

Dermoskopik Görüntülerden Melanom Tespitinde Hiyerarşik Derin Özelliklere İlişkin Performans Karşılaştırması

Hasan Polat^{1*}

¹Elektrik ve Enerji Bölümü /Teknik Bilimler Meslek Yüksekokulu, Bingöl Üniversitesi, Türkiye

*(hasanpolat@bingol.edu.tr) Başlıca yazarın mail adresi

Özet – Melanom cilt kanseri en ölümcül kanser türlerinden biri olup ve ciddi bir halk sağlığı sorudur. Hastalığın erken ve doğru tanısı, kanser ile mücadelede etkin tedavilerin yürütülmesine olanak sağlayarak ölüm riskini azaltmaktadır. Ancak, malign melanom lezyonlarının diğer iyi huylu melanositik lezyonlarla olan benzerlikleri, dermoskopi görüntülerinden çıplak gözle değerlendirmeleri olumsuz etkileyerek erken ve doğru tanıları sekteye uğratmaktadır. Bu çalışmada, dermoskopi görüntülerinden iyi ve kötü huylu lezyonların tanısı için hekimlerin görsel algılarına ve ayırt etme kabiliyetlerine destek sağlayabilecek bir model önerilmiştir. Önerilen model, lezyonlara ilişkin ayırt edici özelliklerin otomatik olarak çıkarılması ve çıkarılan özelliklerin destek vektör makineleri (DVM) ile sınıflandırılmasından oluşmaktadır. Özellik çıkarımında, ön eğitilmiş bir evrimsel sinir ağı modeli tarafından alçak seviyeden yüksek seviyeye doğru hiyerarşik olarak çıkarılan özellik haritaları kullanılmıştır. Bulgular, en yüksek sınıflandırma performansının yüksek seviyeli özellik haritalarının kullanılması ile elde edildiğini göstermiştir. Sınıflandırma performansı, melanositik lezyonlara ilişkin ön eğitilmiş model tarafından çıkarılan 7x7 boyutunda yüksek seviyeli özellikler ile doğruluk, özgüllük, duyarlılık, kesinlik ve F-skor metrikleri türünden sırasıyla %98.12, %97.50, %98.75, %97.55 ve %98.13 olarak elde edilmiştir. Sonuçlar lezyonlara ilişkin genelleyici özelliklerin alçak seviyeli özelliklere kıyasla sınıflandırıcı tarafından daha verimli olarak ayrıştırıldığını göstermiştir.

Anahtar Kelimeler – Cilt Kanseri, Melanom, Derin Öğrenme, Dermoskopi, Destek Vektör Makineleri

I. GİRİŞ

Cilt kanseri, son yıllarda görülme sıklığındaki artış ve buna müteakip ölümle sonuçlanan vakalar nedeniyle ciddi bir halk sağlığı sorunu olarak ortaya çıkmaktadır. Cilt kanserleri arasında malign melanom en ölümcül olanıdır [1]. Melanom diğer cilt kanserlerine kıyasla daha düşük bir insidansa sahip olmasına rağmen daha ölümcül olması araştırmacıların bu konuya eğilim göstermelerine yol açmıştır [2]. Bu kapsamda erken tanı tekniklerinin geliştirilmesi amaçlanmıştır. Genellikle ultraviyole radyasyona bağlı olarak gelişen melanom cilt kanser türünün erken tanısı ile birlikte çeşitli etkin tedavi planlarının hazırlanması mümkün olabilmekte ve hastalığın olumsuz seyri durdurabilmektedir [3].

Melanom tanısında hekimler sıklıkla dermoskopik görüntüleme tekniğinden yararlanmaktadır. İnvaziv olmayan bu görüntüleme

yöntemi ile daha kapsamlı klinik değerlendirmelerin ve doğru tanının gerçekleşmesi mümkün olabilmektedir [4]. Ancak, hekimler tarafından geleneksel yaklaşımlar uygulanarak dermoskopi görüntülerinin incelenmesi, aşırı zaman kaybına, insan kaynaklı hatalara ve zorlu bir tanı sürecine neden olabilmektedir. Çünkü cilt lezyonları zamanla gelişmekte ve şeklini değiştire bilmektedir. Ayrıca, malign melanomun başlangıç aşamasında kötü huylu olmayan diğer cilt lezyonlarına benzemesi çıplak gözle tanıyı zorlaştırmaktadır [5]. Dolayısıyla, kanser ile mücadelede cilt anomalilerinin başlangıç aşamasında hızlı ve doğru bir şekilde tanınması için bilgisayar destekli sistemlerin tasarlanması büyük bir önem taşımaktadır.

