



## Erken Evre Cilt Kanseri Tespiti için İğnecikli Sinir Ağları (SNN) Kullanımı: HAM10000 Veri Kümesi Üzerinde Delta Modülasyon Tabanlı Yaklaşım

Araştırma Makalesi  
10.65520/erciyesfen.1826362

### Künye:

Sayı: 42(1)  
Yıl: 2026  
Sayfa: 59-78

Aslıhan Sönmez<sup>a</sup>  
Volkan Ates<sup>b</sup>

<sup>a</sup> Yük. Lis. Öğr., Tarsus Üniversitesi,  
220928006@tarsus.edu.tr  
<sup>b</sup> Dr. Öğr. Üyesi, Tarsus Üniversitesi,  
volkanfire@hotmail.com

\* Sorumlu Yazar

Geliş Tarihi: 19.11.2025  
Kabul Tarihi: 02.01.2026

### Atıf:

Aslıhan Sönmez, Volkan Ates, (2026).  
Erken Evre Cilt Kanseri Tespiti için  
İğnecikli Sinir Ağları (SNN) Kullanımı:  
HAM10000 Veri Kümesi Üzerinde  
Delta Modülasyon Tabanlı Yaklaşım.  
*Erciyes University Journal of Institute  
Of Science and Technology*, 42(1), 59-  
78.  
<https://doi.org/10.65520/erciyesfen.1826362>

Screened by  
 iThenticate®  
for Authors & Researchers



Except where otherwise noted, content  
in this article is licensed under a  
Creative Commons 4.0 International  
license. Icons by Font Awesome.

### Öz

Deri kanseri, yüksek morbidite oranlarına sahip ve erken teşhisin hayati önem taşıdığı, ancak lezyonlar arası görsel benzerlikler nedeniyle tanısı zor bir hastalıktır. Bu çalışma, geleneksel yapay sinir ağlarının yüksek enerji tüketimine bir alternatif olarak, biyolojik esinli İğnecikli Sinir Ağları (SNN) mimarisini kullanarak cilt lezyonlarının sınıflandırılmasını amaçlamaktadır. HAM10000 veri seti üzerinde eğitilen model, sürekli görüntü verilerini zaman tabanlı iğnecik dizilerine dönüştürmek için enerji verimli bir delta modülasyonu (DM) kodlama tekniği kullanmıştır. Test sonuçları, modelin özellikle Melanom (MEL) ve Bazal Hücreli Karsinom (BCC) ayırımında yüksek başarı sergilediğini göstermiştir.

**Anahtar kelimeler:** İğnecikli sinir ağı, delta modülasyon, HAM10000, deri lezyonu, zaman tabanlı kodlama, sınıflandırma



## Early-Stage Skin Cancer Detection Using Spiking Neural Networks: A Delta Modulation-Based Approach on the HAM10000 Dataset

### Abstract

Skin cancer is a disease with high morbidity rates where early diagnosis is vital, yet diagnosis is challenging due to visual similarities between lesions. This study proposes a biologically inspired Spiking Neural Network (SNN) architecture for skin lesion classification as an alternative to the high energy consumption of traditional neural networks. The model was trained on the HAM10000 dataset and used delta modulation encoding to convert images into spike trains. Results show strong performance especially in distinguishing Melanoma (MEL) from Basal Cell Carcinoma (BCC).

**Keywords:** Spiking neural network, delta modulation, HAM10000, skin lesion, time-based encoding, classification.



### 1. Giriş

Deri kanseri, dünyada en yaygın ve potansiyel olarak ölüme yol açan kanser türlerinden biridir [1] Erken ve doğru tanı, etkili tedavi için kritik önem taşısa da, çeşitli lezyon türlerinin görsel benzerliği nedeniyle tanı koymak zordur [2]. Geleneksel derin öğrenme modelleri, bu sorunu çözmede etkili olsa da, biyolojik sistemlerin doğal işleyişini yansıtmaz. Spiking Neural Network (SNN) modelleri, biyolojik sinir sistemlerinden esinlenerek zaman tabanlı bilgi işleme sunar [3, 4]. Bu çalışma, delta modülasyon

tabanlı iğnecik kodlama kullanan bir SNN mimarisi ile cilt lezyonlarının sınıflandırılmasını hedeflemektedir.

Deri lezyonlarının sınıflandırılması, cilt kanserinin erken teşhisinde hayati bir rol oynamaktadır. Cilt kanseri, dünya genelinde en yaygın kanser türlerinden biri olup, özellikle malign melanom gibi agresif türlerin erken evrede tespit edilmesi, hastaların yaşam süresini ve tedavi başarısını doğrudan etkilemektedir. İlk dönem çalışmalarda, kenar tespiti, renk uzayı dönüşümleri, segmentasyon ve istatistiksel öznitelik çıkarımı gibi klasik görüntü işleme teknikleri kullanılmıştır. Bu tekniklerle elde edilen öznitelikler genellikle Support Vector Machines (SVM), Random Forest (RF) veya K-En Yakın Komşu (K-NN) gibi sınıflandırıcılarla değerlendirilmiştir [5]. Zhang ve ark. cilt lezyonlarını sınıflandırmak için renk histogramları ve sınır bilgileri gibi el ile çıkarılmış öznitelikleri kullanmış, ardından SVM ile sınıflandırma gerçekleştirmiştir. Bu yöntemler özellikle düşük veri gereksinimi açısından avantajlı olsa da, genellikle yüksek doğruluk sağlamada yetersiz kalmıştır [6].

Farklı deri lezyonu türleri arasında görsel benzerliklerin bulunması, sınıflar arasında dengesizliklerin olması ve özellikle düşük çözünürlüklü ya da artefakt içeren görüntülerin varlığı gibi faktörler, tanı süreçlerini oldukça karmaşık hale getirmektedir. Bu durum, klasik klinik yöntemlerle tanının doğruluğunu olumsuz etkileyebilmektedir. Bu zorlukların üstesinden gelmek amacıyla araştırmacılar, son yıllarda bilgisayarlı görü, makine öğrenmesi ve derin öğrenme gibi ileri teknolojilere yönelmişlerdir. Özellikle konvolüsyonel sinir ağları (CNN), cilt lezyonlarının sınıflandırılmasında yaygın olarak kullanılan modellerden biri haline gelmiştir. Derin öğrenme, özellikle CNN sayesinde tıbbi görüntü sınıflandırmasında devrim yaşanmıştır. CNN modelleri, manuel öznitelik mühendisliğine ihtiyaç duymadan, görüntülerden doğrudan yüksek düzeyde temsil öğrenebilme yeteneğine sahiptir. Literatürde CNN kullanılarak deri lezyon sınıflandırma işlemi gerçekleştiren birçok çalışma bulunmaktadır. Codella ve ark. [7] paketleme (ensembling) stratejileriyle çeşitli CNN mimarilerini birleştirerek cilt lezyonu sınıflandırmasında önemli başarılar elde etmiştir. Bu yaklaşım, farklı modellerinin güçlü yönlerini bir araya getirerek sınıflandırma performansını artırmaktadır. Tschandl ve ark. [8], klinik ve dermoskopik görüntüleri birlikte kullanarak çok modaliteli veri ile eğitim gerçekleştirmiş ve doğruluk oranlarını anlamlı şekilde yükseltmiştir. Bu çalışmada, CNN modellerinin klinik karar destek sistemlerine entegrasyonu tartışılmıştır. Thwin ve Par tarafından geliştirilen bu çalışmada, VGG16, Inception-V3 ve ResNet-50 modellerinin birleşimiyle bir cilt lezyon sınıflandırma sistemi önerilmiştir. ISIC 2018 ve HAM10000 veri setlerinde yapılan değerlendirmelerde, oversampling ile dengelenmiş verilerde %96-97 gibi yüksek doğruluklar elde edilerek, önerilen yöntem tekil modellere kıyasla daha başarılı sonuçlar göstermiştir [9]. Nguyen ve ark., HAM10000 veri seti üzerinde cilt lezyonu sınıflandırması için Soft-Attention ile desteklenmiş derin öğrenme modelleri (DenseNet, InceptionNet, ResNet vb.) kullanmıştır. Çalışmada veri dengesizliğini dikkate alan yeni bir loss fonksiyonu önerilmiş ve yaş ile cinsiyet bilgileri de modele dahil edilmiştir. En yüksek başarı, InceptionResNetV2 + Soft-Attention kombinasyonunda %90 doğruluk ile elde edilirken, MobileNetV3Large modeli 30 kat daha hızlı çalışarak %86 doğruluk sağlamıştır [10]. Dosovitskiy ve ark. tarafından önerilen ViT mimarisi, cilt lezyonlarının bağlamsal analizinde CNN'den daha üstün sonuçlar verebilmiştir. Bu model, dikkat mekanizması sayesinde lezyon içi ve çevresel bilgiyi daha iyi yakalayarak sınıflandırma başarısını artırmıştır [11].

