

İğnecikli Sinir Ağları ile Görüntü İşleme: Temel Kavramlar, Uygulamalar ve Gelecek Perspektifleri

Rukiye Uzun Arslan¹

Özet

İğnecikli Sinir Ağları (Spiking Neural Network, SNN), biyolojik sinir sistemlerinin olay odaklı ve seyrek hesaplama prensiplerini taklit eden yapay sinir ağlarının üçüncü nesli olarak öne çıkmaktadır. Geleneksel derin öğrenme modellerinin yüksek enerji tüketimi ve hesaplama gereksinimleri, özellikle gerçek zamanlı ve kaynak kısıtlı uygulamalarda SNN'leri cazip bir alternatif haline getirmektedir. Bu çalışma, SNN'lerin görüntü işleme alanındaki uygulamalarını, temel kavramlar ve güncel literatür ışığında kapsamlı olarak incelemektedir. Çalışmada öncelikle nöron modelleri ve bilgi kodlama stratejileri açıklanmakta; ardından kenar belirleme, görüntü iyileştirme, nesne tespiti ve sınıflandırma gibi çeşitli görüntü işleme görevlerindeki SNN tabanlı yaklaşımlar detaylandırılmaktadır. Ayrıca, SNN'lerin eğitim yöntemleri, kullanılan veri setleri ve nöromorfik donanım platformları ele alınmaktadır. Son olarak, türevlenebilirlik sorunu, karşılaştırma ölçütlerinin eksikliği ve algoritma-donanım birlikte tasarımı ihtiyacı gibi mevcut zorluklar tartışılmakta; sürekli öğrenme ve nöromorfik sensörlerle bütünlük sistemlerin geliştirilmesi gelecek araştırma yönelimleri olarak sunulmaktadır.

1. Giriş

Görüntü işleme, tıbbi teşhisten otonom sistemlere, güvenlik uygulamalarından endüstriyel otomasyona kadar geniş bir yelpazede kritik öneme sahip bir teknoloji olarak konumlanmaktadır. Bu alandaki problemlerin çözümünde uzun yıllardır derin öğrenme tabanlı yöntemler baskın bir rol oynamaktadır. Evrişimli Sinir Ağları (Conventional Neural Network, CNN) ve Derin Sinir Ağları (Deep Neural Network, DNN) gibi mimariler, görüntü

1 Doç. Dr., Zonguldak Bülent Ecevit Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü, rukiye.uzun@beun.edu.tr, 0000-0002-2082-8695

sınıflandırma, nesne tespiti ve görüntü bölütleme gibi görevlerde insan düzeyine yakın performans sergileyebilmektedir (Krizhevsky ve ark., 2012). Bununla birlikte, bu yöntemlerin yüksek hesaplama kaynağı gereksinimi ve yoğun güç tüketimi, özellikle gerçek zamanlı ve kaynak kısıtlı sistemler (uç bilişim) için önemli bir dezavantaj teşkil etmektedir (Merolla ve ark., 2014). Geleneksel yapay sinir ağları, yoğun, çerçeve tabanlı ve senkron çalışan modeller olup yüksek hassasiyetli aritmetik işlemlere dayanmaktadır. Bu özellikler, onları zamansal olarak seyrek veya asenkron verilerin işlenmesi için ideal olmaktan uzaklaştırmaktadır.

İnsan beyni, bu soruna doğadan ilham alan etkili bir çözüm sunmaktadır. Biyolojik nöronlar, sürekli değerler yerine seyrek ve asenkron bir şekilde üretilen aksiyon potansiyelleri (iğnecikler) aracılığıyla iletişim kurar. Bu biyolojik mekanizma, beynin saniyede yüksek miktarda işlemi miliwatt seviyesinde güç tüketerek gerçekleştirmesine olanak tanımaktadır. İğnecikli Sinir Ağları (Spiking Neural Network, SNN), bu biyolojik gerçekçiliği matematiksel modellere taşıyan ve bilgiyi zaman içindeki iğnecik desenleriyle temsil eden yapay sinir ağlarının (YSA) üçüncü nesli olarak 1990'lı yılların sonunda kavramsallaştırılmıştır (Maass, 1997). SNN'ler, olay odaklı ve asenkron hesaplama özellikleri sayesinde, yalnızca ilgili girdi varlığında işlem yaparak önemli ölçüde düşük güç tüketimi sağlarlar (Davies ve ark., 2018). Bu doğal zamansal dinamikleri, onları Dinamik Görüntü Sensörleri veya Tek-Foton Çığ Diyot dizileri gibi nöromorfik görüntüleme sistemleriyle son derece uyumlu hale getirmektedir (Lichtsteiner ve ark., 2008).