Dermoskopi görüntülerinden melanomun otomatik olarak tespit edilmesi, lezyonların görünüm, boyut ve renk gibi farklılıklarından dolayı

zorlu bir süreçtir. Dolayısıyla, lezyonların doğru bir şekilde tespit ve ayırt edilebilmesi için sağlam modellerin geliştirilmesi gerekir [6]. Bu kapsamda özelliklerin manuel olarak çıkarıldığı konvansiyonel yaklaşımlara ve otomatik olarak çıkarıldığı derin mimarilere dayanan birçok başarılı model önerilmiştir. Ancak, derin mimarilere dayanan özellik öğrenme metodolojilerin sunmuş olduğu başarımlar nedeniyle popüleritesi artmıştır [7]. Bu kapsamda, Thabar ve ark. [8] hekimlere melanom tanısında destek sağlayan segmentasyon ve sınıflandırma modeli önermişlerdir. Lezyonlara ilişkin bölgelerden hızlandırılmış sağlam öznelikler yöntemi (Speeded Up Robust Features-SURF) ile özellik çıkarımı gerçekleştirilmiştir. Akabinde, evrimsel sinir ağları kullanılarak (ESA) sınıflandırma işlemi gerçekleştirilmiştir. Shetty ve ark. [9] dermoskopik görüntülerden farklı cilt lezyonlarının tespiti için konvansiyonel ve ESA tabanlı öğrenme algoritmalarını test etmişlerdir. ESA mimarisi kullanılarak %95.18 oranında bir başarı ile daha üstün bir performans elde edildiğini bildirmişlerdir. Hosny ve ark. [4] önceden eğitilmiş AlexNet mimarisinin ince ayarlanması ile melanom türünün de yer aldığı yedi farklı cilt lezyonunu sınıflandırmaya çalışmışlardır. Ön eğitilmiş modelin son üç katmanına ait ağırlıklarının yeniden ayarlanması ile ISIC 2018 veri seti sınıflandırılmaya çalışılmıştır. Veri artırımı yöntemi uygulanarak %98.70 oranında sınıflandırma doğruluğunu elde etmişlerdir. Ozkan ve Koklu [10] atipik ve normal nevüs türünde lezyonlardan malign melanom lezyonlarının ayırt edilmesi için konvansiyonel makine öğrenme algoritmalarına dayanan otomatik tespit modeli önermişlerdir. Dermatoloji uzmanları tarafından lezyonların ABCD (asimetri, kenar, renk ve pigment) kuralına göre işaretlenen özellikleri kullanılarak farklı sınıflandırıcı algoritmalarının ayrıştırıcı kabiliyetleri test edilmiştir. En iyi performansı %92.50 ile yapay sinir ağları (YSA) tananlı model ile elde etmişlerdir.

Bu çalışmada, dermoskopi görüntülerinden iyi ve kötü huylu lezyonların tanısı için hekimlerin görsel algılarına ve ayırt etme kabiliyetlerine destek sağlayabilecek bir modelin geliştirilmesi amaçlanmıştır. Bu kapsamda, lezyonlara ilişkin dermoskopik görüntülerden özelliklerin etkin ve otomatik olarak çıkarılması için büyük ölçekli görüntü kümeleri üzerinde önceden eğitilmiş bir ESA modeli kullanılmıştır. Ön eğitilmiş mimari


tarafından çıkarılan özelliklerin sınıflandırılmasında destek vektör kümeleri (DVM) kullanılmıştır. Derin mimari tarafından alçak seviyeden yüksek seviyeye doğru hiyerarşik olarak çıkarılan özellik haritaları ayrı ayrı değerlendirilmiştir. Böylelikle, lezyonlardan basit ve karmaşık özelliklerinin ayırt edicilik noktasında baskınlığı irdelenmeye çalışılmıştır.

II. MATERYAL VE YÖNTEM

Bu çalışmada atipik ve genel nevüslerden malign melanom tanısında önerilen modelin eğitiminde kullanılan veri seti, otomatik özellik çıkarımında kullanılan ön eğitilmiş ESA mimarisi, sınıflandırıcı ve model başarımları metrikleri açıklanmaktadır.

A. PH^2 Melanositik Veri Seti

Bu çalışmada, melanositik lezyonlara ilişkin dermoskopi görüntülerinin yer aldığı PH^2 veri seti kullanılmıştır [11]. Veri seti 160'ı atipik/ genel nevüs ve 40'ı malign melanom lezyon olmak üzere toplamda 200 görüntüden oluşmaktadır (Ph2, pdf). Veri seti segmentasyon ve sınıflandırma modellerinin geliştirilmesi ve test edilmesi amacıyla üretilmiştir. Dermoskopik görüntüler, değişmeyen koşullar altında 20x büyütülerek 8-bit RGB formatında ve 768x560 piksel çözünürlüğünde sunulmuştur [1]. Şekil 1'de PH^2 veri setinde yer alan farklı lezyonlara ilişkin örnek görüntüler paylaşılmıştır.