Esteva ve ark. çalışmalarında, 129,450 dermatolojik görüntü üzerinde eğitilmiş bir Inception-v3 modeli kullanılarak cilt kanseri teşhisi gerçekleştirilmiş, modelin dermatologlarla kıyaslanabilir düzeyde doğruluk sağladığı gösterilmiştir. Bu çalışma, CNN modellerinin tıbbi görüntü analizinde ulaştığı yüksek başarıyı ortaya koymuştur [12]. Han ve ark. çok sınıflı cilt lezyonu sınıflandırması için CNN tabanlı bir model geliştirmiş ve HAM10000 veri seti kullanarak eğitmiştir. Model, mobil uygulamalarla entegre edilerek klinik ortamlarda kullanılabilirliği araştırılmıştır. Yazarlar, modelin özellikle melanom gibi ölümcül lezyonları yüksek doğrulukla sınıflandırabildiğini belirtmişlerdir [13]. Liu ve ark. ResNet50 mimarisi kullanarak HAM10000 veri seti üzerinde eğitim gerçekleştirmiş, veri artırma (data augmentation), transfer öğrenme (transfer learning) ve sınıf dengesizliğini gidermeye yönelik yöntemler kullanarak doğruluk oranını artırmıştır. Çalışmada, sınıflar arası dengesizliklerin özellikle az görülen lezyon türlerinde sınıflandırma performansını etkilediği ifade edilmiştir [4].

Erdem ve Aydın, HAM10000 veri setinden 10.000 görüntü kullanarak yedi farklı cilt lezyonunun sınıflandırılması amacıyla VGG16, VGG19, Xception (fine-tuning) ve hibrit (VGG16+VGG19) derin öğrenme modellerini uygulamıştır. Deneysel sonuçlar, Xception modelinin %88,92 doğruluk oranı ile en yüksek performansı sağladığını, önerilen hibrit modelin ise %83,43 doğruluk ile literatürdeki birçok çalışmaya kıyasla başarılı sonuçlar verdiğini ortaya koymuştur [14].

Serte ve Demirel, HAM10000 veri setini kullanarak CNN tabanlı derin özellik vektörleri oluşturmuş ve bu vektörleri destek vektör makineleri (SVM) gibi klasik makine öğrenmesi yöntemleriyle sınıflandırmıştır. Bu melez yaklaşım, bazı CNN modellerine kıyasla daha az parametreyle benzer doğruluk oranlarına ulaşmıştır [15]. Karar Ali ve ark. HAM10000 veri seti üzerinde EfficientNet B0-B7 modellerini transfer öğrenme ve ince ayar yöntemleriyle eğiterek çok sınıflı deri kanseri sınıflandırması gerçekleştirmiştir. Veri ön işleme adımları tüy temizleme, (hair removal) veri artırma ve yeniden boyutlandırmayı içermektedir. En iyi sonuç, EfficientNet B4 modeliyle %87,91 doğruluk ve %87 F1 skoru ile elde edilmiş, orta karmaşıklıkta modellerin daha dengeli performans gösterdiği tespit edilmiştir [16]. Nils Gessert ve arkadaşları, ISIC 2018 cilt lezyon tanıma yarışması için 10.000 görüntüden oluşan veri setinde, Densenet, SENet ve ResNeXt modellerinden oluşan bir CNN ansamblı kullanmıştır. Sınıf dengesizliği için kayıp ağırlıklandırma ve dengeli örnekleme teknikleri uygulanmış, çok sayıda ölçeklenmemiş kırpma görüntüsü değerlendirmeye dahil edilmiştir [17]. Takumi Morita ve Xian-Hua Han, etiketsiz deri lezyon görüntülerinden yararlanmak için negatif örnek kullanmayan kendinden denetimli öğrenme yöntemi geliştirmiştir. Önerilen model, sınırlı sayıda etiketli veri ile yapılan sınıflandırma görevlerinde performansı artırarak, iki benchmark veri setinde tanıma başarısını iyileştirmiştir [18]. Ishak Pacal ve ark. tarafından geliştirilen bu çalışmada, deri kanserinin erken teşhisi için MetaFormer mimarisi temelinde hibrit bir CNN-ViT tabanlı derin öğrenme modeli önerilmiştir. Model, odaklanmış kendine dikkat mekanizmaları sayesinde önemli bölgeleri daha iyi tespit edip gürültüyü azaltarak ISIC 2019 ve HAM10000 veri setlerinde yüksek doğruluk ve F1 skorları elde etmiş, mevcut ileri CNN ve ViT modellerini geride bırakmıştır. Ayrıca, hafif yapısı sayesinde gerçek zamanlı ve mobil uygulamalara uygun olup, klinik kullanıma yönelik pratik bir çözüm sunmaktadır [19].

Bu çalışmanın temel amacı; biyolojik sistemlerden ilham alan SNN mimarisinin, deri lezyonlarının sınıflandırılmasındaki potansiyelini ortaya koymaktır. Delta modülasyon tabanlı iğnecik kodlama yönteminin entegre edildiği bu mimari ile, zaman tabanlı sinyallerin etkin bir şekilde işlenmesi ve sınıflandırma başarımının artırılması hedeflenmektedir. Böylece, sadece sınıflandırma doğruluğu yüksek bir model elde etmekle kalmayıp, aynı zamanda nöromorfik bilgi işlem sistemlerinin sağlık alanındaki uygulanabilirliğine dair somut bulgular sunulması amaçlanmaktadır.

Bu çalışmada, cilt lezyonlarının sınıflandırılması için SNN tabanlı bir yöntem uygulanmıştır. Geleneksel yapay sinir ağlarından farklı olarak, SNN'ler bilgiyi iğnecik tabanlı iletim ile işler ve biyolojik nöron davranışını taklit eder. Girdi görüntüleri, delta modulation yöntemi kullanılarak iğnecik dizilerine dönüştürülmüş, böylece ağ yalnızca önemli değişimleri öğrenerek gereksiz bilgileri ihmal etmiştir. Bu iğnecik tabanlı veriler, evrimsel ve tam bağlantılı katmanlarda Leaky Integrate-and-Fire (LIF) nöronları ile işlenmiş ve son katmanda sınıflandırma gerçekleştirilmiştir. Kullanılan yaklaşım, hem enerji verimliliğini artırmakta hem de biyolojik olarak ilham alınmış bir öğrenme mekanizması sunmakta ve sınıflandırma performansını yüksek tutarken hesaplama maliyetini düşürmektedir. Bu sayede delta modülasyonu ve SNN kombinasyonu, görüntü tabanlı medikal sınıflandırma problemlerinde etkili ve sürdürülebilir bir çözüm sağlamaktadır.

## 2.1. Görüntü Veri seti HAM10000

Bu çalışmada, cilt lezyonlarının sınıflandırılması amacıyla HAM10000 (Human Against Machine with 10000 training images) veri kümesi kullanılmıştır. Bu veri kümesi, Avusturya Graz Üniversitesi Tıp Fakültesi Dermatoloji Departmanı ile Avusturya'nın diğer medikal merkezlerinden elde edilen 10.015 dermatoskopik görüntü içermektedir. Veri seti yedi farklı sınıfa kapsamaktadır: Melanom (mel), Melanom benzeri lezyonlar (akiec), Bazal hücreli karsinom (bcc), Benign pigmentli nevüsler (nv), Seboreik keratoz (bkl), Dermatofibroma (df) ve Vasküler lezyonlar (vasc). Bir lezyonun "tehlike" derecesini değerlendirmek birçok faktöre (erken teşhis, büyüme hızı, yayılma potansiyeli vb.) bağlıdır.

Kesin bir sıralama yapmak yerine, bu sınıfları tıbbi önemlerine ve potansiyel risklerine göre gruplandırmak daha doğru olacaktır:

### 1. Grup: Malign (Kanserli) ve Yüksek Riskli

Bu gruptakiler cilt kanseridir ve en ciddi riskleri taşır.

- i. Melanom (mel): Genellikle en tehlikeli cilt kanseri olarak kabul edilir. Hızla büyüme ve vücudun diğer bölgelerine yayılma (metastaz) potansiyeli yüksektir. Erken teşhisi hayattır.
- ii. Bazal Hücreli Karsinom (bcc): En yaygın cilt kanseri türüdür. Genellikle yavaş büyür ve nadiren metastaz yapar, ancak tedavi edilmezse çevresindeki dokuya zarar verebilir.

### 2. Grup: Pre-Malign (Kanser Öncesi)

Bu lezyonlar henüz kanser değildir ancak zamanla kansere dönüşme riski taşırlar.


- i. Melanom benzeri lezyonlar (akiec - Aktinik Keratoz): Genellikle güneşe maruz kalma sonucu oluşan bu lezyonlar, tedavi edilmezse Skuamöz Hücreli Karsinom'a (farklı bir cilt kanseri türü) dönüşme riski taşır.

### 3. Grup: Benign (İyi Huylu / Zararsız)


Bu gruptaki lezyonlar kanserli değildir ve genellikle sağlık açısından bir tehlike oluşturmazlar.

- i. Benign pigmentli nevüsler (nv): Halk arasında "ben" olarak bilinen normal, iyi huylu pigment birikimleridir.
- ii. Seboreik keratoz (bkl): Yaygın, zararsız, genellikle yaşla birlikte ortaya çıkan siğil benzeri cilt büyümeleridir.
- iii. Dermatofibroma (df): Cilt altında oluşan küçük, sert, iyi huylu nodüllerdir.
- iv. Vasküler lezyonlar (vasc): Kan damarlarından kaynaklanan (örneğin "kiraz anjiyomu" gibi) iyi huylu oluşumlardır.


Özetle, Melanom (mel) en yüksek aciliyeti ve tehlike potansiyelini taşıırken, onu diğer kanser türü olan Bazal Hücreli Karsinom (bcc) ve kanser öncüsü olan Aktinik Keratoz (akiec) takip eder. Diğer dört sınıf (nv, bkl, df, vasc) genellikle iyi huylu olarak kabul edilir. Kullanılan veri setine ait örnek görüntüler Sekil 1'de görülmektedir.