Bu derleme makalesi, SNN'lerin görüntü işleme alanındaki geniş uygulama yelpazesini, güncel literatür ışığında kapsamlı bir şekilde analiz etmeyi hedeflemektedir. Makalenin ikinci bölümünde SNN'lerin tarihsel gelişimi, temel nöron modelleri ve bilgi kodlama stratejileri açıklanacaktır. Üçüncü bölüm, SNN'ların kenar belirleme, görüntü etiketleme, görüntü onarımı ve iyileştirmesi, içerik tabanlı görüntü erişimi, nesne tespiti ve görüntü sınıflandırması gibi çeşitli görevlerdeki kullanımlarını detaylandıracaktır. Dördüncü bölümde SNN'lerin eğitiminde kullanılan başlıca yöntemler (ANN-ISA dönüşümü, vekil gradyan vb.) ve kullanılan veri setleri sınıflandırılacak, beşinci bölümde donanımsal gerçekleştirme platformları ve nöromorfik işlemciler ele alınacaktır. Altıncı bölümde karşılaşılan temel zorluklar ve açık araştırma problemleri tartışılacak, son bölümde ise genel bir değerlendirme ve gelecek perspektifi sunulacaktır.

2. SNN Temel Kavramları ve Mimarisi

2.1. Tarihsel Gelişim ve Nöron Modelleri

YSA'ların evrimi çoğunlukla üç kuşak üzerinden sınıflandırılmaktadır. İlk kuşakta McCulloch–Pitts nöron modeli, ikinci kuşakta ise sürekli değerli aktivasyonlara dayanan klasik YSA yer almaktadır. Üçüncü kuşak olarak tanımlanan SNN, bilgi iletimini iğnecik (spike) adı verilen ayrık ve zamana bağlı olaylar üzerinden gerçekleştirerek bu çerçeveden ayrılmaktadır (Maass, 1997). Bu yaklaşım, biyolojik nöronların seyrek ve olay temelli iletişimini modellemeyi hedeflemekte; zamansal kodlama mekanizmalarının hesaplamadaki rolünü ön plana çıkarmaktadır. Görsel işleme bağlamında Thorpe ve Imbert (1989)'in çalışmaları, özellikle hızlı işleme senaryolarında zamansal bilginin önemini vurgulayarak İSA literatürünün teorik arka planına katkı sağlamıştır.

SNN'lerin temel yapı taşı olan nöron modelleri, membran potansiyelinin zamana bağlı değişimini ve iğnecik üretim koşullarını matematiksel olarak tanımlar. Bu modeller biyofiziksel ayrıntı ile hesaplama maliyeti arasında farklı dengeler sunar. Model seçimi genellikle ağ ölçeğine ve uygulama hedeflerine bağlıdır. Bu çerçevede, 1952'de geliştirilen Hodgkin-Huxley (HH) nöron modeli, iyonik akımların ayrıntılı matematiksel tanımını sunar. Biyolojik olarak en gerçekçi modeldir ancak doğrusal olmayan diferansiyel denklemlerden oluşan yapısı nedeniyle hesaplama karmaşıklığı yüksektir. Bu nedenle, büyük ölçekli simülasyonlarda pratik kullanımı sınırlıdır (Izhikevich, 2003). Ancak, belirli görevlerde biyolojik gerçekçiliğin ön planda olduğu çalışmalarda tercih edilebilmektedir (Voudaskas ve ark., 2025). Bu hesaplama maliyetini azaltmaya yönelik olarak geliştirilen yaklaşımlar arasında Izhikevich modeli, HH'de gözlenen birçok ateşleme dinamiğini (ör. adaptasyon ve patlama) daha düşük maliyetle yaklaşık biçimde temsil etmeyi amaçlar (Izhikevich, 2003). Bu nedenle orta ve büyük ölçekli ağ simülasyonlarında sık kullanılan seçeneklerden biridir (Kılıçarslan, 2024). Leaky Integrate-and-Fire (LIF) modeli ise Lapiçque'e dayanan, daha basit ve hesaplama açısından uygun bir nöron modelidir (Lapiçque, 1907). Modelin dinamiği, giriş iğneciklerinin membran potansiyelinde integrasyonu, sızıntı ile zamana bağlı azalması ve eşik geçildiğinde iğnecik üretimi üzerine kuruludur. Hesaplama verimliliği yüksektir. Basitliği nedeniyle görüntü işleme uygulamalarında yaygın biçimde kullanılmıştır (Wu ve ark., 2013; Kerr ve ark., 2015; İncetaş ve Arslan, 2019; İncetaş, 2022; İncetaş ve ark., 2022). IF modeli, LIF modelinin sızıntı bileşenini içermeyen daha basit bir varyantıdır. Donanımsal gerçekleştirilmede avantaj sağlar (Kerr ve ark., 2015). Bu modellerin haricinde sinaptik ve zamansal davranışları daha iyi modelleyen modellerin yanı sıra, biyolojik