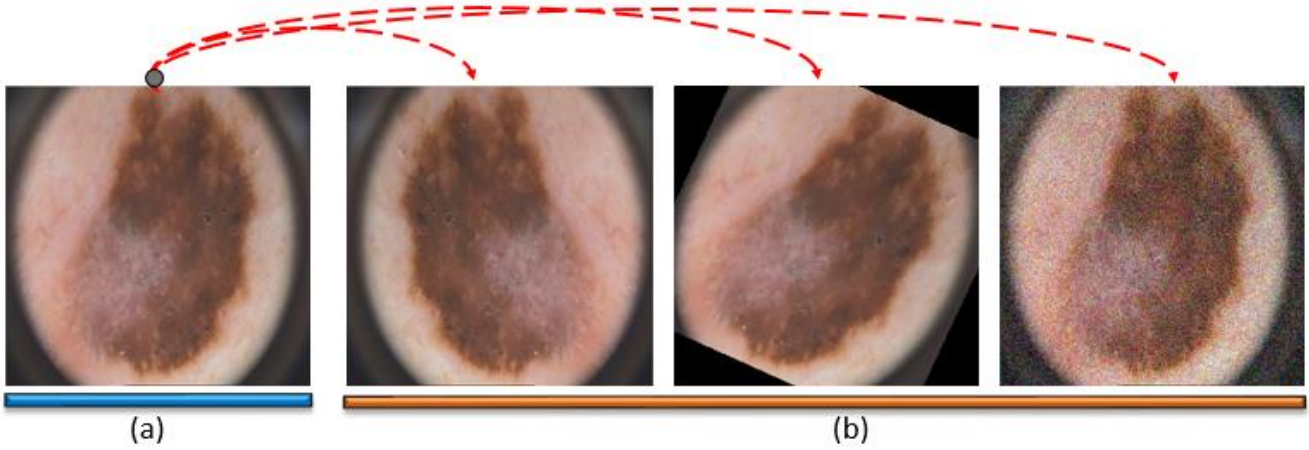
Şekil 1. PH^2 veri setine ilişkin örnek görüntüler (1. Sütun genel nevüs, 2. Sütun atipik nevüs ve 3. sütun ise malign melanom)

B. Görüntülerin Ön İşlenmesi

Malign melanoma ilişkin görüntü sayısının diğer melanositik lezyonlara kıyasla az olması, sınıflar arası dengesizliğe yol açmaktadır. Bu sorunun üstesinden gelebilmek için veri artırımı yöntemi uygulanmıştır. Veri artırımı yöntemi ile azınlık üye

sayısına sahip sınıf için makul düzeyde yapay örüntüler üretilebilir. Böylelikle, ağın eğitiminde

çok sayıda ve dengeli veri kullanılarak daha etkin ve tutarlı modeller geliştirilebilir[4], [12].



Şekil 2. Malign melanom lezyonuna ilişkin örnek sentetik görüntüler, (a): orijinal görüntü, (b): veri artırımı tekniği ile elde edilen sentetik görüntüler

Bu çalışmada, orijinal görüntülere Gauss gürültüsü, yansıtma ve -45 ila +45 derece aralığında değişen rastgele döndürme işlemleri uygulanarak, veri artırımı gerçekleştirilmiştir. İşlem akabinde, malign melanom sınıfı için 160 ve diğer melanositik lezyonlara ilişkin 160 görüntü sayısı ile dengeli bir dağılım elde edilmiştir. Veri artırımı sonucu üretilen sentetik görüntülere ilişkin bazı örnekler Şekil 2’de verilmiştir.

