

Kortikal L5PC6 Piramidal Nöronların Alt Bölge Kombinasyonları Üzerinden Tümör Sınıflandırması Tumor Classification via Subregion Combinations of Cortical L5PC6 Pyramidal Neurons

Zübeyir Özcan¹, İlknur Kayıkçıoğlu Bozkır², and Temel Kayıkçıoğlu¹

¹Department of Electrical and Electronics Engineering, Karadeniz Technical University, Trabzon, Türkiye

²Department of Software Engineering, Gümüşhane University, Gümüşhane, Türkiye

Emails: zubeyirozcan@ktu.edu.tr, ilknurkayikcioglu@gumushane.edu.tr, tkayikci@ktu.edu.tr

Özetçe —Bu çalışmada, benign ve malignant tümör örneklerinin, bir kortikal L5PC6 piramidal nöronun farklı alt bölgeleri kullanılarak sınıflandırılması amaçlanmıştır. Gerçek veri seti üzerinde spike tabanlı bir öğrenme yöntemi uygulanmış, her sınıf için ayrı bir nöron eğitilerek aksiyon potansiyeli üretimine dayalı bir karar mekanizması oluşturulmuştur. Eğitim süreci boyunca farklı sinaptik bağlantı türleri ve spike kodlama yöntemleri değerlendirilmiş, piramidal nöron için en yüksek performans yoğunluk kodlamayla elde edilmiştir. Bölgesel analizler, özellikle bazal bölgenin sınıflandırma başarısında öne çıktığını göstermiştir. Elde edilen sonuçlar, piramidal nöronların morfolojik ve biyofiziksel çeşitliliğinin sınıflandırma görevlerinde anlamlı bir avantaj sağladığını ortaya koymaktadır.

Anahtar Kelimeler—piramidal nöron; L5PC6; alt bölge uyarımı; tümör sınıflandırması

Abstract—In this study, it was aimed to classify benign and malignant tumor samples by utilizing different subregions of a cortical L5PC6 pyramidal neuron. A spike-based learning method was applied to a real dataset, and a decision mechanism based on action potential generation was established by training a separate neuron for each class. During the training process, various types of synaptic connections and spike encoding schemes were evaluated and intensity coding yielded the highest performance for the pyramidal neuron. Regional analyses revealed that the basilar region particularly stood out in terms of classification success. The results demonstrate that the morphological and biophysical diversity of pyramidal neurons provides a significant advantage in classification tasks.

Keywords—pyramidal neuron; L5PC6; subregion stimulation; tumor classification

I. GİRİŞ

Kortikal piramidal nöronlar, beyinde sıkça rastlanan ve yapısal olarak çok bölmeli bir mimariye sahip hücrelerdir. Karmaşık morfolojik yapıları ve biyofiziksel çeşitlilikleri sayesinde, farklı kortikal katmanlara uzanabilen geniş dendritik ağlara sahiptirler. Bu özellikleri, hem uzak kortikal bölgelerden bilgi alabilmelerine hem de işledikleri bilgiyi uzak bölgelere iletebilmelerine olanak tanımaktadır. Apikal ve bazal dendritik bölgeleri aracılığıyla gelen uyarımları mekânsal olarak ayrıştırarak işleyebilen bu hücrelerin alt bölgeleri,

ulaştıkları kortikal katmanlar ve taşıdıkları biyofiziksel özellikler bakımından birbirinden ayrılmaktadır. Literatürde, bu alt bölgelerin gelen uyarımlara farklı tepkiler verdiği ve nöronal çıktılar üzerinde etkilerinin olduğu çeşitli çalışmalarla gösterilmiştir [1]. Ancak, söz konusu bölgelerin bilgi işleme ve sınıflandırma gibi görevlerdeki katkısı hâlâ detaylı araştırmalara ihtiyaç duymaktadır. Bu nedenle, piramidal nöronlar, karar verme süreçlerine entegre edilebilecek potansiyel hesaplamalı birimler olarak dikkat çekmektedir.