nöronların daha karmaşık dinamiklerini yakalamayı hedefleyen başka modeller de bulunmaktadır (Voudaskas ve ark., 2025).

2.2. Bilgi Kodlama Stratejileri

Dış dünyadan alınan uyarıların (ör. görüntüdeki piksel yoğunlukları) SNN tarafından işlenebilmesi için iğnecik dizilerine dönüştürülmesi gerekir. Bu dönüşüm “kodlama stratejisi” olarak adlandırılır ve seçilen yöntem, temsilin doğruluğunu, hesaplama yükünü ve ağır zamansal davranışını etkileyebilir. Literatürde bu amaçla farklı kodlama yaklaşımları önerilmiştir. Bu yaklaşımlar arasında en yaygın kullanılanlardan biri hız tabanlı (rate) kodlamadır. Bu yöntemde bilgi, belirli bir zaman penceresinde üretilen iğnecik sayısı veya ateşleme olasılığı üzerinden temsil edilir. Yaklaşım, ateşleme hızına dayalı biyolojik gözlemlerle ilişkilendirilir ve statik çerçeve tabanlı verilerde (geleneksel kamera görüntüleri gibi) sıklıkla kullanılır (Adrian ve Zotterman, 1926). Bununla birlikte, iğneciklerin kesin zamanlamasını doğrudan kullanmadığı için bazı durumlarda daha uzun gözlem pencereleri gerekebilir ve bu da gecikmeyi artırabilir. Popülasyon kodlamasında ise bilgi, tek bir nöron yerine bir nöron grubunun aktivite örüntüsüyle temsil edilir. Zamansal kodlamada bilgi, iğneciklerin üretim zamanları üzerinden ifade edilir. Gecikme kodlamasında uyarı şiddeti, uyarı başlangıcından sonra ilk iğneciğe kadar geçen süreyle temsil edilir. Bir diğer yaklaşımda ise bilgi, ardışık iğnecikler arasındaki zaman aralıkları üzerinden taşınır. Delta modülasyonu uyarının değişimini iğneciklerle kodlar ve olay kameralarından gelen verilerle uyumlu olabilir. Zamansal yaklaşımlar bazı senaryolarda daha seyrek iğnecik üretse de, zamanlama jitter’ı ve donanım değişkenliğine daha duyarlı olabilmektedir (Wu vd., 2007; Vemuru, 2020). Bunların yanı sıra Poisson kodlama, girdileri olasılıksal bir süreçle iğnecik dizisine dönüştürür; yoğunluk-gecikme kodlaması ise yüksek yoğunluklu piksellerin daha erken iğnecik üretmesine dayanarak hız tabanlı ve zamansal kodlama arasında bir ara yaklaşım sunar.