C. Transfer Öğrenimi ile Hiyerarşik Özellik Çıkarımı

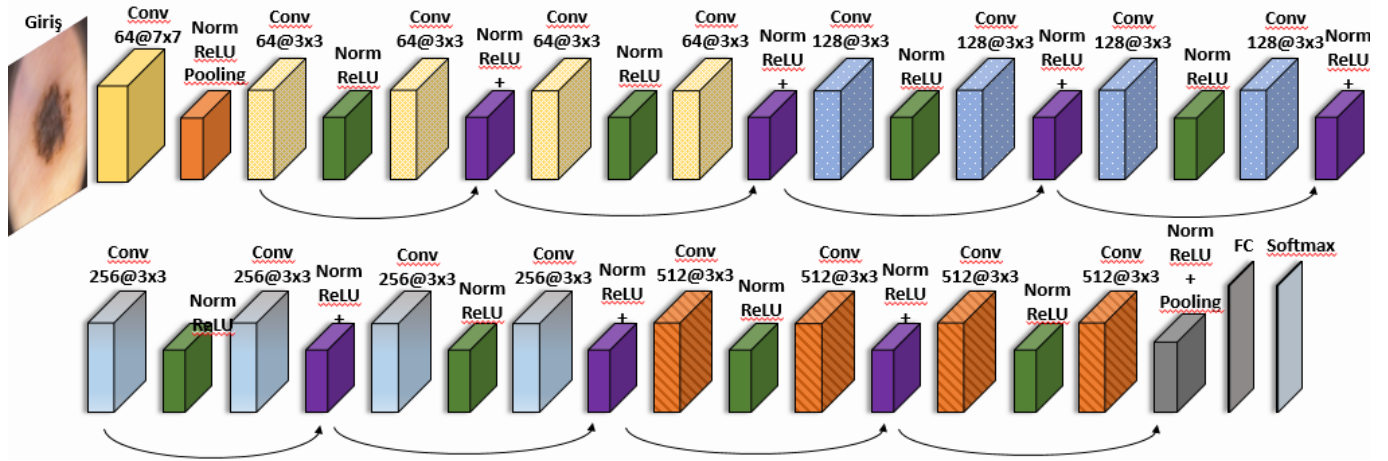
Bu çalışmada transfer öğrenimi ile önceden eğitilmiş ESA mimarilerinin ham görüntülerden ayırt edici özellik çıkarabilme kabiliyetlerinden yararlanılmıştır. Transfer öğrenimi ile daha önceden milyonlarca görüntü üzerinde eğitilmiş ESA mimarilerinin ağırlıkları probleme özgü olarak eğitilmiştir. [2], [13]. Böylelikle, önceden eğitilmiş özelliklerin yeni verilere artımlı olarak uyarlanmıştır.

ESA mimarileri, ham görüntülerden hiyerarşik olarak farklı seviyelerdeki özellikleri öğrenmek için çeşitli işlem katmanlarını içerir [14]. Her bir katmandan çıkarılan yerel derin evrimsel özellikler, girdi görüntüsünde küçük bir bölgeye (alıcı alan) atıfta bulunur ve o bölgenin yerel ayrımını yansıtır. Görüntülere ilişkin alçak seviyeden yüksek seviyeye doğru özellikler uçtan uca bağlantı ile öğrenilmiş olur. Son katmanlarda üretilen yüksek seviyeli özellikler, görüntü temsil etmede genelleyici olmalarına karşın yerel model açıklamalarından muzdariptir [14]. Özellikle

melanositik lezyonlarda önem arz eden uzamsal varyasyonlar yüksek seviyeli özellikler ile verimli şekilde temsil edilmeyebilir. Dolayısıyla, ön eğitilmiş ESA mimarisi için her bir katman tarafından üretilen özelliklerin ayrı ayrı değerlendirilmeye alınması ile malign melanom tanısında en etkin seviye özelliklerin belirlenmesi mümkün kılınabilir. Böylelikle, dermoskopi görüntülerinden bilgisayar destekli melanom tanısında sağlam bir modelin üretilmesi mümkün olabilir. Bu çalışmada, ön eğitilmiş modellerden derin artık sinir ağı modeli (ResNet) hiyerarşik derin özelliklerin değerlendirilmesinde kullanılması için uygun görülmüştür.

D. Derin Artık Ağ Mimarisi

Dermoskopi görüntülerinden melanositik lezyonlara ilişkin hiyerarşik derin özelliklerin çıkarılmasında, ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) [15] için geliştirilen ResNet mimarisi kullanılmıştır. Tipik CNN mimarileri ile karşılaştırıldığında, ResNet modeli artık ağ tekniği ile eğitim aşamasında kaybolan gradyan sorunun üstesinden gelerek daha derin bir ağ topolojiye sahip olmasıdır [16]. Farklı varyantları bulursa da genel olarak derin bir artık ağ mimarisi bir dizi artık bloktan oluşur ve her blok, birkaç yığılmış evrim katmandan oluşmaktadır [14]. Bu çalışmada ön eğitilmiş ResNet mimarilerinden katman sayısı açısından en küçük varyant olan ResNet-18 derin ağı kullanılmıştır. Şekil 3’te ResNet-18 mimarisi gösterilmektedir.



Şekil 3. ResNet-18 mimarisinin grafiksel temsili

E. Destek Vektör Kümeleri

DVM özellikle ikili (binary) sınıflandırma problemleri için geliştirilen bir makine öğrenme algoritmasıdır [17]. Sağlam matematiksel teorisiyle günümüzde başarılı bir şekilde uygulanan popüler bir sınıflandırıcıdır (Parikh et al. 2016). Medikal uygulamalarda güçlü öğrenme yeteneği ile sıklıkla kullanılmaktadır. DVM çekirdek (kernel) işlevini kullanarak yüksek düzeyde doğrusal olmayan klinik verileri ayrıştırabilmektedir [18].