BKL



DF




MEL




VASC



BCC



NV



AKIEC

### Şekil 1. HAM10000 örnek sınıf görselleri

Veri kümesinde yer alan görüntüler, başlangıçta 650×450 piksel çözünürlükte ve RGB (renkli) formatta sunulmuştur. Ancak bu boyutlar, derin öğrenme algoritmalarının eğitim sürecinde hem hesaplama yükünü artırmakta hem de gereksiz ayrıntılar içerebilmektedir. Bu nedenle, modelin daha verimli ve hızlı bir şekilde eğitilmesi amacıyla aşağıdaki ön işleme adımları uygulanmıştır:

- **Boyutlandırma (Resizing):** Tüm görüntüler, modelin giriş katmanına uygun olacak şekilde 128×128 piksel boyutuna yeniden ölçeklendirilmiştir. Bu adım, hem hesaplama maliyetini azaltmakta hem de bellekte daha verimli yer kullanımını mümkün kılmaktadır.

- **Renk Uzayı Dönüşümü (Grayscale):** RGB formatındaki renkli görüntüler, gereksiz renk bilgisinden arındırılarak gri tonlamalı (grayscale) forma dönüştürülmüştür. Bu dönüşüm, özellikle yapısal örüntülerin çıkarımı açısından yeterli bilgi sağladığı için tercih edilmiştir.

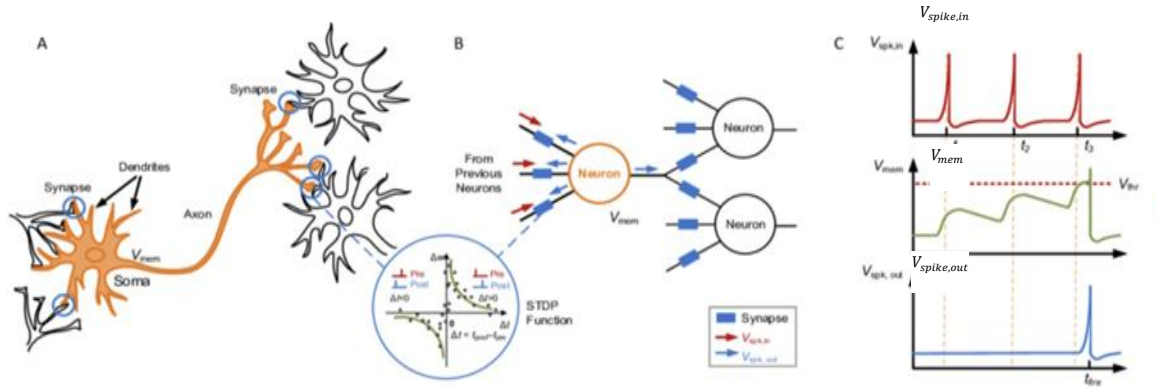
- **Normalizasyon:** Piksel değerleri, min-max normalizasyon yöntemiyle [0, 1] aralığına çekilmiştir. Bu işlem, modelin daha stabil öğrenmesini sağlarken, gradyan iniş algoritmalarının performansını da artırmaktadır. Ayrıca, farklı aydınlatma koşullarına sahip görüntüler arasındaki varyasyonu azaltarak modelin genelleme yeteneğini güçlendirmiştir.

- **Etiket Dengeleme:** Veri kümesinde sınıflar arasında belirgin dengesizlikler bulunmaktadır (örneğin, nv sınıfı çok daha fazla örneğe sahiptir). Bu çalışmada, sınıf dengesizliği ile başa çıkmak için veri artırımı ve sınıf ağırlıklı kayıp fonksiyonu gibi yöntemlerin potansiyel katkısı göz önünde bulundurulmuştur.

Bu çalışmada ele alınan sınıflandırma görevi, tüm sınıfların tek bir modelde değerlendirildiği çok sınıflı bir yaklaşımla sınırlı tutulmamıştır. Buna ek olarak, farklı zorluk seviyelerine göre özel alt sınıf kümeleri (ikili, üçlü ve dördü gruplar) oluşturulmuş ve model bu spesifik senaryolarda da test edilmiştir. Bu çok yönlü metodoloji, modelin hem genel durumlardaki hem de özel senaryolardaki duyarlılığını ölçmeyi ve sınıflar arası ayırım yapma kapasitesini daha derinlemesine analiz etmeyi mümkün kılmıştır.

## 2.2. İğnecikli Sinir Ağı (Spiking Neural Network- SNN)

İğnecikli Sinir Ağı (SNN) modelleri, biyolojik sinir sistemlerinin çalışma prensiplerinden esinlenen ve Maass'ın çalışmasında tanımlandığı üzere üçüncü nesil yapay sinir ağı yapılarıdır [20]. Geleneksel yapay sinir ağlarından farklı olarak, SNN'ler bilgiyi sürekli değerler yerine zaman içinde dağılan ayırık (discrete) iğnecik sinyalleri biçiminde işler. Bu yaklaşım, zamanlama bilgisini doğrudan kullanabilmesi sayesinde SNN'leri özellikle zaman ve enerji verimliliği açısından öne çıkarır. SNN'lerin temelinde yer alan nöron modellerinden biri, Gerstner ve Kistler'in tarafından ayrıntılı olarak açıklanan Leaky Integrate-and-Fire (LIF) modelidir [21]. Bu model, biyolojik nöronların elektriksel davranışlarını matematiksel olarak basitleştirerek ifade eder. Nöron, gelen iğnecikler nedeniyle membran potansiyelinde birikim yapar; potansiyel belirli bir eşik değerine ulaştığında bir iğnecik üretir ve potansiyel sıfırlanır. "Leaky" (sızdıran) özelliği ise membran potansiyelinin zamanla doğal olarak azalmasını, yani bilgilerin belirli bir süre içinde unutulmasını simgeler [22]. Olay tabanlı bilgi işleme (event-driven processing) SNN'lerin en önemli avantajlarından biridir. SNN'ler, yalnızca anlamlı iğnecik sinyalleri ortaya çıktığında işlem yapar ve bu sayede gereksiz hesaplama yapmaktan kaçınır. Bu da onları özellikle düşük güç tüketimi ve gerçek zamanlı uygulamalar için uygun kılar. Örneğin, nöromorfik donanımlar üzerinde SNN modelleri, klasik derin öğrenme modellerine kıyasla çok daha az enerji harcar [23].



**Şekil 2.** SNN ve biyolojik sinir hücresi karşılaştırması. **A.** Tipik bir biyolojik sinir hücresinin basitleştirilmiş diyagramı, **B.** temel bir nöromorfik birim olarak modellenmiş bir iğnecik (spike) üreten sinir hücresi, **C.** Tipik bir "entegrasyon ve ateşleme" (integrate-and-fire) nöronunun çalışma mekanizması.

SNN'lerin bir diğer önemli bileşeni ise iğnecik kodlama yöntemleridir. Bu yöntemler, analog veya sürekli zamanlı verilerin iğnecik dizilerine dönüştürülmesini sağlar. En yaygın iğnecik kodlama teknikleri arasında delta modülasyon, zaman kodlama (temporal coding), frekans kodlama ve rank-order kodlama yer alır. Bu çalışmada kullanılan delta modülasyon tabanlı iğnecik kodlama, sinyaldeki değişikliklerin büyüklüğüne göre iğnecik üretir ve bu sayede veri sıkıştırması ile bilgi iletimini optimize eder [24]. Son yıllarda SNN'ler, özellikle görsel ve işitsel verilerin zaman tabanlı analizinde ve biyolojik sinir sistemlerine yakın bilgi işleme mimarilerinde tercih edilmeye başlanmıştır. Cilt lezyonu gibi medikal görüntü sınıflandırmalarında ise, SNN'ler hem verinin zaman serisi yapısını kullanarak hem de düşük enerji tüketimi ile önemli avantajlar sunmaktadır [25]. Ancak, SNN modellerinin eğitimi ve optimizasyonu klasik yapay sinir ağlarına kıyasla daha karmaşıktır. İğnecik tabanlı aktivasyonların ayırık ve zamana bağlı yapısı, geri yayılım gibi yaygın öğrenme algoritmalarının doğrudan uygulanmasını zorlaştırır. Bu nedenle, delta modülasyon gibi kodlama yöntemleri ve spike-timing dependent plasticity (STDP) gibi biyolojik öğrenme mekanizmaları SNN eğitiminde önemli yer tutmaktadır [26], [22]

Sinaptik ağırlık  $w$ , ön (pre) ve son (post) sinaptik spike'lar tarafından modüle edilebilir; bu ilişki STDP (Spike-Timing Dependent Plasticity) fonksiyonu olarak gösterilmiştir [21]. Rezistif sinapslar, voltaj dikenlerini sinaptik ağırlıklarıyla orantılı akımlara dönüştürür. Nöron bu akım girdilerini

entegre ederek membran voltajı  $V_{mem}$ 'i değiştirir;  $V_{mem}$  belirli bir eşik değeri  $V_{thr}$ 'yi aştığında, nöron ateşler ve  $V_{spk,out}$  şeklinde bir spike üretip bunu hem önceki hem sonraki nöronlara iletir [20]. STDP, sinaptik ağırlıkların ön (pre) ve son (post) sinaptik spike'ların zamanlamasına bağlı olarak ayarlanmasını sağlar. Sinaptik ağırlık  $w$ ,  $\Delta t = t_{post} - t_{pre}$  farkına göre aşağıdaki şekilde değişir:


$$\Delta w = A + e^{\left(\frac{-\Delta t}{\tau^+}\right)} A - e^{\left(\frac{-\Delta t}{\tau^-}\right)} A \quad |\Delta t > 0 \quad \Delta t \leq 0 \quad (1)$$

Burada  $A+$  ve  $A-$ , pozitif ve negatif ağırlık değişimlerinin maksimum değerlerini;  $\tau+$  ve  $\tau-$ , değişimin zaman sabitlerini temsil eder. Pozitif  $\Delta t$  pre-sinaptik spike'ın post-sinaptik spikeden önce gelmesi durumunda sinapsın güçlenmesini (long-term potentiation, LTP), negatif  $\Delta t$  ise post-sinaptik spike'ın pre-sinaptik spikeden önce gelmesi durumunda sinapsın zayıflamasını (long-term depression, LTD) ifade eder [24]. Rezistif sinapslar, voltaj dikenlerini sinaptik ağırlıklarıyla orantılı akımlara dönüştürür. Nöron bu akım girdilerini entegre ederek membran voltajı  $V_{mem}$ 'i değiştirir;  $V_{mem}$  belirli bir eşik değeri  $V_{thr}$ 'yi aştığında, nöron ateşler ve  $V_{spk,out}$  şeklinde bir spike üretip bunu hem önceki hem sonraki nöronlara iletir [23].

