KSÜ Mühendislik Bilimleri Dergisi, 29(3), 2026
Araştırma Makalesi

KSU J Eng Sci, 29(3), 2026
Research Article

Kahramanmaras Sutcu Imam University
Journal of Engineering Sciences

Geliş Tarihi : 23.02.2026
Kabul Tarihi : 20.05.2026

Received Date : 23.03.2026
Accepted Date : 20.05.2026

AFET SONRASI YENİDEN YAPILAŞMA SÜREÇLERİNDE HIZLANDIRICI BİR ARAÇ OLARAK YAPAY ZEKA DESTEKLİ OTOMATİK KAT PLANI ÜRETİMİ

ARTIFICIAL INTELLIGENCE-SUPPORTED AUTOMATIC FLOOR PLAN GENERATION AS AN ACCELERATING TOOL IN POST-DISASTER RECONSTRUCTION PROCESSES

İlker KARABULUT[1*] (ORCID: 0000-0002-7894-6491)
Burhan ERGEN[2] (ORCID: 0000-0003-3244-2615)

[1] Fırat Üniversitesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye
[2] Fırat Üniversitesi, Bilgisayar Mühendisliği Bölümü, Elazığ, Türkiye

*Sorumlu Yazar / Corresponding Author: İlker KARABULUT, 231129205@firat.edu.tr

ÖZET

Büyük ölçekli afetler sonrasında ortaya çıkan acil konut ihtiyacı, kısa süre içinde binlerce konut biriminin hızlı ve nitelikli biçimde tasarlanmasını zorunlu kılmaktadır. Geleneksel mimari tasarım yöntemleri, her bir konut biriminin ayrı ayrı ele alınmasını gerektirdiğinden, zaman ve iş gücü bakımından ölçeklenebilirlik açısından sınırlı kalmaktadır. Bu çalışmada, oda sayısı, oda türü ve mekânsal bağlantı şeması gibi kullanıcı tarafından tanımlanan sınırlı tasarım kısıtlarından otomatik olarak kat planı üreten hibrit bir öğrenme çerçevesi önerilmektedir. Söz konusu kısıtlar, vaziyet planı ve yapı sınırları bağlamında temsil edilmekte; mekânsal ilişkilerin kodlanması amacıyla İkinci Nesil Grafik Dikkat Ağı (GATv2) mimarisi kullanılmaktadır. GATv2 modülü tarafından üretilen vektörel yerleşim çıktıları, diferansiyellenebilir bir işleme katmanından geçirilerek koşullu üretken çekişmeli ağ (cGAN) aracılığıyla görsel doku ve mobilya bilgisi içeren nihai kat planlarına dönüştürülmektedir. RPLAN veri setinde yer alan 80.000 etiketli plan üzerinde eğitilen ve optimize edilen model, 0,7649 IoU yerleşim doğruluğu ve 22,10 Fréchet Inception Distance (FID) değeri elde etmiştir. Bulgular, afet sonrası toplu konut üretiminde tasarım esnekliğini korurken üretim süresini belirgin biçimde azaltabilecek bir karar destek aracının uygulanabilirliğini ortaya koymaktadır.

Anahtar Kelimeler: Derin öğrenme, çizge dikkat ağı, koşullu üretken çekişmeli ağ, mimari otomasyon.

ABSTRACT

The pressing need for housing after large-scale disasters requires the rapid, high-quality design of thousands of units in a short time. Conventional architectural methods are limited in scalability, in both time and labour, because each unit is treated individually. In this study, a hybrid learning framework is proposed that automatically generates floor plans from sparse, user-defined design constraints (number/type of rooms and connection scheme). These constraints are represented by the site plan and building boundaries, and the Second-Generation Graph Attention Network (GATv2) architecture is used to encode spatial relationships. The vector layouts produced by the GATv2 module pass through a differentiable rendering layer and are converted, via a conditional generative adversarial network (cGAN), into final floor plans containing visual texture and furnishing. Trained and optimised on the RPLAN dataset of 80,000 labelled plans, the model achieved a layout accuracy of 0.7649 IoU and a Fréchet Inception Distance (FID) of 22.10. The findings indicate the viability of a decision-support tool able to markedly reduce production time while preserving design flexibility in post-disaster mass housing.

Keywords: Deep learning, graph attention network, conditional generative adversarial network, architectural automation.

This work is licensed under a Creative Commons Attribution 4.0 International License (CC BY 4.0).