Bu çalışmada, DVM kullanılarak iyi huylu ve kötü huylu melanositik sınıflar arasındaki marjı en üst düzeye çıkararak bir hiper düzlemle lezyonların doğru bir şekilde sınıflandırılması amaçlanmıştır. Ön eğitilmiş ESA mimarisi tarafından çıkarılan hiyerarşik özellik haritalarının giriş uzayında x_i , $i = 1 \leq i \leq N_x$ giriş vektörleri olarak ele alınır. Girişlere ilişkin çıkış etiketleri $y_i \in \{-1, 1\}$ olarak ifade edilir. Hiper düzlemin normal vektörü (w) ve bias (b) olmak üzere eğitim kümesinin $y_i(wx_i + b) \geq 1$ koşulunu yerine getirmesi beklenir [19]. Böylelikle, özellik haritalarına ilişkin veri dizilerinin ayrıştırılması nihayetlendirilebilir. Ayrıca, DVM ile sınıflandırma işlemleri kaynak [20]'da matematiksel olarak detaylandırılmıştır.

III. BULGULAR

Bu çalışmada melanositik görüntülerin ön işlenmesi, derin hiyerarşik özelliklerin çıkarılması ve çıkarılan özelliklerin sınıflandırılmasına ilişkin uygulanan işlemler, Matlab yazılım ortamında gerçekleştirilmiştir. Ön eğitilmiş mimari tarafından çıkarılan özelliklerin sınıflandırılmasında beş katlı

çapraz doğrulama (k-fold cross validation) tekniği uygulanmıştır. Her bir sınıflandırma katında görüntülere ilişkin özellik haritalarının %80'i sınıflandırıcının eğitimi ve %20'si ise önerilen modelin test edilmesinde kullanılmıştır. Düşük seviyeden yüksek seviyeye doğru hiyerarşik olarak çıkarılan özelliklere ilişkin elde edilen sınıflandırma başarımları doğruluk, duyarlılık, özgüllük, kesinlik ve F-skör metrikleri türünden Tablo 1'de gösterilmektedir.

Tablo 1'de en yüksek performansın 5. evrişim bloğu tarafından üretilen özellik haritalarının kullanılması ile elde edildiği rapor edilmiştir. Melanositik lezyonlara ilişkin çıkarılan 7x7 boyutunda yüksek seviyeli özelliklerin, anomalilere ilişkin ayırt edici dinamikleri en iyi şekilde yansıttığı gözlemlenmiştir. Ön eğitilmiş mimarinin 5. Evrişim bloğu (res5a) için sınıflandırma performansı doğruluk, özgüllük, duyarlılık, kesinlik ve F-skör metrikleri türünden sırasıyla %98.12, %97.50, %98.75, %97.55 ve %98.13 olarak elde edilmiştir. Yüksek seviyeli özellik haritaları için sınıflandırma doğrulukları %98.12 ila %95.31 aralığında dağılım sergilemesi, performansın diğer evrişim bloklarına kıyasla daha yüksek ortalama ve düşük varyansa sahip olduğu gözlemlenmiştir. Malign melanom lezyonlarının iyi huylu melanositik lezyonlardan ayrıştırılmasında düşük seviyeli özellik haritalarının daha verimsiz olduğu elde edilen bulgularla rapor edilmiştir. Ön eğitilmiş mimari tarafından 3. Evrişim bloğu tarafından üretilen özellik haritalarının lezyonlara ilişkin ayırt edici dinamikleri diğer bloklara kıyasla genel olarak daha zayıf bir şekilde

temsil ettiği gözlemlenmiştir. 3. Evrişim bloğu yer alan (res3a_branch2a) operatörü tarafından üretilen 28x28 boyutunda özellik haritaları için elde sınıflandırma başarımı doğruluk türünden %89.37 olarak elde edilmiştir. Sınıflandırma performansının hiyerarşik derin özelliklere göre daha iyi gözlemlenmesi için katmanlara ilişkin sınıflandırma performans dağılımı Şekil 4’te gösterilmiştir.

IV. TARTIŞMA

ESA mimarileri giriş görüntülerini evrişim işlemleri ile aşamalı olarak aşağı örnekleyerek özellik haritalarını üretirler. Bu çalışmada, lezyonlara ilişkin özelliklerin otomatik olarak çıkarılmasında ön eğitilmiş mimari 224x224 görüntü çözünürlüğünden sırasıyla 112x112, 56x56, 28x28, 14x14 ve 7x7 boyutlarında hiyerarşik derin özellikleri sunmuştur. Uçtan uca mimari tarafından damıtılarak elde edilen küçük özellik haritaları tarafından en yüksek doğrulukta tespiti sağlanması, lezyonlar için genelleyici bilgilerin daha ayırt edici olduğunu belirtmektedir. Düşük seviye özellik haritaları tarafından sunulan zengin uzamsal bilgilerin tanısallık performansı sekteye uğrattığı elde edilen bulgulardan çıkarılmaktadır.