3. SNN’lerin Görüntü İşleme Uygulamaları

SNN’ler, temel özellik çıkarımından nesne tespiti ve görüntü sınıflandırması gibi daha karmaşık görme görevlerine kadar çeşitli görüntü işleme problemlerinde kullanılmaktadır. Kenar belirleme, görüntü işlemenin temel adımlarından biri olup birçok yüksek seviyeli görüntü analizi yönteminin ön aşamasını oluşturur. Geleneksel yöntemler (Sobel, Prewitt, Canny gibi) genellikle gradyan tabanlıdır ve gürültüye karşı duyarlı olabilmektedir. Biyolojik görme sisteminden esinlenen SNN tabanlı yaklaşımlar bu probleme alternatif bir çerçeve sunmaktadır. Wu ve arkadaşları (2007), gri seviye değerlerini uyarıcı ve baskılayıcı sinaptik bağlantılar üzerinden işleyen bir SNN modeli

önermiştir. Yedjour ve arkadaşları (2017) HH nöron modelini kullanarak kenar belirleme performansını incelemiştir. Vemuru (2020) ise Gabor filtreleri ile SNN yaklaşımını birleştiren bir yöntem geliştirmiştir. Bunun yanı sıra Kerr ve arkadaşları (2013, 2015, 2018) yoğunluk ve derinlik görüntülerinde kenar çıkarımı üzerine çalışmalar gerçekleştirmiştir. Clogenson ve arkadaşları (2011) altıgen görüntüleme yapısı ile SNN'ni birleştirerek biyolojik retinaya daha yakın bir görüntü temsili üzerinde kenar belirleme performansını incelemiştir. İncetaş ve Arslan (2019), IF modeliyle verimli bir kenar belirleme yöntemi sunmuştur.

SNN tabanlı yöntemler görüntü işaretleme (watermarking) çalışmalarında da kullanılmaktadır. Bu uygulamalarda amaç, su işaretini görüntü kalitesini bozmayacak şekilde yerleştirmek ve aynı zamanda çeşitli işlemlere karşı dayanıklılığını sağlamaktır. İncetaş ve Kılıçaslan (2025) tarafından önerilen yöntemde, öncelikle SNN tabanlı kenar belirleme ile görüntünün kenar bölgeleri tespit edilmekte ve su işareti bu bölgelere gömülmektedir. Ayrık Dalgacık Dönüşümü ve Tekil Değer Ayrışımı ile birleştirilen bu yaklaşım, sıkıştırma ve gürültü gibi saldırılara karşı yüksek gürbüzlük sağlar. Görüntü iyileştirme alanında ise SNN modelleri gürültü giderme ve çözünürlük artırma problemlerinde kullanılmaktadır. Kılıçaslan (2024) tarafından önerilen SNN tabanlı anizotropik difüzyon yaklaşımında, difüzyon sürecinde kullanılan eşik değerleri ağ dinamiklerine bağlı olarak uyarlanabilir biçimde belirlenmektedir. Böylece görüntünün farklı bölgelerinde difüzyon miktarı değiştirilebilmekte ve kenar bilgisinin korunması hedeflenmektedir. Benzer şekilde, İncetaş (2023) ve Kılıçaslan (2024) tarafından geliştirilen SNN tabanlı enterpolasyon yöntemleri, piksel benzerliğini iğnecik tabanlı bir temsil üzerinden değerlendirerek yüksek çözünürlüklü görüntü üretimini amaçlamaktadır. İçerik tabanlı görüntü erişimi (Content-Based Image Retrieval, CBIR) sistemlerinde de SNN tabanlı özellik çıkarımı yaklaşımları kullanılmaktadır. Bu sistemlerde görüntüler genellikle kenar bilgisi gibi ayırt edici özellikler üzerinden temsil edilir. İncetaş ve Arslan (2025) tarafından geliştirilen yöntemde, veritabanındaki görüntülerin kenar haritaları SNN tabanlı bir modelle çıkarılmakta ve benzerlik hesaplamaları bu temsiller üzerinden yapılmaktadır.