GİRİŞ

Doğal afetler, özellikle depremler, kentsel dokuda yarattıkları ani yıkımlarla barınma ihtiyacını acil ve kitlesel bir boyuta taşımaktadır. Yakın tarihte yaşanan Maraş (2023) depremi sonrası yapılan tespitlerde, depremden etkilenen 11 ilde, yüz binlerce yapının hasarlı olduğu ortaya çıkmıştır. Yıkım veya ağır hasar yalnızca konut niteliği taşıyan yapılarla sınırlı kalmamış; tarihî ve kültürel yapılar, eğitim kurumları, idari yapılar, sağlık yapıları ve konaklama tesisleri de bu süreçten etkilenmiştir. Bu kapsamda, şehircilik ve mimari tasarım yaklaşımlarının, çevresel faktörler ile kullanıcı tercihlerini birlikte değerlendirerek, doğal çevre ile uyumlu, iklimsel ve bölgesel koşullara duyarlı, altyapı olanaklarını dikkate alan ve toplumsal talepleri mevcut kaynaklar kapsamında en uygun sonuca ulaştıran bir çerçevede geliştirilmesi gerekmektedir (Hastürk ve Altan, 2023). Afet sonrası iyileştirme çalışmalarının başarısı, kalıcı konutların güvenli ve nitelikli biçimde çok kısa sürede üretilebilmesine bağlıdır. Ancak geleneksel mimari tasarım süreçleri, her konutu tekil bir problem olarak ele aldığı için binlerce birimin aynı anda tasarlanması gereken senaryolarda zaman ve iş gücü açısından ölçeklenebilir değildir. Bu nedenle, tasarım kalitesini korurken üretim hızını artıran ve mimara çoklu yerleşim alternatifleri sunabilen karar destek yaklaşımlarına duyulan gereksinim artmaktadır (Ünal, 2021).

Bu bağlamda, derin öğrenme tabanlı üretken modellerin mimarlık disiplinine entegrasyonu, "üretken tasarım" iş akışlarında yeni olanaklar sağlamıştır. Veri odaklı yaklaşımlar, kısıtlar altında hızlı alternatif üretimi ve tekrar üretim maliyetinin düşürülmesi gibi avantajlar sunmaktadır (Rahbar vd., 2022).

Otomatik kat planı üretimine yönelik çalışmalar, kural tabanlı yöntemlerden veri odaklı öğrenme modellerine doğru evrilmiştir. Örneğin, (Wu vd., 2019) konut planlarını vektörel bir gösterimle ele alarak oda yerleşimi ve duvar çizimini sıralı bir üretim süreci olarak modellemiş; ayrıca bu alanda yaygın kullanılan RPLAN veri setini tanıtmıştır. 2020 sonrası literatürde, özellikle Çekişmeli Üretici Ağlar (GAN) ve Çizge Sinir Ağları (GNN) tabanlı kısıt-güdümlü üretim yaklaşımları öne çıkmaktadır. House-GAN yaklaşımı, oda ilişkilerini kabarcık diyagramı olarak temsil edip graf-kısıtlı yerleşim sentezini ilişkisel bir GAN mimarisiyle ele almıştır (Nauata vd., 2020); daha sonra House-GAN++ ile vektörel düzeltme ve geometrik tutarlılık açısından geliştirilmiştir (Nauata vd., 2021). Benzer şekilde, Graph2Plan modeli kullanıcı tarafından tanımlanan yerleşim grafiği ve bina sınırı kısıtlarını birlikte öğrenerek sınır-uyumlu yerleşimler üretebilen bir çerçeve sunmuştur (Hu vd., 2020).

Mevcut yaklaşımlarda temel zorluk, topolojik tutarlılık -oda komşuluğu ve bağlantı mantığı- ile görsel veya çizimsel gerçekçilik arasında dengeli bir çıktı üretmektir. Çizge tabanlı modeller, komşuluk ilişkilerini doğru kurgulamada güçlü olsa da çizim ayrıntıları ve semantik doku üretiminde sınırlı kalabilmekte ve yalnızca görüntü-çevirimi odaklı modeller ise görsel olarak ikna edici çıktılar üretmesine rağmen komşuluk ihlali ve çakışma gibi mantıksal hatalara yatkın olabilmektedir (Rahbar vd., 2022). Afet sonrası özellikle yeniden yapım gibi hız ve ölçek gereksinimi yüksek senaryolarda bu kopukluk, tasarımın uygulanabilirliği ve üretim verimliliği açısından daha da kritik hale gelmektedir.

Sunulan bu çalışmada, GNN'in topolojik analiz gücünü koşullu GAN (cGAN) tabanlı görsel sentez ile birleştiren hibrit bir çerçeve önerilmektedir. Önerilen sistem, mimarın belirlediği oda sayısı, oda türü ve komşuluk ilişkileri gibi seyrek kısıtları girdi olarak alarak oldukça kısa bir zamanda birden çok inşa edilebilir ve yaşanabilir kat planı alternatifi üretmeyi ve böylece afet sonrası kitlesel konut üretim süreçlerinde karar verme ve tasarım geliştirme döngüsünü hızlandırmayı hedeflemiştir.