Malign melanom ve iyi huylu melanositik lezyonların kendi sınıflarında yüksek varyasyon ve sınıflar arası düşük varyasyon nedeniyle manuel özellik çıkarımı ile arzu edilen sınıflandırma modellerinin tasarımı sekteye uğramaktadır [14]. Bu çalışmada, ESA algoritması ile otomatik olarak özellik çıkarılması, derin mimarilerin kabiliyetlerini ortaya koymaktadır.

Klinik alanda cilt kanseri tanılarındaki başarı büyük bir hekimlerin kabiliyetlerine bağlıdır. Ancak, hekimler tarafından yapılan değerlendirmelerde doğru tanımlara ilişkin hassasiyet performansı nadiren %80 üzere çıkmaktadır [21]. Bu çalışmada elde edilen %98.75 oranında bir hassasiyet performansı ile bilgisayar destekli tespit sistemlerinin önemi bir kez daha vurgulanmıştır. Ayrıca, ön eğitilmiş mimari tarafından otomatik olarak çıkarılan lezyonlara ilişkin detayların, çıplak gözle değerlendirilen özelliklere göre daha ayırt edici oldukları çıkarılmaktadır.

Tablo 1. Hiyerarşik derin özellik haritalarına göre elde edilen sınıflandırma performansları

Katman	Doğ.	Özg.	Duy.	Kes.	F-skor
'conv1'	93.43	94.37	92.50	94.12	93.24
'bn_conv1'	92.50	93.75	91.25	93.45	92.21
'conv1_relu'	94.37	95	93.75	94.93	94.29
'pool1'	94.06	93.75	94.37	93.89	94.10
'res2a_branch2a'	94.06	93.75	94.37	93.66	93.99
'bn2a_branch2a'	94.06	93.75	94.37	93.66	93.99
'res2a_branch2a_relu'	94.37	94.37	94.37	94.27	94.26
'res2a_branch2b'	93.43	94.37	92.50	94.13	93.24
'bn2a_branch2b'	92.50	93.75	91.25	93.46	92.28
'res2a'	94.37	95	93.75	94.95	94.30
'res2a_relu'	94.37	94.37	94.37	94.37	94.34
'res2b_branch2a'	92.81	92.50	93.12	92.55	92.70
'bn2b_branch2a'	92.81	93.12	92.50	93.19	92.68
'res2b_branch2a_relu'	93.75	93.75	93.75	93.76	93.69
'res2b_branch2b'	94.68	95.62	93.75	95.47	94.53
'bn2b_branch2b'	93.43	94.37	92.50	94.31	93.19
'res2b'	92.50	93.75	91.25	93.58	92.18
'res2b_relu'	93.43	93.12	93.75	93.14	93.32
'res3a_branch2a'	89.37	91.87	86.87	91.55	88.83
'bn3a_branch2a'	89.37	92.50	86.25	92.14	88.61
'res3a_branch2a_relu'	92.18	93.75	90.62	93.40	91.88
'res3a_branch2b'	95.62	96.87	94.37	96.80	95.50
'bn3a_branch2b'	95.62	96.25	95	96.19	95.54
'res3a'	95.31	96.25	94.37	96.10	95.15
'res3a_relu'	95.62	96.25	95	96.14	95.47
'res3a_branch1'	94.06	94.37	93.75	94.25	93.94
'bn3a_branch1'	94.37	95	93.75	94.82	94.21
'res3b_branch2a'	93.75	94.37	93.12	94.16	93.56
'bn3b_branch2a'	94.68	95	94.37	94.86	94.55
'res3b_branch2a_relu'	91.56	90.62	92.50	90.92	91.42
'res3b_branch2b'	91.87	90	93.75	90.33	91.81
'bn3b_branch2b'	92.18	90.62	93.75	91.01	92.09
'res3b'	93.75	93.12	94.37	93.17	93.62
'res3b_relu'	94.37	93.75	95	93.84	94.28
'res4a_branch2a'	95.93	95.62	96.25	95.63	95.90
'bn4a_branch2a'	96.25	95.62	96.87	95.67	96.24
'res4a_branch2a_relu'	94.68	93.75	95.62	93.84	94.66
'res4a_branch2b'	96.87	96.25	97.50	96.41	96.91
'bn4a_branch2b'	96.56	96.87	96.25	96.86	96.51
'res4a'	96.87	96.87	96.87	96.90	96.86
'res4a_relu'	96.56	96.25	96.87	96.28	96.55
'res4a_branch1'	95	93.75	96.25	93.92	95.02
'bn4a_branch1'	94.37	93.12	95.62	93.36	94.40
'res4b_branch2a'	95.93	94.37	97.50	94.72	96.02
'bn4b_branch2a'	95.31	94.37	96.25	94.64	95.33
'res4b_branch2a_relu'	95	93.75	96.25	93.96	95.04
'res4b_branch2b'	95	93.75	96.25	94.07	95.03
'bn4b_branch2b'	95	95	95	95.08	94.97
'res4b'	96.87	96.25	97.50	96.32	96.89
'res4b_relu'	96.56	95.62	97.50	95.73	96.58
'res5a_branch2a'	97.81	96.25	99.37	96.41	97.85
'bn5a_branch2a'	97.81	96.25	99.37	96.41	97.85
'res5a_branch2a_relu'	96.56	95.62	97.50	95.80	96.60
'res5a_branch2b'	96.56	95	98.12	95.27	96.63
'bn5a_branch2b'	96.25	94.37	98.12	94.76	96.35
'res5a'	98.12	97.50	98.75	97.55	98.13
'res5a_relu'	97.18	95.62	98.75	95.79	97.23
'res5a_branch1'	96.56	96.87	96.25	96.86	96.50
'bn5a_branch1'	96.25	96.25	96.25	96.22	96.20
'res5b_branch2a'	96.56	95	98.12	95.24	96.63
'bn5b_branch2a'	96.87	95	98.75	95.29	96.95
'res5b_branch2a_relu'	95.93	95	96.87	95.12	95.97
'res5b_branch2b'	95.31	93.75	96.87	93.93	95.35
'bn5b_branch2b'	95.31	93.75	96.87	93.93	95.35
'res5b'	95.31	93.75	96.87	93.93	95.35
'res5b_relu'	95.31	93.12	97.50	93.54	95.39
'pool5'	93.12	89.37	96.87	90.29	93.37
'fc'	91.25	89.37	93.12	90.16	91.44