### 2.3. İğnecik Kodlama: Delta Modülasyon

SNN içerisinde analog sinyallerin iğnecik dizilerine dönüştürülmesi, ağırlık giriş verisinin biyolojik ilkelere daha yakın bir biçimde işlenmesini sağlar. Bu dönüşümde kullanılan kodlama yöntemi, ağırlık öğrenme kapasitesini ve bilgi temsil gücünü doğrudan etkilemektedir. Geleneksel oran-temelli kodlama (rate coding) yöntemleri, sinyali belirli bir zaman aralığındaki iğnecik frekansı üzerinden temsil ederken, bu yaklaşım genellikle enerji açısından verimsiz kalmaktadır. Buna karşılık, delta modülasyon (DM) zaman-temelli bir iğnecik kodlama tekniği olarak öne çıkmaktadır [27].

Delta modülasyonun temel prensibi, giriş sinyalindeki değişimlerin (yani türevsel bilginin) iğnecik üretimine yol açmasıdır. Eğer sinyalde belirli bir eşik değerini aşan bir artış ya da azalış varsa, buna karşılık gelen bir "pozitif" veya "negatif" iğnecik üretilir. Böylece sürekli değişmeyen, yalnızca belirgin farklılıklar içeren sinyaller etkin bir şekilde kodlanır. Bu yöntemin çalışma prensibi Şekil 3'te görülmektedir. Bu yöntem, hem bilgi kaybını minimize etme hem de gereksiz iğnecik üretimini azaltarak enerji verimliliğini artırma avantajı sağlar. Ayrıca delta modülasyon, sensör verilerinin düşük bant genişliğiyle iletilmesi ve donanım üzerinde gerçek zamanlı çalışmaya uygunluğu nedeniyle donanım tabanlı SNN uygulamalarında tercih edilmektedir. Özellikle görsel ve işitsel sinyallerin sıkıştırılmış bir şekilde iğnecik dizilerine dönüştürülmesinde etkili sonuçlar verdiği gösterilmiştir. Sonuç olarak, bu çalışmada delta modülasyonun seçilmesinin nedeni hem biyolojik olarak makul bir sinyal işleme mekanizması sunması hem de donanım uyumluluğu sayesinde gerçek zamanlı uygulamalara olanak sağlamasıdır.



Şekil 3. Delta Modülasyon ve İğnecik Yapısı [28]

### 2.3. Performans Ölçütleri

Bu çalışmada, sınıflandırma performansının değerlendirilmesi amacıyla doğruluk matrisine (confusion matrix) dayalı metrikler kullanılmıştır. Bu matrisin temelini oluşturan dört ana parametre şu şekilde tanımlanmıştır:

- Gerçek Pozitif (TP - True Positive): Kanserli bir cilt lezyonunun model tarafından doğru bir şekilde "kanserli" olarak sınıflandırıldığı durumlar.
- Gerçek Negatif (TN - True Negative): Kanserli olmayan (iyi huylu) bir lezyonun doğru bir şekilde "kanserli değil" olarak sınıflandırıldığı durumlar.
- Yanlış Pozitif (FP - False Positive): Kanserli olmayan bir lezyonun model tarafından hatalı bir şekilde "kanserli" olarak etiketlendiği durumlar.
- Yanlış Negatif (FN - False Negative): Kanserli bir lezyonun hatalı bir şekilde "kanserli değil" olarak göz ardı edildiği durumlar.

Modelin genel başarısını ölçmek için bu dört parametre temel alınarak doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1-skoru (F1-score) metrikleri aşağıda verilen formüller kullanılarak hesaplanmıştır.

Doğruluk, modelin tahminlerinin genel doğruluğunu değerlendirmekte olup, Denklem 2.1'de gösterilmiştir.

$$\text{Doğruluk} = (TP + TN) / (TP + TN + FP + FN) \quad (2.1)$$

Kesinlik, pozitif olarak yapılan tahminlerin içerisindeki gerçek pozitiflerin oranını ifade eder ve Denklem 2.2'de gösterilmiştir.

$$\text{Kesinlik} = TP / (TP + FP) \quad (2.2)$$

Duyarlılık, gerçek pozitiflerin tüm pozitifler içerisindeki oranını belirtir ve Denklem 2.3'te gösterilmiştir.

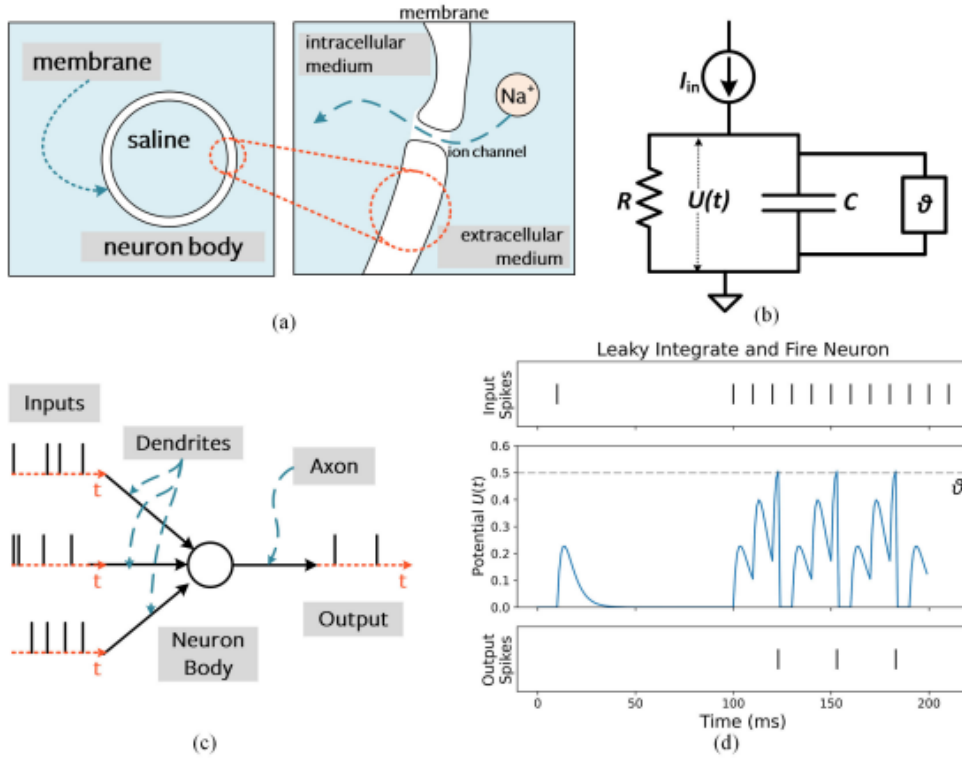
$$\text{Duyarlılık} = TP / (TP + FN) \quad (2.3)$$

F1-skoru ise kesinlik ve duyarlılığın ağırlıklı ortalaması olup, Denklem 2.4'te gösterildiği gibi hesaplanır.

$$F1 - skor = TP / (TP + 0.5 * (FP + FN)) \quad (2.4)$$

### 2.3. Model Mimarisi ve Eğitim Süreci

Bu çalışmada, cilt lezyonu sınıflandırması için biyolojik sinir sistemlerinden esinlenmiş bir SNN mimarisi geliştirilmiştir. Model, zaman tabanlı bilgi işleme yeteneğine sahip LIF nöronlarından oluşmakta olup, üç ana katmandan meydana gelmektedir: Giriş katmanı, gizli katmanlar ve çıkış katmanı. Giriş katmanı, delta modülasyon yöntemiyle iğnecik dizilerine dönüştürülmüş gri tonlamalı görüntü verilerini zaman adımları halinde alır ve sonraki katmanlara iletir. Gizli katmanlar, gelen iğnecik akımlarını entegre ederek membran potansiyelini günceller ve belirlenen eşik değerini aşan nöronlar için iğnecik üretir. Modelin çıkış katmanı ise, sınıf sayısı kadar nörondan oluşmakta ve her nöronun aktivasyon seviyesi ilgili sınıfın tahmini olasılığını temsil etmektedir.



**Şekil 4.** (a) Yalıtkan bilipid membran (b) Kapasitif membran elektriksel eşleniği (c) dendritik iletim. (d) Membran potansiyeli simülasyonu.

