmiştir. Dolayısıyla, benzer detektör yapılarında YSA'nın test edilmeye değer olduğu sonucu çıkarılmıştır. Görüntü parametreleri kullanıldığında ışın enerjisi ile azalan arkaplan reddinin YSA ile herhangi bir düzeltme olmadan 90%'nin üzerine çıkarılabileceği görülmektedir.

#### Kaynakça

Agostinelli, S., Allison, J., Amako, K., Apostolakis, J., Araujo, H., Arce, P. ... & Zschiesche, D. (2003). Geant4—a simulation toolkit. *Nuclear Instruments and Methods in Physics Research Section A*, 506 (3), 250-303.

Allison J., Amako K., Apostolakis J., Araujo H., Arce P., Asai M. ... & Yoshida, H. (2006). Geant4 developments and applications. *IEEE Transactions on Nuclear Science*, 53 (1), 270-278.

Allison J., Amako K., Apostolakis J., Arce P., Asai M., Aso T. ... & Yoshida, H. (2016). Recent developments in Geant4. *Nuclear Instruments and Methods in Physics Research Section A*, 835, 186-225.

Aydın, G., Sarıgül. M., & Sarıgül. H. (2020). Position resolution study at high energies of a sampling electromagnetic calorimeter whose active material is a scintillator with Peroxide-cured polysiloxane base. *Nuclear Instruments and Methods in Physics Research A*, 955 (Mart), 163341.

Deng, L., Li, J., Huang, J.T., Yao, K., Yu, D., Seide, F. ... & Acero, A. (2013). Recent advances in deep learning for speech research at Microsoft. *IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP, Vancouver: IEEE*, 13859384.

Diemoz, M. (CMS ECAL İşbirliği Adına). (2007). The electromagnetic calorimeter of the CMS experiment. *Nuclear Instruments and Methods in Physics Research Section A*, 581 (1-2), 380-383.

Glorot, X., Bordes, A., & Bengio, Y. (2011). Deep Sparse Rectifier Neural Networks. *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, PMLR, Fort Lauderdale*, 15, 315-323.

Graves, A., Mohamed, A., & Hinton, G. (2013). Speech recognition with deep recurrent neural networks. *International Conference on Acoustics, Speech and Signal Processing, ICASSP, Vancouver: IEEE*, 6645–6649.

Hinton, G.E., & Salakhutdinov, R.R. (2006). Reducing the dimensionality of data with neural network. *Science*, 313 (5786), 504–507.

Hinton, G., Deng, L., Yu, D., Dahl, G.E., Mohamed, A., Jaitly, N. ... & Kingsbury, B. (2012). Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *Signal Processing Magazine, IEEE*, 29 (6), 82–97.

Keras. (2021). <https://keras.io>. (Erişim 15 Mart 2021).

Kingma, D.P., & Ba, J. (2017). Adam: A Method for Stochastic Optimization. *arXiv:1412.6980v9 [cs.LG]*.

Krizhevsky, A., Sutskever, I., & Hinton, G.E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60 (6), 84-90.

Roy, A., Jain, S., Banerjee, S., Bhattacharya, S., & Majumfer, G. (2016). Simulation of  $\pi^0 - \gamma$  separation study for proposed CMS forward electromagnetic calorimeter, *J. Phys. Conf. Ser.*, 759, 012074.

Roy, A., Jain, S., Banerjee, S., Bhattacharya, S., & Majumfer, G. (2017). Simulation study of energy resolution, position resolution and  $\pi^0$ - $\gamma$  separation of a sampling electromagnetic calorimeter at high energies. *Journal of Instrumentation*, 12, P07013.

Tensorflow. (2021). <https://www.tensorflow.org>. (Erişim 15 Mart 2021).