Doğ:Doğruluk, Özg:Özgüllük, Duy: Duyarlılık, Kes: Kesinlik model başarımlerini ifade etmektedir.



Şekil 4. Hiyerarşik derin özellik haritaları kullanılarak doğruluk metriği türünden sınıflandırma performans dağılımı

V. SONUÇLAR

Bu çalışmada, melanositik lezyonlara ilişkin hiyerarşik özelliklerin kullanıldığı bir otomatik tanı modeli önerilmiştir. Hiyerarşik olarak çıkarılan derin özellikler, ayrı ayrı değerlendirilmeye alınarak iyi ve kötü huylu lezyon sınıflarına ilişkin en etkin bilgilerin belirlenmesi de amaçlanmıştır. Sonuçlar, lezyonlara ilişkin yüksek seviyeli bilgilerin sınıflandırıcı model tarafından en verimli şekilde ayrıştırıldığını göstermiştir. Yüksek seviyeli özellik haritaları ile %98.12 oranında tatmin edici bir performans elde edilmiştir.

İleriki çalışmalarda melanositik lezyonlara ilişkin daha büyük görüntü verileri kullanılarak, iyi huylu lezyonların kendi kategorilerinde alt sınıflara ayrıştırılmasında uygun özelliklerin belirlenmesi planlanmaktadır.