LIF nöron modelinde yalıtkan bilipid membran hücre içi ve hücre dışı ortamı ayırır. Geçitli iyon kanalları  $Na^+$  gibi yük taşıyıcılarının zardan geçmesine izin verir. Kapasitif membran ve dirençli iyon kanalları bir RC devresi oluşturur. Membran potansiyeli bir  $\theta$  eşikini aştığında, bir ani yükselme meydana gelir.  $I_{in}$  tarafından üretilen giriş sivri uçları dendritik ağaç aracılığıyla nöron gövdesine iletilir. Yeterli uyarım çıkışta sivri uç emisyonuna neden olur. Membran potansiyelinin  $U(t)$  eşikine ulaştığını gösteren simülasyon, keyfi olarak  $\theta = 0,5$  V olarak ayarlanmıştır ve bu da çıkış iğneciklerini oluşturur [28].

Bir RC devresi kullanılarak modellenen pasif membranın dinamikleri şu şekilde gösterilebilir

$$\tau \frac{dU(t)}{dt} = -U(t) I_{in}(t)R \quad (5)$$

$$U(t) = I_{in}R + [U_0 - I_{in}R]e^{-\frac{t}{\tau}} \quad (6)$$

$$U[t] = \beta U[t - 1] + (1 - \beta)I_{in}[t] \quad (7)$$

$V(t)$  membran potansiyelini,  $\tau_m$  membran zaman sabitini,  $R$  membran direncini ve  $I(t)$  nörona gelen toplam akımı ifade etmektedir. Membran potansiyeli, belirlenen eşik değeri ( $V_{th}$ ) aştığında nöron bir iğnecik üretmekte ve potansiyeli sıfırlanmaktadır ve  $\beta = e^{-1/\tau}$  zamana bağlı bozunma (depolarizasyon) oranıdır [22]. SNN'lerin eğitimi, iğnecik fonksiyonlarının ayırık ve zamana bağımlı yapısı nedeniyle klasik geri yayılım algoritmalarıyla doğrudan mümkün değildir. Bu nedenle, model eğitimi sırasında surrogate gradient (vekil gradyan) yöntemi uygulanmıştır. Bu yaklaşım, iğnecik aktivasyon fonksiyonlarının türevlerini yumuşatarak, gradyan tabanlı optimizasyon algoritmalarının kullanılmasına olanak vermektedir [26].

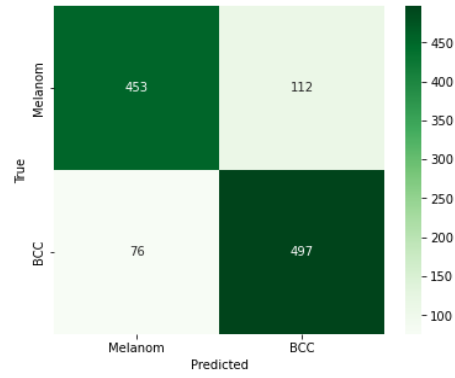
### 3. Bulgular

Eğitim sürecinde, modelin çıkışındaki iğnecik oranları hedef sınıf etiketleriyle karşılaştırılarak çapraz entropi kaybı minimize edilmiştir. Optimizasyon algoritması olarak Adaptif Moment Tahmin algoritması (ADAM) seçilmiş ve öğrenme oranı 0.001 olarak ayarlanmıştır [25]. Model eğitimi esnasında aşağıdaki hiper parametre seti olarak, zaman adımı sayısı 100, batch boyutu 64 olarak belirlenmiş, aşırı öğrenme riskini azaltmak için dropout uygulanmış ve erken durdurma (early stopping) kriterleri kullanılmıştır. Ayrıca, HAM 10000 veri setinde gözlenen sınıf dengesizliğini gidermek amacıyla sınıf ağırlıklı kayıp fonksiyonu kullanılarak az temsil edilen sınıfların model üzerindeki etkisi artırılmıştır [8, 24]. Bu mimari ve eğitim süreci, modelin hem genel hem de alt grup sınıflandırma performansını artırmaya yönelik olarak tasarlanmıştır ve detaylı şekilde analiz edilmiştir.

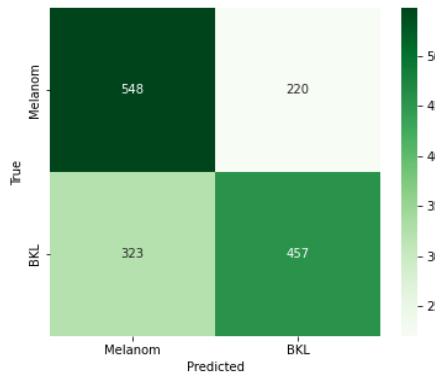
Çalışmada ikili, uçlu ve dörtlü sınıflandırma teknikleri kullanılmış ve sınıflandırma performansları incelenmiştir. İkili sınıflandırmada sırasıyla tehlikeli sınıfların sınıflandırılması Melanom - Bazal Hücreli Karsinom (Mel-BCC), yapılmıştır. Sonrasında Melanom - Seboreik Keratoz (Mel - BKL) ve Melanom - Benign tehlikeli ve görece tehlikesiz sınıfların sınıflandırma performansları incelenmiştir. Üçlü sınıflandırmada sırasıyla Melanom - Seboreik Keratoz - Benign (Mel -BKL - Nev), Melanom - Seboreik Keratoz - Bazal Hücreli Karsinom (Mel -BKL - BCC) ve Melanom - Bazal Hücreli Karsinom - Benign (Mel - BCC - Nev) modelleri oluşturulmuştur. Dörtlü sınıflandırmada ise Melanom - Seboreik Keratoz - Benign - Bazal Hücreli Karsinom (Mel -BKL - BCC - Nev) sınıflarının tümünü kapsayan bir model geliştirilmiştir. Geliştirilen sınıflandırma modellerinin eğitim aşamasında elde edilen performans sonuçları Tablo 1, 2 ve 3'te test aşamasında ölçülen performansları ise Tablo 4, 5 ve 6'da verilmektedir. Modellerin eğitim aşamasında elde edilen karmaşıklık matrisleri Şekil 5, 6 ve 7'de görülmekte ve test aşamasında elde edilen karmaşıklık matrisleri ise Şekil 8, 9 ve 10'da verilmektedir.

**Tablo 1.** Cilt Lezyon sınıflandırmasında kullanılan iki sınıflı modellerin eğitim sonuçları

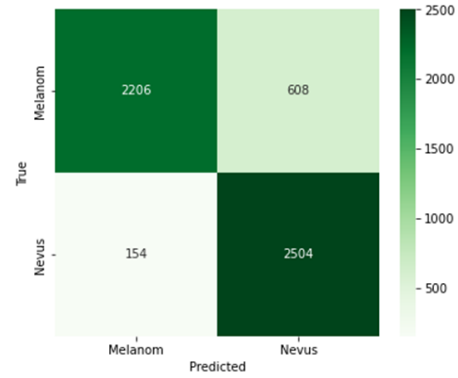
Model	Sınıf	Kesinlik	Duyarlılık	F1
MEL-BCC	MEL	0.86	0.80	0.83
	NEV	0.82	0.87	0.84
MEL - BKL	MEL	0.63	0.71	0.67
	BKL	0.68	0.59	0.63
MEL -NEV	MEL	0.93	0.78	0.85
	NEV	0.80	0.94	0.87



A



B

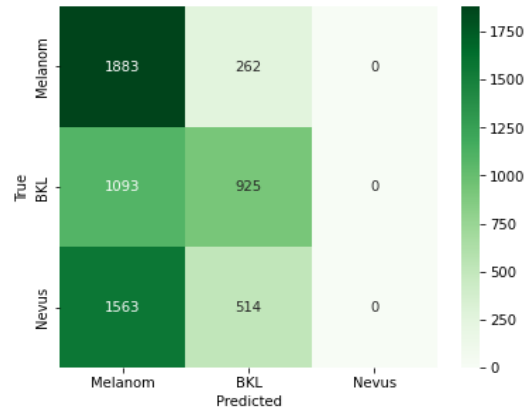


C


**Şekil 5.** İki sınıflı modellerin eğitim karmaşıklık matrisleri  
A. MEL – BCC, B. MEL – BKL, C. MEL – NEV

**Tablo 2.** Cilt Lezyon sınıflandırmasında kullanılan üç sınıflı modellerin eğitim sonuçları

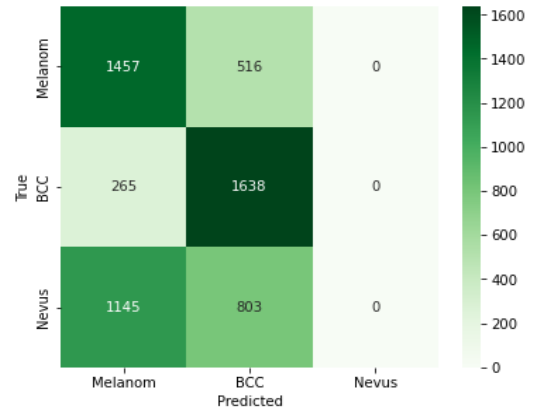
Model	Sınıf	Kesinlik	Duyarlılık	F1
MEL-BKL-NV	MEL	0.41	0.88	0.56
	BKL	0.54	0.46	0.50
	NV	0.0	0.0	0.0
MEL-BKL-BCC	MEL	0.90	0.48	0.62
	BKL	0.78	0.37	0.50
	BCC	0.51	1.0	0.68
MEL-BCC-NV	MEL	0.51	0.74	0.60
	BCC	0.55	0.86	0.67
	NV	0.0	0.0	0.0