Yapılan çalışmalar, apikal ve bazal dendritlerin sinaptik uyarımları farklı biçimlerde işlediğini göstermektedir. Polsky ve arkadaşları, bazal dendritlerin sinaptik uyarımları doğrusal şekilde işlerken, apikal dendritlerin doğrusal olmayan işlemler gerçekleştirdiğini ortaya koymuştur [1]. Spruston ise bu bölgelerdeki iyon kanal dağılımı ve iletim özelliklerinin nöronal çıktılar üzerinde önemli etkiler yarattığını vurgulamıştır [2]. Ayrıca, Branco ve Häusser, farklı bölgelerden gelen uyarımların zamansal özelliklerine olan duyarlılıkların değiştiğini göstermiştir [3].

Moldwin ve Segev, yaptıkları çalışmada bir piramidal nöronun eğitilerek iki sınıflı bir sınıflandırma problemini başarıyla çözebileceğini göstermiştir [4]. Çalışmalarında kullandıkları piramidal nöron modelinin alt bölge performanslarını da ele almış olsalar da, sınıflandırma için kullanılan veri setinin yapay olması, yalnızca uyarıcı (eksitator) sinaptik bağlantıların dikkate alınması ve sinaptik ağırlıkların yalnızca pozitif değerler alabileceği yönündeki kısıtlar, yöntemin potansiyel performansını sınırlayabilecek unsurlar olarak dikkat çekmektedir. Bu eksikliklere Kayıkçıoğlu Bozkır ve arkadaşlarının çalışmasında değinilmiştir [5]. Bir EKG veri seti kullanılarak piramidal nöronların sınıflandırma performansı incelenmiş ve önerilen aynalama yaklaşımı sayesinde ağırlıkların pozitif olma kısıtının yol açtığı performans kayıplarının önüne geçildiği gösterilmiştir. Ancak bu çalışmada da baskılayıcı (inhibitör) sinaptik bağlantıların sınıflandırma üzerindeki etkisi araştırılmamıştır. Özcan ve arkadaşları ise benzer bir yaklaşımı baskılayıcı sinapsları dahil ederek uygulamışlardır [6]. Çeşitli veri setleri kullanarak basit nöron modellerinin performansını değerlendirmişlerdir. Ancak bu çalışmada piramidal nöron modeline yer verilmemesi, konuyla ilgili araştırmalarda önemli bir boşluk bırakmıştır.

Bu çalışmada, yukarıda belirtilen sınırlılıkların aşılması

ve piramidal nöronların alt bölge düzeyinde bilgi işleme potansiyelinin daha gerçekçi koşullar altında değerlendirilmesi amaçlanmaktadır. Buna göre, L5PC6 tipi bir kortikal piramidal nöron modeli kullanılarak iki sınıflı bir tümör sınıflandırma problemi ele alınmıştır. Çalışmada, tümör veri setinin öznelitik vektörleri, daha önce literatürde önerilmiş bir öznelitik-spike dönüşüm yöntemiyle spike örüntülerine dönüştürülmüştür. Bu örüntüler, nöronun farklı dendritik alt bölgelerine sinaptik giriş olarak uygulanmıştır. Apikal ve bazal dendrit bölgelerine ek olarak soma hem bireysel hem de kombinasyon halinde uyarılırken oluşan somatik aksiyon potansiyelleri üzerinden sınıflandırma performansları karşılaştırılmıştır. Ayrıca, bu performans sonuçları yaygın olarak kullanılan HH, IZH ve LIF gibi basitleştirilmiş nöron modelleriyle karşılaştırılarak, piramidal morfolojinin sınıflandırma üzerindeki etkisi ortaya konulmuştur.

II. MATERYAL VE YÖNTEM

A. Veri Seti

Bu çalışmada *Breast Cancer Wisconsin* veri seti kullanılmıştır [7]. Toplam 569 örnek içeren veri setinde, her örnek bir hastaya ait olup tümörün iyi huylu (benign) veya kötü huylu (malignant) olduğunu gösteren etiket bilgisiyle birlikte 30 sayısal öznelitik barındırmaktadır. Bu öznelitikler, hücre çekirdeğine ait morfolojik özelliklerin ortalama, en büyük ve standart sapma değerlerini içermektedir. Veri seti kullanılırken; rastgele karıştırıldıktan sonra yarısı eğitim, yarısı test olmak üzere iki alt kümeye ayrılmıştır. Bu sayede çalışma için eğitim ve test başarımları ayrı ayrı değerlendirilmiştir.