KAYNAKLAR

- [1] F. De Engenharia, "Chapter 1 P H 2 - A Public Database for the Analysis of Dermoscopic Images," pp. 1–22.
- [2] R. L. Araújo, F. H. D. d. Araújo, and R. R. V. e. Silva, "Automatic segmentation of melanoma skin cancer using transfer learning and fine-tuning," *Multimed. Syst.*, vol. 28, no. 4, pp. 1239–1250, 2022, doi: 10.1007/s00530-021-00840-3.
- [3] R. Naga Swetha, V. K. Shrivastava, and K. Parvathi, "Multiclass skin lesion classification using image augmentation technique and transfer learning models," *Int. J. Intell. Unmanned Syst.*, 2021, doi: 10.1108/IJUS-02-2021-0010.
- [4] K. M. Hosny, M. A. Kassem, and M. M. Fouad, "Classification of Skin Lesions into Seven Classes Using Transfer Learning with AlexNet," *J. Digit. Imaging*, vol. 33, no. 5, pp. 1325–1334, 2020, doi: 10.1007/s10278-020-00371-9.
- [5] R. Kaur, H. GholamHosseini, R. Sinha, and M. Lindén, "Automatic lesion segmentation using atrous convolutional deep neural networks in dermoscopic skin cancer images," *BMC Med. Imaging*, vol. 22, no. 1, pp. 1–13, 2022, doi: 10.1186/s12880-022-00829-y.
- [6] H. ur Rehman, N. Nida, S. A. Shah, W. Ahmad, M. I. Faizi, and S. M. Anwar, "Automatic melanoma detection and segmentation in dermoscopy images using deep RetinaNet and conditional random fields," *Multimed. Tools Appl.*, vol. 81, no. 18, pp. 25765–25785, 2022, doi: 10.1007/s11042-022-12460-8.
- [7] M. K. Hasan, M. A. Ahamad, C. H. Yap, and G. Yang, "A survey, review, and future trends of skin lesion segmentation and classification," *Comput. Biol. Med.*, vol. 155, no. February, p. 106624, 2023, doi: 10.1016/j.compbiomed.2023.106624.
- [8] P. Thapar, M. Rakhra, G. Cazzato, and M. S. Hossain, "A Novel Hybrid Deep Learning Approach for Skin Lesion Segmentation and Classification," *J. Healthc. Eng.*, vol. 2022, 2022, doi: 10.1155/2022/1709842.
- [9] B. Shetty, R. Fernandes, A. P. Rodrigues, R. Chengoden, S. Bhattacharya, and K. Lakshmana, "Skin lesion classification of dermoscopic images using machine learning and convolutional neural network," *Sci. Rep.*, vol. 12, no. 1, pp. 1–11, 2022, doi: 10.1038/s41598-022-22644-9.
- [10] M. Koklu and I. A. Ozkan, "Skin Lesion Classification using Machine Learning Algorithms," *Int. J. Intell. Syst. Appl. Eng.*, vol. 4, no. 5, pp. 285–289, 2017, doi: 10.18201/ijisae.2017534420.
- [11] "ADDI - Automatic computer-based Diagnosis system for Dermoscopy Images." https://www.fc.up.pt/addi/ph2_database.html (accessed Mar. 10, 2023).
- [12] D. Müller, I. Soto-Rey, and F. Kramer, "Robust chest CT image segmentation of COVID-19 lung infection based on limited data," *Informatics Med. Unlocked*, vol. 25, no. July, 2021, doi: 10.1016/j.imu.2021.100681.
- [13] N. D. Kathamuthu *et al.*, "A deep transfer learning-based convolution neural network model for COVID-19 detection using Computed tomography scan images for medical applications," *Adv. Eng. Softw.*, vol. 175, no. August 2022, p. 103317, 2022, doi: 10.1016/j.advengsoft.2022.103317.
- [14] Z. Yu *et al.*, "Melanoma Recognition in Dermoscopy Images via Aggregated Deep Convolutional Features," *IEEE Trans. Biomed. Eng.*, vol. 66, no. 4, pp. 1006–1016, 2019, doi: 10.1109/TBME.2018.2866166.
- [15] O. Russakovsky *et al.*, "ImageNet Large Scale Visual Recognition Challenge," *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211–252, 2015, doi: 10.1007/s11263-015-

- 0816-y.
- [16] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
 - [17] L. D. Avendaño-Valencia and S. D. Fassois, "Natural vibration response based damage detection for an operating wind turbine via Random Coefficient Linear Parameter Varying AR modelling," *J. Phys. Conf. Ser.*, vol. 628, no. 1, pp. 273–297, 2015, doi: 10.1088/1742-6596/628/1/012073.
 - [18] K. S. Parikh and T. P. Shah, "Support Vector Machine – A Large Margin Classifier to Diagnose Skin Illnesses," *Procedia Technol.*, vol. 23, pp. 369–375, 2016, doi: 10.1016/j.protcy.2016.03.039.
 - [19] S. Erpolat and E. Öz, "Kanser Verilerinin Sınıflandırılmasında Yapay Sinir Ağları ile Destek Vektör Makinelerinin Karşılaştırılması," *İstanbul Aydın Üniversitesi Fen Bilimleri Dergisi*, vol. 2, no. 5, pp. 71–83, 2010, [Online]. Available: http://iaud.aydin.edu.tr/makaleler/yil2sayi5/IAUD_Yi1_2_Sayi_5_Makale_4.pdf.
 - [20] E. A. Zany, "Support Vector Machines (SVMs) versus Multilayer Perception (MLP) in data classification," *Egypt. Informatics J.*, vol. 13, no. 3, pp. 177–183, 2012, doi: 10.1016/j.eij.2012.08.002.
 - [21] R. C. Maron *et al.*, "Systematic outperformance of 112 dermatologists in multiclass skin cancer image classification by convolutional neural networks," *Eur. J. Cancer*, vol. 119, pp. 57–65, 2019, doi: 10.1016/j.ejca.2019.06.013.