A



B

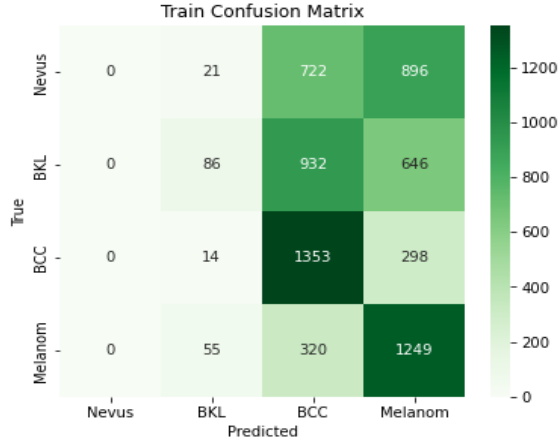


C

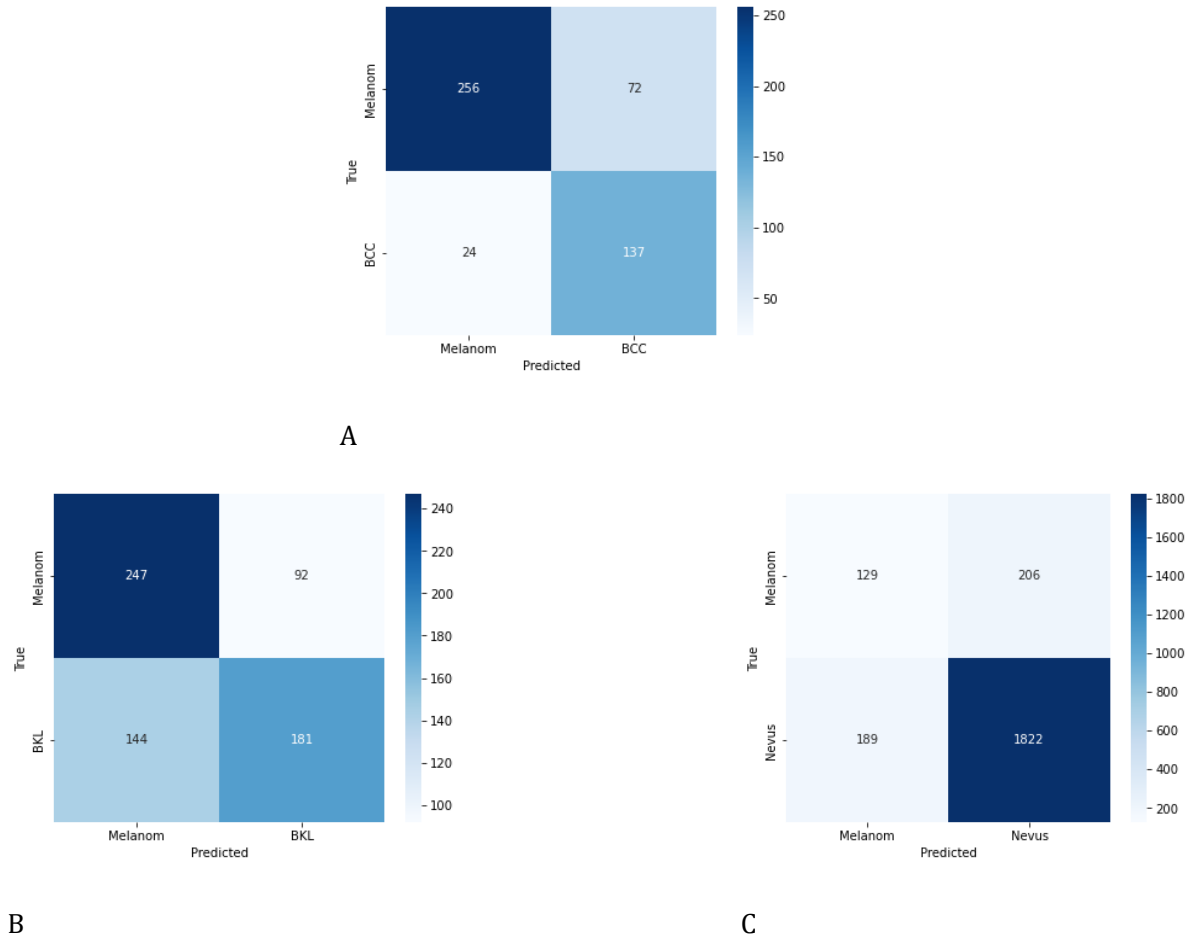
**Şekil 6.** Üç sınıflı modellerin eğitim karmaşıklık matrisleri  
A. MEL-BKL-NEV, B. MEL-BKL-BCC, C. MEL-BCC-NEV

**Tablo 3.** Cilt Lezyon sınıflandırmasında kullanılan dört sınıflı modelin eğitim sonuçları

Model	Sınıf	Kesinlik	Duyarlılık	F1
NEV - BKL-BCC-MEL	NEV	0.0	0.0	0.0
	BKL	0.49	0.05	0.09
	BCC	0.41	0.81	0.54
	MEL	0.40	0.77	0.53

**Şekil 7.** Dört sınıflı modelin eğitim karmaşıklık matrisi**Tablo 4.** Cilt Lezyon sınıflandırmasında kullanılan iki sınıflı modellerin test sonuçları

Model	Sınıf	Kesinlik	Duyarlılık	F1
MEL-NEV	MEL	0.41	0.39	0.40
	NEV	0.90	0.91	0.90
MEL- BKL	MEL	0.63	0.73	0.68
	BKL	0.66	0.56	0.61
MEL -BCC	MEL	0.91	0.78	0.84
	BCC	0.66	0.85	0.74

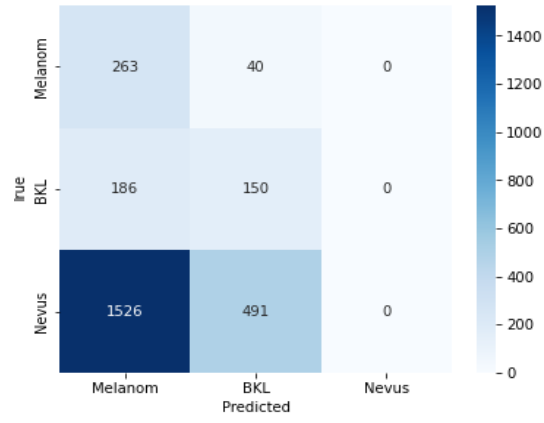


**Şekil 8.** İki sınıflı modellerin test karmaşıklık matrisleri

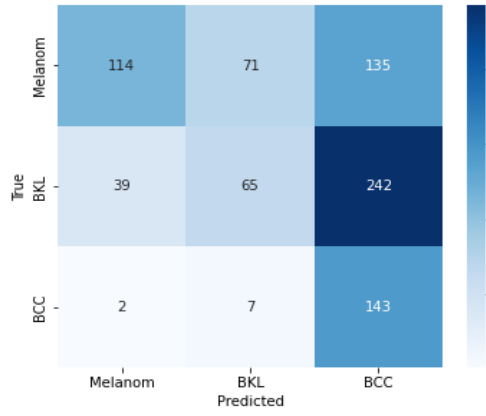
A. MEL – BCC, B. MEL – BKL, C. MEL – NEV

**Tablo 5.** Cilt Lezyon sınıflandırmasında kullanılan üç sınıflı modellerin test sonuçları

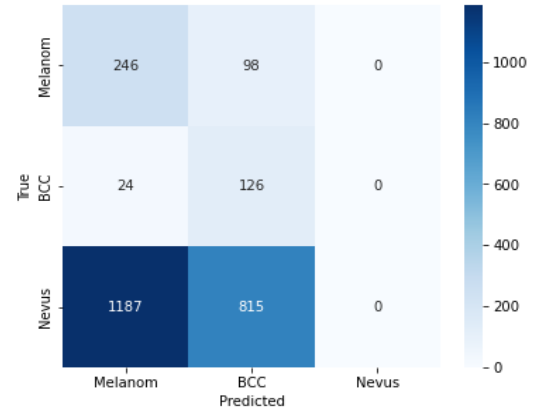
Model	Sınıf	Kesinlik	Duyarlılık	F1
MEL-BKL-NEV	MEL	0.13	0.87	0.23
	BKL	0.22	0.45	0.29
	NV	0.0	0.0	0.0
MEL-BKL-BCC	MEL	0.74	0.36	0.48
	BKL	0.45	0.19	0.27
MEL-BCC-NEV	BCC	0.28	0.94	0.43
	MEL	0.17	0.72	0.27
	NV	0.0	0.0	0.0



A



B

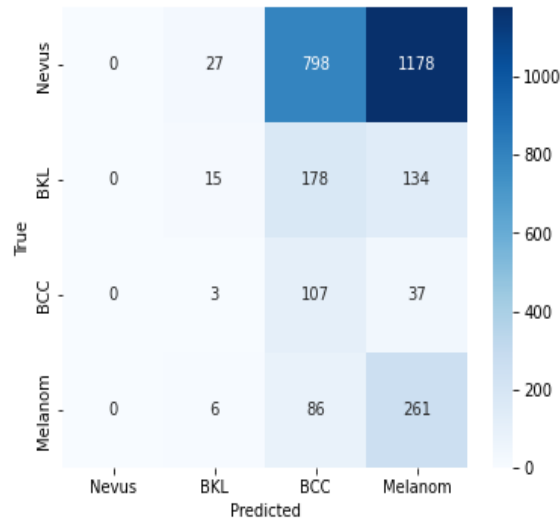


C

**Şekil 9.** Üç sınıflı modellerin eğitim karmaşıklık matrisleri  
**A.** MEL -BKL-NEV, **B.** MEL -BKL-BCC, **C.** MEL -BCC-NEV