B. Nöron Modelleri

Kullanılan piramidal nöron modeli, Hay ve arkadaşları tarafından sunulan üç farklı kortikal piramidal nöron modelinden biridir [8]. Bu çalışma kapsamında yalnızca Şekil 1'de gösterilen ve L5PC6 tipi bir piramidal hücreye ait olan model esas alınmıştır. Modelin iyon kanal dağılımı ve diğer biyofiziksel parametreler, Shai ve arkadaşlarının çalışmasındaki düzenlemelere uygun biçimde güncellenmiştir [9].

Elde edilen sonuçları değerlendirmek ve karşılaştırmak amacıyla, Hodgkin-Huxley (HH), Izhikevich (IZH) ve Leaky Integrate-and-Fire (LIF) nöron modelleri ayrıca çalışmaya dahil edilmiştir. Bu modeller, sınıflandırma performansları yönünden referans olarak ele alınmış ve alt bölge bazlı değerlendirmelerle karşılaştırılmıştır.

C. Öznelitik-Spike Dönüşümü

Bu çalışmada, sayısal öznelitik vektörlerinin zamansal spike örüntülerine dönüştürülmesi için SPIGEN yöntemi kullanılmıştır [6]. Yöntem üç temel adımdan oluşmaktadır. İlk adımda, öznelitik değerleri yedi bitlik kuantalama işlemine tabi tutulmuştur. İkinci adımda, kuantal aralıklar ikili, yoğunluk veya Gray kodlama olmak üzere üç farklı yöntemle ikili koda dönüştürülmüştür. Elde edilen ikili kodlarda "1" değeri ilgili sinapta giriş olduğuna, "0" ise giriş olmayacağı anlamına gelmektedir. Tüm örnekler için sinaptik girişler, elde edilen bu kodlar üzerinden yapılmıştır.



Şekil 1: Piramidal nöron morfolojisi ve girdi entegrasyonu

D. Aynalama Yaklaşımı

Bu çalışmaya, Kayıkçıoğlu Bozkır ve arkadaşlarının önerdiği aynalama yaklaşımı ayrıca dahil edilmiştir [5]. Aynalama yaklaşımında, her spike giriş örüntüsü bit düzeyinde 1'ler 0'a, 0'lar 1'e olmak üzere terslenmiş ve genişletilmiş bir giriş vektörü elde edilmiştir. Bu şekilde, her giriş hem orijinal haliyle hem de aynalanmış biçimiyle nöron modeline sunulmuştur. Böylece, Moldwin ve Segev'in çalışmalarında değindikleri sinaptik ağırlıkların pozitif olma kısıtı aşılmıştır [4].

E. Öğrenme Yöntemi

Çalışmanın öğrenme yönteminde üç temel unsur bulunmaktadır.

- **Sinaptik girişler:** Öznelitiklerin spike örüntülerine dönüştürülmesiyle elde edilmiştir ve ikili değerler almaktadır. Burada "1", sinaptik girişin bir spike içerdiğini; "0" ise spike bulunmadığını ifade etmektedir.
- **Nöronal çıktı:** Nöronun verilen spike örüntüsüne karşılık olarak aksiyon potansiyeli üretip üretmediği

değerlendirilmiştir. Hiç aksiyon potansiyeli oluşmazsa çıktı “0”, en az bir aksiyon potansiyeli oluşursa çıktı “1” kabul edilmiştir.