Son yıllarda SNN'ler, daha karmaşık görüntü anlama görevleri olan nesne tespiti ve görüntü sınıflandırmasında da giderek daha fazla kullanılmaktadır. SNN'ler düşük güç tüketimi ve olay odaklı yapısı, özellikle otonom araçlar, drone'lar ve robotik gibi uç bilişim (edge AI) uygulamaları için büyük avantaj sunmaktadır. Nesne tespiti üzerine yapılan çalışmalarda, SNN tabanlı yaklaşımlar veri seti türleri ve eğitim yöntemleri açısından incelenmektedir. Kullanılan veri setleri; statik veri setleri (CIFAR, ImageNet gibi), statik verilerden dönüştürülen nöromorfik veri setleri, nöromorfik yakalama veri

setleri ve simülasyon yoluyla oluşturulan veri setleri olarak sınıflandırılmaktadır. Algoritmalar ise ANN-SNN dönüşümü ve vekil gradyan ile doğrudan eğitim olmak üzere iki ana başlıkta incelenmektedir (Wu ve ark., 2025; Iaboni ve Abichandani, 2024). Görüntü sınıflandırma çalışmalarında ise SNN'lerin eğitimi için farklı öğrenme paradigmaları irdelenmektedir. Çalışmalarda öne çıkan yaklaşımlar arasında sinaptik plastisite tabanlı yöntemler, yaklaşık geri yayılım temelli yöntemler ve ANN-SNN dönüşümü yer almaktadır (Niu ve ark., 2023). Bu bağlamda hiyerarşik SNN mimarileri, görsel dikkat benzeri mekanizmalarla birlikte daha üst düzey görme görevleri için önerilen yaklaşımlar arasında yer almaktadır (Wu vd., 2013; Kerr vd., 2011).

4. Eğitim Yöntemleri ve Veri Setleri

SNN'lerin en büyük zorluklarından biri, iğnecik fonksiyonunun türevlenemez (non-differentiable) olması nedeniyle geleneksel geri yayılım (backpropagation) algoritmasının doğrudan uygulanamamasıdır (Voudaskas ve ark., 2025). Literatürde bu problemi aşmak için üç ana öğrenme yaklaşım geliştirilmiştir. Bunlardan ilki ANN-SNN dönüşümü ile eğitimidir. Bu yöntemde önce geleneksel bir ANN geri yayılım gibi standart tekniklerle eğitilir; ardından öğrenilen ağırlıklar ve mimari, aktivasyonların iğnecik hızlarına veya zamanlamalarına eşlenmesiyle işlevsel olarak eşdeğer bir SNN'ye dönüştürülür. Bu yaklaşım, ANN'lerin olgun eğitim altyapısından yararlanmayı sağlar; ancak dönüşüm sırasında bilgi kaybı, kodlama kaynaklı performans düşüşü ve özellikle zaman tabanlı kodlamalarda gecikme gibi sorunlar görülebilir (Voudaskas ve ark., 2025). İkinci ve son yıllarda en yaygın hale gelen yaklaşım, vekil gradyan ile doğrudan eğitimidir. İleri yayılımda gerçek iğnecikleme dinamiği korunurken, geri yayılım sırasında türevlenebilir bir vekil fonksiyon kullanılarak gradyan hesabı mümkün kılınır. Bu sayede SNN'ler ANN'ye dönüştürmeye ihtiyaç duymadan doğrudan görev üzerinde optimize edilir ve zamansal dinamikleri daha etkin öğrenebilir (Voudaskas ve ark., 2025). Üçüncü yaklaşım ise sinaptik plastisite tabanlı öğrenme (STDP) kurallarıdır. Burada biyolojik olarak daha gerçekçi öğrenme kuralları da SNN'lerin eğitiminde kullanılmaktadır. Bu denetimsiz öğrenme yöntemleri, nöronlar arasındaki sinaptik bağlantıların, iğneciklerin göreceli zamanlamalarına göre güçlendirilmesi veya zayıflatılması prensibine dayanır. Ancak, büyük ölçekli ve denetimli görevlerde STDP'nin performansı, diğer yöntemlere göre genellikle daha düşük kalmaktadır (Niu ve ark., 2023; Iaboni ve Abichandani, 2024).