**Tablo 6.** Cilt Lezyon sınıflandırmasında kullanılan dört sınıflı modelin test sonuçları

Model	Sınıf	Kesinlik	Duyarlılık	F1
NEV - BKL-BCC-MEL	NEV	0.0	0.0	0.0
	BKL	0.29	0.05	0.08
	BCC	0.09	0.73	0.16
	MEL	0.16	0.74	0.27



**Şekil 10.** Dört sınıflı modelin test karmaşıklık matrisi

Çalışma, tüm sınıfların tek bir modelde değerlendirildiği çok sınıflı bir yaklaşımla sınırlı kalmayıp, farklı zorluk seviyelerine göre ikili, üçlü ve dördü alt sınıf kümeleri oluşturularak modelin performansı detaylıca analiz edilmiştir. Eğitim sürecinde, aşırı öğrenme riskini azaltmak için dropout ve erken durdurma kriterleri kullanılmıştır. Ayrıca, HAM10000 veri setinde gözlemlenen sınıf dengesizliğini gidermek amacıyla, az temsil edilen sınıfların model üzerindeki etkisini artırmak için sınıf ağırlıklı kayıp fonksiyonu uygulanmıştır. Optimizasyon algoritması olarak Adaptif Moment Tahmin algoritması (ADAM) ve öğrenme oranı 0.001 olarak belirlenmiştir.

İkili sınıflandırma, modellerin temel ayırım yapma yeteneklerini göstermesi açısından kritik öneme sahiptir. Test sonuçları aşağıdaki senaryolarda önemli başarılar ortaya koymaktadır. Melanom (MEL) ve Bazal Hücreli Karsinom (BCC) ayırımını hedefleyen (MEL-BCC) model, en tehlikeli iki kanser türünü (Melanom en tehlikeli kabul edilir) birbirinden ayırmada yüksek başarı göstermiştir. MEL sınıfının kesinliği 0.91 ve F1 skoru 0.84 olarak ölçülmüştür. Bu, modelin özellikle Melanomu yüksek bir kesinlikle teşhis etme yeteneğinin güçlü olduğunu gösterir. BCC'nin F1 skoru ise 0.74'tür. Melanom (MEL) ve Benign Pigmentli Nevüsler (NEV) ayırımını gerçekleştiren (MEL-NEV) senaryoda model, iyi huylu ve en yaygın sınıf olan Nevüs'e (NEV) karşı belirgin bir eğilim göstermiştir. NEV, test aşamasında 0.90 F1 skoru (Kesinlik 0.90, Duyarlılık 0.91) ile neredeyse mükemmel performans sergilerken, Melanom'un F1 skoru 0.40'ta kalmıştır. Bu, modelin Nevüs'ü çok iyi tanımladığını, ancak Melanom'u Nevüs'ten ayırırken zorlandığını veya Nevüs lehine hata yaptığını düşündürmektedir. Melanom (MEL) ve Seboreik Keratoz (BKL) ayırımının yapıldığı modelde (MEL-BKL) MEL, 0.68 F1 skoru, BKL ise 0.61 F1 skoru elde etmiştir. Bu sonuçlar, iki sınıf arasında kabul edilebilir bir ayırım yapma yeteneği olduğunu gösterir.

Sınıf sayısının artmasıyla birlikte model performansı genel olarak düşüş eğilimi göstermiştir. Hem üçlü (MEL-BKL-NEV ve MEL-BCC-NEV) hem de dördü sınıflandırma senaryolarında, Nevüs (NV) sınıfının Kesinlik, Duyarlılık ve F1 skorları 0.0 olarak kaydedilmiştir. Bu, modelin test aşamasında Nevüs sınıfının hiçbir örneğini doğru bir şekilde sınıflandıramadığı, muhtemelen tüm NV örneklerini diğer sınıflara atadığı anlamına gelir. Dördü sınıflandırmada, hem BCC (0.73) hem de MEL (0.74) yüksek duyarlılığa sahiptir, yani pozitif vakaların çoğunu tespit edebilmektedir. Ancak, kesinlikleri sırasıyla 0.09 ve 0.16 gibi çok düşüktür. Bu durum, modelin birçok negatif örneği yanlışlıkla kanserli (pozitif) olarak tahmin ettiğini (yüksek Yanlış Pozitif - FP oranı) ve sınıflar arası ayırım yapma gücünün düştüğünü göstermektedir.

Cilt kanseri şüphesiyle yapılan klinik başvuruların çok büyük bir bölümü, iyi huylu bir oluşum olan "Nevüs" (NV) tanısıyla sonuçlanmaktadır. Bu klinik gerçek, HAM10000 gibi deri lezyonu veri setlerine de yansımakta ve NV sınıfı, örnek sayısı açısından diğer tüm sınıflarla karşılaştırıldığında

belirgin bir farkla en yüksek frekansa sahip olmaktadır. Çalışmada kullanılan verilerin sınıf dağılımı Tablo 7'de sunulmuştur.

**Tablo 7.** HAM1000 veri seti örnek frekansları

Sınıf	Mel	Nv	Bcc	Bkl	Df	Vasc	Akiec
Frekans	1113	6705	514	1099	115	142	327

Görece fazla temsil edilen NV sınıfının verileri incelendiğinde, özellikle malign (kötü huylu) melanom (MEL) sınıfı verileriyle yapısal ve görsel açıdan kayda değer benzerlikler tespit edilmektedir. İki lezyon türü arasındaki bu yüksek morfolojik benzerlik, otomatik sınıflandırma modelleri için önemli bir zorluk teşkil etmekte ve modelin NV örneklerini, özellikle de atipik görünümlü olanları, MEL'den ayırt etmesini güçleştirmektedir. Dolayısıyla, veri setindeki bu dengesiz dağılım (sınıf dengesizliği) ve sınıflar arasındaki yüksek görsel benzerlik, modellerin doğru ve güvenilir bir şekilde öğrenmesinin önündeki temel engeller olarak öne çıkmaktadır.

#### 4. Tartışma ve Sonuç

Bu çalışma, SNN mimarisini tıbbi görüntü analizine uygulayarak, mevcut teknolojilere alternatif sunma ve kritik ayırım senaryolarında güçlü performans gösterme potansiyeli nedeniyle öne çıkmaktadır. Çalışmanın temel güçlü yanı, biyolojik sinir sistemlerinden ilham alan Üçüncü Nesil Yapay Sinir Ağı yapısı olan Spiking Neural Networks (SNN) kullanımına odaklanmasıdır. Geleneksel derin öğrenme modellerinin (CNN) aksine, SNN'ler bilgiyi zaman tabanlı ayırık iğnecik sinyalleri biçiminde işler. Bu olay tabanlı bilgi işleme (event-driven processing), yalnızca anlamlı sinyaller ortaya çıktığında işlem yapılmasını sağlar ve gereksiz hesaplamayı önler. Bu yaklaşım, sınıflandırma performansını yüksek tutarken hesaplama maliyetini düşürmektedir. SNN'ler, özellikle nöromorfik donanımlar üzerinde kullanıldığında, klasik derin öğrenme modellerine kıyasla çok daha az enerji harcar ve gerçek zamanlı uygulamalar için son derece uygundur.

Çalışmanın bir diğer güçlü yönü, SNN'e entegre edilen delta modülasyon (DM) tabanlı iğnecik kodlama yöntemidir. DM, sinyaldeki belirgin değişimlere (türevsel bilgiye) göre iğnecik üretir. Bu, sürekli değişmeyen sinyallerin etkin bir şekilde kodlanmasını sağlar, bilgi kaybını minimize eder ve gereksiz iğnecik üretimini azaltarak veri iletimini optimize eder. Delta modülasyonu, görsel verilerin sıkıştırılmış bir şekilde iğnecik dizilerine dönüştürülmesinde etkili sonuçlar vermesinin yanı sıra, düşük bant genişliği gerektirmesi ve donanım üzerinde gerçek zamanlı çalışmaya uygunluğu nedeniyle nöromorfik uygulamalarda tercih edilmektedir.

Çalışmada elde edilen bulgular ışığında, SNN modelinin tıbbi olarak en kritik ayırım senaryolarından birinde yüksek performans sergilediğini göstermektedir. İkili sınıflandırmada, en tehlikeli cilt kanseri olan Melanom'u (MEL) Bazal Hücreli Karsinom'dan (BCC) ayırmada test aşamasında %91 kesinlik ve %84 F1 skoru elde edilmesi, modelin yüksek riskli malign lezyonları güvenilir bir şekilde ayırt edebilme potansiyelini kanıtlamaktadır. Erken ve doğru tanı, etkili tedavi için kritik önem taşıdığından, bu bulgu, SNN'lerin erken teşhis sistemleri için umut vadeden bir alternatif olduğunu desteklemektedir. Çalışmanın metodolojisi, modelin genel performansını değil, aynı zamanda farklı zorluklardaki sınıflar arası ayırım kapasitesini de derinlemesine analiz etmeyi mümkün kılmıştır.