- **Sinaptik bağlantı tipi:** Bu çalışmada iki uyarıcı sinaps (AMPA, NMDA) ve iki baskılayıcı sinaps ($GABA_A$, $GABA_B$) kullanılmıştır. Eğitim süreci boyunca sinaptik güncellemeler her sinaps tipi için ayrı ayrı yapılmıştır. Ayrıca, her öznetelik girişi dört farklı sinaptik tip üzerinden nörona bağlanmıştır.

$$\Delta w_i = \eta \times (d - \text{çıktı}) \times x_i \quad (1)$$

$$w_i^{\text{Yeni}} \leftarrow \begin{cases} \max(0, w_i^{\text{Eski}} + \Delta w_i), & \text{Eksitator} \\ \max(0, w_i^{\text{Eski}} - \Delta w_i), & \text{İnhibitör} \end{cases} \quad (2)$$

Bu çalışmada uyarlanmış bir perceptron öğrenme kuralı kullanılmıştır. Bu kurala göre ağırlık güncellemeleri tüm sinaps tipleri için ayrı ayrı ve negatif değer almayacak şekilde düzenlenmiştir. İlgili ifadeler Denklem (1) ve Denklem (2)’de gösterilmektedir.

Öncelikle nöronal çıktı ile hedef çıktı arasındaki fark hesaplanmış, elde edilen hata değeri belirli bir öğrenme oranıyla her bir sinaptik girişin değeriyle çarpılarak ağırlık güncelleme miktarı belirlenmiştir. Bu değişim, sinapsın tipi dikkate alınarak uygulanmıştır.

F. Eğitim ve Test

Çalışmada ele alınan sınıflandırma problemi iki sınıflıdır. Bu doğrultuda, her bir sınıf için ayrı bir piramidal nöron modeli kullanılmıştır. Eğitim sürecinde, benign sınıfı temsil eden nöron yalnızca benign örnekler için aksiyon potansiyeli üretmeye, malignant örnekler karşısında ise sessiz kalmaya yönelik olarak eğitilmiştir. Benzer süreç malignant sınıfı için de uygulanmıştır. Böylece her nöron yalnızca kendi sınıfına ait örnekleri seçici olarak temsil edecek şekilde özelleştirilmiştir.

Eğitim süreci, önceden belirlenen spike örüntüleri ve sinaptik bağlantı tipleri üzerinden yürütülmüştür. Toplam 20 epok boyunca tüm eğitim verileri her iki nöron için ayrı ayrı işlenmiştir. Her epok sonunda nöronal çıktılar ile hedef çıktılar arasındaki farklar üzerinden ortalama kare hata (MSE) değeri hesaplanmış ve öğrenme eğilimi takip edilmiştir.

Test aşamasında hem piramidal nöron modeli hem de karşılaştırmalı olarak kullanılan üç farklı basit nöron modeli için sınıflandırma performansı değerlendirilmiştir. Basit nöron modellerinde, farklı spike kodlama yöntemlerinin sınıflandırma başarısına etkisi ayrıca analiz edilmiştir. Elde edilen sonuçlara göre en iyi performansı sağlayan yoğunluk kodlama yöntemi, tüm piramidal nöron deneylerinde standart olarak kullanılmıştır.

Basit nöron modellerinde, iki sınıfı temsil eden iki ayrı nöronun çıktıları değerlendirilerek sınıf etiketine karar verilmiştir. Eğer yalnızca bir nöron aksiyon potansiyeli üretmişse, örnek o sınıfa atanmıştır. Her iki nöron da çıktı üretirse, en erken aksiyon potansiyelini üreten nöronun sınıfı esas alınmıştır. Hiçbiri ateşleme gerçekleştirmemişse, zar potansiyeli en yüksek seviyeye ulaşan nöronun sınıfı tercih edilmiştir.


Piramidal nöron için sınıflandırma başarımı iki düzeyde değerlendirilmiştir. İlk olarak, benign ve malignant sınıflarını temsil eden iki piramidal nöronun her birinin kendi sınıfına ait örnekleri ne ölçüde doğru sınıflandırdığı analiz edilmiştir. Ardından, yukarıda açıklanan bütüncül karar mekanizması piramidal nöronlar için de uygulanarak genel sınıflandırma başarımı elde edilmiştir.

Son olarak, modelin genellenebilirliğini değerlendirmek amacıyla eğitim ve test verileri bağımsız şekilde ele alınmış, tüm deneylerde performans F1-skör ölçütü ile değerlendirilmiştir.