SNN çalışmalarında kullanılan veri setleri de dört grupta toplanmaktadır (Wu ve ark., 2025). Statik veri setleri doğrudan iğnecik tabanlı olmadığından, genellikle hız/zamansal kodlama ile spike dizilerine dönüştürülmektedir. Nöromorfik dönüşüm veri setlerinde statik veriler hareket/video

simülasyonlarıyla yapay olarak nöromorfik veriye çevrilir. Nöromorfik yakalama veri setleri ise nöromorfik kameralarla doğrudan olay akışı olarak kaydedilen veri setleridir. SNN'lerin zamansal işleme avantajlarını en iyi yansıtır. Son olarak, simülasyonla üretilen veri setleri ise bilgisayar simülasyonları ile sentetik olarak oluşturulan veri setleridir.

5. Donanımsal Gerçekleme ve Nöromorfik Platformlar

SNN'lerin en önemli avantajlarından biri, nöromorfik donanımlarda son derece verimli bir şekilde çalışabilmeleridir. Bu donanımlar, spikelerin seyrek ve asenkron yapısından faydalanarak geleneksel Von Neumann mimarisine sahip işlemcilerle kıyasla birkaç kat daha düşük güç tüketimiyle çalışabilmektedir. IBM TrueNorth ve Intel Loihi, SNN'lerin çalıştırılması için tasarlanmış nöromorfik işlemcilerdir. Bu mimarilerde nöron ve sinaps benzeri hesaplama birimleri donanım düzeyinde gerçekleştirilir ve işlem yoğunlukla iğnecik iletimiyle tetiklenir (Voudaskas ve ark., 2025). Nöromorfik çiplerin yanında FPGA tabanlı gerçeklemeler de yaygındır. FPGA'ler, SNN mimarisini uygulamaya göre özelleştirmeye olanak verdiği için düşük gecikme ve görece düşük güç hedeflenen tasarımlarda tercih edilir. Karmaşık nöron modellerinde doğrusal olmayan terimler yaklaşık hesaplamalarla sadeleştirilerek kaynak kullanımı azaltılabilir. SNN'lerin pratikte daha dikkat çekici olduğu alanlardan biri de nöromorfik sensörlerle bütünleşik çalışmadır. Nöromorfik sensörler, doğal olarak olay veya spike benzeri çıktılar üretir. Geleneksel işleme yöntemleri, bu sinyallerin biriktirilmesini, sayısallaştırılmasını ve ardından işlenmesini gerektirirken, SNN'ler bu sinyalleri doğrudan işleyerek uçtan uca daha düşük gecikmeli ve daha verimli sistemlerin kurulmasına olanak tanır (Voudaskas ve ark., 2025).

6. Mevcut Yaklaşımların Sınırlamaları ve Gelecek Çalışmalar

SNN, görüntü işleme alanında önemli bir potansiyel sunmasına rağmen, yaygın olarak kullanılmalarının önünde bazı temel zorluklar bulunmaktadır. Bu zorluklar özellikle eğitim yöntemleri, veri setlerinin yapısı ve donanımsal kısıtlarla ilişkili konularda ortaya çıkmaktadır. SNN'lerin eğitimi, iğnecik üretim mekanizmasının türevlenebilir olmaması nedeniyle zorluk içermektedir. Bu sorunu aşmak için geliştirilen vekil gradyan yöntemleri ve ANN-SNN dönüşüm yaklaşımları önemli ilerlemeler sağlamış olsa da her iki yaklaşımın da belirli sınırlamaları bulunmaktadır. Örneğin dönüşüm tabanlı yöntemlerde bilgi kaybı ve gecikme sorunları ortaya çıkabilirken, vekil gradyan yöntemleri seçilen hiperparametrelere duyarlı olabilmektedir. Biyolojik olarak esinlenmiş öğrenme kuralları ise özellikle karmaşık ve denetimli görevlerde henüz yeterli performansa ulaşamamıştır. Bir diğer önemli konu, veri setleri ve karşılaştırma

ölçütleridir. SNN çalışmalarında kullanılan veri setleri çoğu zaman sınırlı ölçekli veya belirli uygulamalara özgüdür. Ayrıca farklı çalışmalarda kullanılan kodlama yöntemleri, ağ mimarileri ve performans ölçütleri önemli ölçüde değişiklik gösterebilmektedir. Bu durum, farklı yöntemlerin sonuçlarının doğrudan ve adil biçimde karşılaştırılmasını zorlaştırmaktadır. SNN modellerinde zamansal bilgi işlenirken genellikle birden fazla zaman adımı kullanılması gerektiğinden, özellikle hız tabanlı kodlama yaklaşımlarında gecikme problemi ortaya çıkabilmektedir. Bunun yanında, bu ağların donanım üzerinde verimli çalışabilmesi için ağ mimarilerinin ve nöron modellerinin donanım kısıtları dikkate alınarak tasarlanması gerekmektedir.