Bununla birlikte, çok sınıflı senaryolarda özellikle Benign Pigmentli Nevüs (NV) sınıfında belirgin bir performans düşüşü gözlemlenmiştir. Üçlü ve dördü sınıflandırma deneylerinde NV sınıfına ait kesinlik ve duyarlılık değerlerinin oldukça düşük olması, bu sınıfın model tarafından diğer lezyon türleriyle sıklıkla karıştırıldığını göstermektedir. Bu durumun temel nedenlerinden biri, HAM10000 veri kümesinde NV sınıfının görsel açıdan yüksek derecede heterojen bir yapıya sahip olmasıdır. NV lezyonları; renk dağılımı, doku yapısı ve sınır belirginliği açısından geniş bir varyasyon sergilemekte, bu da tekil ve ayırt edici bir temsil öğrenimini zorlaştırmaktadır. Ek olarak, delta modülasyonun doğası gereği kenar ve ani yoğunluk değişimlerine duyarlı olması, NV sınıfının çoğu örneğinde görülen daha yumuşak geçişli ve düşük kontrastlı yapıların yeterince vurgulanamamasına yol açmaktadır. Buna karşılık, Melanom ve BCC gibi malign lezyonlar düzensiz sınırlar ve belirgin yapısal bozulmalar

sergilediğinden, delta modülasyon sonrası elde edilen iğnecik temsilleri bu sınıflar için daha ayırt edici olmuştur. Bu durum, modelin malign sınıflar lehine daha kararlı karar sınırları oluşturmaya, ancak benign sınıfların temsilde zayıf kalmasına neden olmaktadır.

Bu bulgular doğrultusunda, gelecekteki çalışmalarda NV sınıfındaki performansın iyileştirilmesine yönelik olarak öncelikle, NV sınıfına özgü veri artırma ve örnek çeşitlendirme teknikleri ile görsel heterojenliğin daha dengeli biçimde şekillenmesi planlanmaktadır. Bunun yanı sıra, delta modülasyonun farklı kodlama yaklaşımlarıyla hibrit biçimde kullanılması veya çok katmanlı SNN mimarilerinin tasarlanması, benign lezyonlara ait ince yapısal detayların daha iyi yakalanmasını mümkün kılacaktır.

İkili, üçlü ve dördü alt grupların kullanılması, modelin güçlü ve zayıf yönlerini (örneğin, Nevüs gibi dengesiz sınıfları büyük gruplarda sınıflandırmadaki başarısızlıklar) açıkça ortaya koymuştur. Bu çok yönlü değerlendirme, gelecekteki çalışmalar için dengesizlik sorunlarının çözümüne yönelik net hedefler sağlamaktadır.



**Hakem:** Dış, Bağımsız.

**Teşekkür:**

Bu çalışmanın gerçekleştirilmesinde destek veren tüm kişi ve kurumlara teşekkür ederiz.

**Beyanname:**

**1. Özgünlük Beyanı:**

Bu çalışma özgündür.

**2. Yazar Katkıları:**

**Fikir:** AS,VA; **Kavramsallaştırma:** AS,VA; **Literatür Taraması:** AS,VA; **Veri Toplama:** AS,VA; **Veri İşleme:** AS,VA; **Analiz:** AS,VA; **Yazma - orijinal taslak:** AS,VA; **Yazma - inceleme ve düzenleme:** AS,VA.

**3. Etik Kurul İzni:**

Etik Kurul İzni gerekmemektedir.

**4. Finansman/Destek:**

Bu çalışma, herhangi bir finansman ya da destek almamıştır.


**5. Çıkar Çatışması:**

Yazarlar, herhangi bir çıkar çatışması olmadığını beyan etmektedirler.

**6. Üretken Yapay Zeka Beyanı:**

Çalışmanın hiçbir safhasında yapay zeka araçlarından faydalanılmamıştır.

**7. Sürdürülebilir Kalkınma Amaçları:**



**KAYNAKÇA**

A. Esteva et al., "Dermatologist-level classification of skin cancer with deep neural networks," Nature, vol. 542, no. 7639, pp. 115–118, 2017.

- [2] P. Tschandl, C. Rosendahl, and H. Kittler, "The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions," *Sci Data*, vol. 5, no. 1, pp. 1–9, 2018.
- [3] S. S. Han, M. S. Kim, W. Lim, G. H. Park, I. Park, and S. E. Chang, "Classification of the clinical images for benign and malignant cutaneous tumors using a deep learning algorithm," *Journal of Investigative Dermatology*, vol. 138, no. 7, pp. 1529–1538, 2018.
- [4] Y. Liu et al., "A deep learning system for differential diagnosis of skin diseases," *Nat Med*, vol. 26, no. 6, pp. 900–908, 2020.
- [5] D. A. Okuboyejo and O. O. Olugbara, "A review of prevalent methods for automatic skin lesion diagnosis," *Open Dermatol J*, vol. 12, no. 1, 2018.
- [6] Y. Zhang, H. Liu, and Q. Hu, "Transfuse: Fusing transformers and cnns for medical image segmentation," in *International conference on medical image computing and computer-assisted intervention*, Springer, 2021, pp. 14–24.
- [7] N. C. F. Codella et al., "Deep learning ensembles for melanoma recognition in dermoscopy images," *IBM J Res Dev*, vol. 61, no. 4/5, pp. 1–5, 2017.
- [8] P. Tschandl, C. Rosendahl, and H. Kittler, "The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions," *Sci Data*, vol. 5, no. 1, pp. 1–9, 2018.
- [9] S. M. Thwin and H.-S. Park, "Skin lesion classification using a deep ensemble model," *Applied Sciences*, vol. 14, no. 13, p. 5599, 2024.
- [10] V. D. Nguyen, N. D. Bui, and H. K. Do, "Skin lesion classification on imbalanced data using deep learning with soft attention," *Sensors*, vol. 22, no. 19, p. 7530, 2022.
- [11] A. Dosovitskiy et al., "An image is worth 16x16 words: Transformers for image recognition at scale," *arXiv preprint arXiv:2010.11929*, 2020.
- [12] A. Esteva et al., "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, vol. 542, no. 7639, pp. 115–118, 2017.
- [13] S. S. Han, M. S. Kim, W. Lim, G. H. Park, I. Park, and S. E. Chang, "Classification of the clinical images for benign and malignant cutaneous tumors using a deep learning algorithm," *Journal of Investigative Dermatology*, vol. 138, no. 7, pp. 1529–1538, 2018.
- [14] E. Erdem and T. Aydin, "Artificial Neural Network-Based Approaches to Improve Classification of Skin Lesions," in *2023 Medical Technologies Congress (TIPTEKNO)*, IEEE, 2023, pp. 1–4.
- [15] S. Serte and H. Demirel, "Gabor wavelet-based deep learning for skin lesion classification," *Comput Biol Med*, vol. 113, p. 103423, 2019.
- [16] K. Ali, Z. A. Shaikh, A. A. Khan, and A. A. Laghari, "Multiclass skin cancer classification using EfficientNets—a first step towards preventing skin cancer," *Neuroscience Informatics*, vol. 2, no. 4, p. 100034, 2022.
- [17] N. Gessert et al., "Skin lesion diagnosis using ensembles, unscaled multi-crop evaluation and loss weighting," *arXiv preprint arXiv:1808.01694*, 2018.

- [18] T. Morita and X.-H. Han, "Investigating self-supervised learning for Skin Lesion Classification," in 2023 18th International Conference on Machine Vision and Applications (MVA), IEEE, 2023, pp. 1–5.
- [19] I. Pacal, B. Ozdemir, J. Zeynalov, H. Gasimov, and N. Pacal, "A novel CNN-ViT-based deep learning model for early skin cancer diagnosis," *Biomed Signal Process Control*, vol. 104, p. 107627, 2025.
- [20] W. Maass, "Networks of spiking neurons: the third generation of neural network models," *Neural networks*, vol. 10, no. 9, pp. 1659–1671, 1997.
- [21] W. Gerstner and W. M. Kistler, *Spiking neuron models: Single neurons, populations, plasticity*. Cambridge university press, 2002.
- [22] F. Ponulak and A. Kasinski, "Introduction to spiking neural networks: Information processing, learning and applications," *Acta Neurobiol Exp (Wars)*, vol. 71, no. 4, pp. 409–433, 2011.
- [23] M. Davies et al., "Loihi: A neuromorphic manycore processor with on-chip learning," *Ieee Micro*, vol. 38, no. 1, pp. 82–99, 2018.
- [24] S. Bian, E. Donati, and M. Magno, "Evaluation of encoding schemes on ubiquitous sensor signal for spiking neural network," *IEEE Sens J*, 2024.
- [25] M. Pfeiffer and T. Pfeil, "Deep learning with spiking neurons: Opportunities and challenges," *Front Neurosci*, vol. 12, p. 409662, 2018.
- [26] E. O. Neftci, H. Mostafa, and F. Zenke, "Surrogate gradient learning in spiking neural networks: Bringing the power of gradient-based optimization to spiking neural networks," *IEEE Signal Process Mag*, vol. 36, no. 6, pp. 51–63, 2019.
- [27] A. Tavanaei, M. Ghodrati, S. R. Kheradpisheh, T. Masquelier, and A. Maida, "Deep learning in spiking neural networks," *Neural networks*, vol. 111, pp. 47–63, 2019.
- [28] J. K. Eshraghian et al., "Training spiking neural networks using lessons from deep learning," *Proceedings of the IEEE*, vol. 111, no. 9, pp. 1016–1054, 2023.