III. BULGULAR VE TARTIŞMA

A. Eğitim Hataları


Şekil 2 ve Şekil 3’te eğitim aşamalarında elde edilen hataların epoklara göre seyirleri gösterilmektedir. Tüm modellerde, epok sayısı arttıkça MSE değerlerinde belirgin bir azalma gözlenmiştir. Basit nöronlarda, özellikle yoğunluk kodlama, erken epoklardan itibaren daha hızlı ve kararlı bir öğrenme eğrisi sunarak diğer kodlama yöntemlerine göre daha düşük hata seviyelerine ulaşmıştır. Piramidal nöron için, eğitim süreci boyunca bazal bölge üzerinden yapılan eğitim en düşük hata ile sonuçlanırken, apikal bölgenin tek başına kullanımı diğerlerine kıyasla daha yüksek hata değerleri üretmiştir. Genel olarak sonuçlar incelendiğinde ise piramidal nöronlar için alt bölgelerin eğitiminde küçük farklılıklar mevcuttur.



Şekil 2: Basit nöron modelleri için eğitim hatalarının seyri

B. Basit Nöron Modellerinin Sınıflandırma Performansları

Tablo 1’de, HH, IZH ve LIF nöron modelleri için farklı spike kodlama yöntemleri kullanılarak elde edilen eğitim ve test başarı oranları karşılaştırılmaktadır. Eğitim aşamasında en yüksek doğruluk, HH modeli ile ikili kodlama yöntemi kullanıldığında %99,56 olarak elde edilmiştir. Tüm modellerde ikili ve Gray kodlamalar benzer başarılar sağlarken, yoğunluk kodlama yöntemi eğitim aşamasında diğer yöntemlere kıyasla biraz daha düşük performans göstermiştir.



Şekil 3: Piramidal nöron için eğitim hatalarının seyri

Aşama	Kodlama	HH	IZH	LIF
Eğitim	İkili	99,56%	98,68%	98,68%
	Yoğunluk	97,36%	97,35%	96,49%
	Gray	98,68%	98,24%	98,68%
Test	İkili	92,64%	92,65%	92,65%
	Yoğunluk	97,09%	96,49%	97,38%
	Gray	95,29%	95,60%	95,31%

Tablo I: Basit nöron modelleri için performans bulguları

Ancak test aşamasında bu durum tersine dönmüştür. Yoğunluk kodlama, üç modelde de en yüksek test başarılarını sağlamıştır: HH için %97,09, IZH için %96,49 ve LIF için %97,38. Bu sonuçlar, yoğunluk tabanlı spike kodlamanın genellenabilirlik açısından daha güçlü bir temsil sunduğunu göstermektedir. Özellikle HH ve LIF modellerinde test başarısının yüksek oluşu, bu modellerin karmaşık örüntülere karşı daha iyi öğrenme gerçekleştirdiğini ortaya koymaktadır.

C. Piramidal Nöronun Sınıflandırma Performansı

Tablo II'de, piramidal nöron modeli kullanılarak elde edilen eğitim ve test başarıları hem sınıf bazlı hem de bütüncül olarak verilmiştir. Eğitim verileri üzerinden değerlendirildiğinde, bazal bölge ile yapılan sınıflandırmalar, malignan ve benign örneklerde dengeli bir başarı sergilemiştir. Benzer şekilde, yalnızca soma bölgesi kullanıldığında da birleşik başarı oranı %97,80'e ulaşmıştır. Apikal ve diğer bölge kombinasyonları ise biraz daha düşük başarımlar göstermiştir.

Test aşamasında ise apikal ve apikal + bazal bölgeler, birleşik başarımda %97,38 ile en yüksek sınıflandırma performansını göstermiştir. Özellikle benign sınıflar için tüm bölgelerde yüksek doğruluklar elde edilmiş, ancak malignan sınıf için başarı oranları göreceli olarak daha düşük kalmıştır. Bu durum, benign örneklerin daha kolay sınıflandırılabilirliğini, malignan sınıfın ise daha karmaşık nöronal yanıtlar gerektirdiğini düşündürmektedir.