Gelecekteki çalışmaların önemli bir kısmı algoritma ve donanımın birlikte tasarlanmasına odaklanmaktadır. Bu kapsamda eğitim algoritmalarının donanım özellikleriyle uyumlu olacak şekilde geliştirilmesi, yeni spiking ağ mimarilerinin tasarlanması ve daha verimli eğitim yöntemlerinin araştırılması öne çıkan konular arasındadır. Ayrıca SNN'lerin modellenmesi, eğitimi ve donanıma aktarımı için kapsamlı yazılım araçlarının geliştirilmesi ile sürekli öğrenme, pekiştirmeli öğrenme ve çoklu veri türlerinin birlikte işlendiği uygulama alanlarında yeni çalışmalar yapılması beklenmektedir.

7. Sonuç

Bu çalışma, SNN'lerin görüntü işleme alanında araştırılan yaklaşımlar arasında yer aldığını ve farklı uygulamalarda değerlendirildiğini göstermektedir. Biyolojik sinir sistemlerinden esinlenen olay tabanlı ve enerji verimli hesaplama yapıları sayesinde SNN'ler, kenar belirleme, görüntü iyileştirme ve görüntü sınıflandırma gibi çeşitli görevlerde başarılı sonuçlar sunabilmektedir. Özellikle düşük güç tüketimi gerektiren uç bilişim uygulamaları açısından dikkat çekici bir alternatif oluşturmaktadır. SNN'lerin en önemli avantajları arasında seyrek ve asenkron hesaplama yapısı ile nöromorfik sensörlerle uyumlu çalışabilme yeteneği yer almaktadır. Bu özellikler, otonom sistemler, robotik ve nesnelerin interneti gibi kaynak kısıtlı ortamlarda kullanımını desteklemektedir. Bununla birlikte, eğitim yöntemlerindeki zorluklar, standart veri setleri ve karşılaştırma ölçütlerinin sınırlı olması gibi bazı sorunlar hâlen araştırma konusudur. Gelecekte algoritma–donanım birlikte tasarımı, yeni spiking ağ mimarileri ve daha gelişmiş eğitim yöntemleri üzerine yapılacak çalışmaların SNN'lerin kullanım alanlarını genişletmesi beklenmektedir. Ayrıca nöromorfik sensörlerle bütünleşik çalışan sistemlerin geliştirilmesi, enerji verimli yapay zekâ uygulamalarının ilerlemesine katkı sağlayabilir. Bu yönleriyle SNN'ler geleceğin görüntü işleme sistemleri için önemli bir araştırma alanı olarak değerlendirilmektedir.

Kaynaklar

- Clogenson, M., Kerr, D., McGinnity, T. M., Coleman, S. A., & Wu, Q. (2011). Biologically inspired edge detection using spiking neural networks and hexagonal images. In *International Conference on Neural Computation Theory and Applications* (pp. 381-384). SciTePress.
- Davies, M., Srinivasa, N., Lin, T. H., Chinya, G., Cao, Y., Choday, S. H., ... & Wang, H. (2018). Loihi: A neuromorphic manycore processor with on-chip learning. *Ieee micro*, 38(1), 82-99.
- Hodgkin, A. L., & Huxley, A. F. (1952). A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of physiology*, 117(4), 500.
- Iaboni, C., & Abichandani, P. (2024). Event-based spiking neural networks for object detection: a review of datasets, architectures, learning rules, and implementation. *IEEE Access*, 12, 180532-180596.
- Izhikevich, E. M. (2003). Simple model of spiking neurons. *IEEE Transactions on neural networks*, 14(6), 1569-1572.
- İncetaş, M. O. (2022). Anisotropic diffusion filter based on spiking neural network model. *Arabian Journal for Science and Engineering*, 47(8), 9849-9860.
- İncetaş, M. O., Kılıçaslan, M., & Farshi, T. R. (2022). Image retrieval with SNN-based multi-level thresholding. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, Özel Sayı, 98-108.
- İncetaş, M. O. (2023). Image interpolation based on spiking neural network model. *Applied Sciences*, 13(4), 2438.
- İncetaş, M. O., & Arslan, R. U. (2019). Edge Detection Using Integrate and Fire Neuron. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 23(2), 611-616.
- İncetaş, M. O., & Arslan, R. U. (2025). Spiking neural network-based edge detection model for content-based image retrieval. *Signal, Image and Video Processing*, 19(2), 169.
- İncetaş, M. O., & Kılıçaslan, M. (2025). Image watermarking based on spiking neural networks. *Cluster Computing*, 28(11), 736.
- Kerr, D., Coleman, S., & McGinnity, T. M. (2018). Biologically inspired intensity and depth image edge extraction. *IEEE Transactions on Neural Networks and Learning Systems*, 29(11), 5356-5365.
- Kerr, D., Coleman, S. A., McGinnity, T. M., & Clogenson, M. (2013, August). Biologically inspired intensity and range image feature extraction. In *The 2013 International Joint Conference on Neural Networks (IJCNN)* (pp. 1-8). IEEE.
- Kerr, D., McGinnity, T. M., Coleman, S., & Clogenson, M. (2015). A biologically inspired spiking model of visual processing for image feature detection. *Neurocomputing*, 158, 268-280.

- Kılıçaslan, M. (2024). Image interpolation with spiking neural network based pixel similarity. *Signal, Image and Video Processing*, 18(10), 6925-6936.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Lapicque, L. (1907). Recherches quantitatives sur l'excitation électrique des nerfs traitée comme une polarisation. *Journal de physiologie et de pathologie générale*, 9, 620-635.
- Lichtsteiner, P., Posch, C., & Delbruck, T. (2008). A 128 \times 128 120 dB 15 μ s latency asynchronous temporal contrast vision sensor. *IEEE journal of solid-state circuits*, 43(2), 566-576.
- Maass, W. (1997). Networks of spiking neurons: the third generation of neural network models. *Neural networks*, 10(9), 1659-1671.
- Merolla, P. A., Arthur, J. V., Alvarez-Icaza, R., Cassidy, A. S., Sawada, J., Akopyan, E., ... & Modha, D. S. (2014). A million spiking-neuron integrated circuit with a scalable communication network and interface. *Science*, 345(6197), 668-673.
- Niu, L. Y., Wei, Y., Liu, W. B., Long, J. Y., & Xue, T. H. (2023). Research progress of spiking neural network in image classification: A review. *Applied intelligence*, 53(16), 19466-19490.
- Saifei, W. U., Yuan, Z., Di, X. I. E., Hai, Y. U., & Jiang, Z. H. U. (2025). Comprehensive survey of spiking neural networks for visual object detection: from biological mechanisms to state-of-the-art applications. *Journal of Functional Materials and Devices*, 31(5), 364-378.
- Thorpe, S. J., & Imbert, M. (1989). Biological constraints on connectionist modelling. *Connectionism in perspective*, 63-92.
- Voudaskas, M., MacLean, J. I., Dutton, N. A., Stewart, B. D., & Gyongy, I. (2025). Spiking neural networks in imaging: A review and case study. *Sensors*, 25(21), 6747.
- Wu, Q., McGinnity, M., Maguire, L., Belatreche, A., & Glackin, B. (2007, August). Edge detection based on spiking neural network model. In *International Conference on Intelligent Computing* (pp. 26-34). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Yedjour, H., Meftah, B., Lézoray, O., & Benyettou, A. (2017). Edge detection based on Hodgkin–Huxley neuron model simulation. *Cognitive processing*, 18(3), 315-323.
- Zhang, A., Cao, H., Shan, N., Wang, J., Pu, M., & Song, Y. (2025). Spiking neural networks for object detection and semantic segmentation across event-driven and frame-based modalities: A review. *Intelligent Opto-Electronics*, 1(2), 250007-1.