Aşama	Bölge	Malignant	Benign	Birleşik
Eğitim	Soma	95,18%	96,93%	97,80%
	Apikal	95,18%	94,29%	96,93%
	Bazal	95,62%	95,58%	97,80%
	Apikal ve Bazal	94,34%	95,15%	96,93%
	Tümü	94,32%	95,16%	96,93%
Test	Soma	93,58%	97,07%	96,79%
	Apikal	92,14%	96,20%	97,38%
	Bazal	93,02%	96,77%	97,09%
	Apikal ve Bazal	91,89%	96,47%	97,38%
	Tümü	92,18%	96,47%	97,09%

Tablo II: Piramidal nöron için performans bulguları

Genel olarak, piramidal nöronun farklı alt bölgeleri üzerinden yapılan değerlendirmeler hem tekil hem de bütüncül bilgi işlemeyi destekleyecek şekilde yüksek sınıflandırma başarıları sunmuş ve bölgesel seçiciliğin sınıf ayrımı üzerindeki etkisini ortaya koymuştur.

IV. SONUÇ VE ÖNERİLER

Bu çalışmada, piramidal nöronun alt bölgeleri kullanılarak iki sınıflı bir tümör verisi üzerinde spike tabanlı bir sınıflandırma sistemi geliştirilmiştir. Bulgular, özellikle bazal bölgenin sınıflandırma başarısında öne çıktığını ve yoğunluk kodlamanın genellenabilirlik açısından avantaj sağladığını göstermiştir. Basit nöron modelleriyle karşılaştırıldığında, piramidal nöronun morfolojik çeşitliliği karar doğruluğunu artırıcı bir etki yaratmıştır. Gelecek çalışmalarda, inhibisyonun daha ayrıntılı ele alınması ve çok sınıflı yapılarla modelin genişletilmesi önerilmektedir.

KAYNAKÇA

- [1] A. Polsky, B. W. Mel, and J. Schiller, "Computational subunits in thin dendrites of pyramidal cells," *Nature Neuroscience*, vol. 7, no. 6, pp. 621–627, 2004.
- [2] N. Spruston, "Pyramidal neurons: dendritic structure and synaptic integration," *Nature Reviews Neuroscience*, vol. 9, no. 3, pp. 206–221, 2008.
- [3] T. Branco and M. Häusser, "The single dendritic branch as a fundamental functional unit in the nervous system," *Current Opinion in Neurobiology*, vol. 20, no. 4, pp. 494–502, 2010.
- [4] T. Moldwin and I. Segev, "Perceptron learning and classification in a modeled cortical pyramidal cell," *Frontiers in Computational Neuroscience*, vol. 14, p. 33, 2020.
- [5] I. Kayıkcıoğlu Bozkır, Z. Özcan, C. Kose, T. Kayıkcıoğlu, and A. E. Cetin, "Improving a cortical pyramidal neuron model's classification performance on a real-world ECG dataset by extending inputs," *Journal of Computational Neuroscience*, vol. 51, no. 3, pp. 329–341, 2023.
- [6] Z. Özcan, İ. K. Bozkır, and T. Kayıkcıoğlu, "SPIGEN: A Configurable Population-Coded Spike Pattern Generator for Single-Spike Learning in Spiking Neural Networks," unpublished, 2025.
- [7] W. Wolberg, O. Mangasarian, N. Street, and W. Street, "Breast Cancer Wisconsin (Diagnostic) [Dataset]," *UCI Machine Learning Repository*, 1993.
- [8] E. Hay, S. Hill, F. Schürmann, H. Markram, and I. Segev, "Models of neocortical layer 5b pyramidal cells capturing a wide range of dendritic and perisomatic active properties," *PLoS Computational Biology*, vol. 7, no. 7, p. e1002107, 2011.
- [9] A. S. Shai, C. A. Anastassiou, M. E. Larkum, and C. Koch, "Physiology of layer 5 pyramidal neurons in mouse primary visual cortex: coincidence detection through bursting," *PLoS Computational Biology*, vol. 11, no. 3, p. e1004090, 2015.