MATERYAL VE YÖNTEM

Bu çalışmada önerilen model, afet sonrası acil barınma ihtiyacına yönelik olarak, oda sayısı, oda türü ve ilişkileri gibi mimari program verisini çok kısa bir zamanda inşa edilebilir bir kat planına dönüştüren uçtan uca bir yapay zeka sistemidir. Önerilen sistem mimarisi üç temel modülden oluşmaktadır: Birinci aşama, Topolojik Yerleşim Tahmini (GNN), ikinci aşama, Anlamsal Maskeleme ve üçüncü aşama, Görsel Doku Sentezi (cGAN).

Veri Seti ve Ön İşleme

Modelin eğitimi ve testi için, Şekil 1'de bir örneği verilen literatürdeki oldukça kapsamlı konut veri setlerinden biri olan RPLAN (Wu vd., 2019) kullanılmıştır. Bu veri seti, vektörel formatta etiketlenmiş 80.000'den fazla gerçek kat planını içermektedir.

Başlangıç aşamasında, filtrelenmiş nitelikli konut planlarından oluşan veri kümesi, örnekler arasında örtüşme olmayacak şekilde iki ayrık alt kümeye bölünmüştür. Veri kümesinin %80'i model için, kalan %20'si ise bağımsız test seti olarak ayrılmıştır. Bu çalışmada ayrı bir doğrulama seti kullanılmamıştır.

Bu nedenle çalışmada raporlanan mIoU, FID, topolojik doğruluk ve piksel düzeyinde doğruluk değerleri doğrulama performansını değil, eğitim sürecinde kullanılmayan bağımsız test seti üzerindeki nihai değerlendirme sonuçlarını ifade etmektedir. Modelin optimizasyonu, yüksek hesaplama kapasitesine sahip NVIDIA A100 GPU donanımı üzerinde gerçekleştirilmiş; bu sayede büyük matris operasyonları ve derin öğrenme katmanlarındaki gradyan akışları optimize edilmiştir. Toplam 50 devir süren eğitim periyodu boyunca, üretici ve ayırt edici ağların yakınsama kararlılığı hassasiyetle takip edilmiştir.

Eğitim sürecinde model yakınsaması, üretici ve ayırt edici ağlara ait kayıp değerleri ile belirli aralıklarla elde edilen örnek üretimler üzerinden takip edilmiştir. Test seti, eğitim sürecinde model seçimi, hiperparametre ayarı veya erken durdurma amacıyla kullanılmamış; yalnızca eğitim tamamlandıktan sonra nihai performans değerlendirmesi için kullanılmıştır. Bu kapsamda IoU, FID ve piksel düzeyinde doğruluk değerleri, eğitim sürecinde görülmeyen bağımsız %20'lik test seti üzerinde hesaplanmıştır.Ham veri setinin doğrudan modele verilmesi, eğitim sürecinde kararsızlıklara ve anlamsız üretimlere yol açabilir. Bu nedenle, çalışmanın metodolojik bütünlüğünü desteklemek amacıyla çok katmanlı bir önişleme ve filtreleme boru hattı geliştirilmiştir.

Veri ön işleme aşamasında, her bir kat planı bir çizge yapısına G = (V,E) dönüştürülmüştür. Burada düğümler (V) odaları, kenarlar (E) ise odalar arasındaki kapı veya komşuluk bağlantılarını temsil etmektedir. Her düğüm için salon ve mutfak gibi oda tipleri vektör olarak kodlanmış ve modelin girdisi haline getirilmiştir.

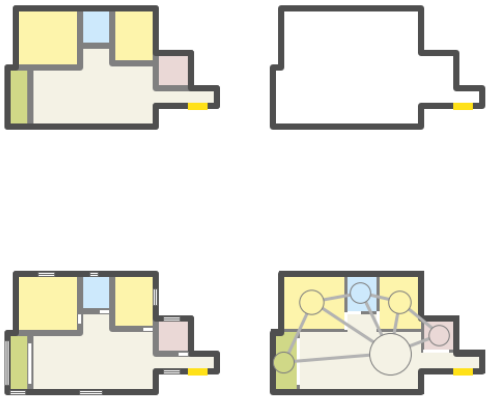

Şekil 1. RPLAN Veri Setinden Bir Örnek

Her bir düğüm v_i, odanın kimliğini ve geometrik durumunu tanımlayan zengin bir öznitelik vektörü X_i ile temsil edilir. Literatürdeki basit temsillerin aksine, bu çalışmada hibrit bir öznitelik seti kurgulanmıştır. Denklem (1)'de X_i vektörü, D_f boyutunda olup aşağıdaki bileşenlerin birleşiminden oluşur:

$$X_i = [o_{type} \,||\, g_{geo} \,||\, p_{pos}] \quad (1)$$

- o_{type} **(Oda Tipi- One-hot Vector):** Odanın fonksiyonunu (Salon, Mutfak, Banyo, vb.) kodlayan 13 boyutlu vektör.
- g_{geo} **(Geometrik Öznitelikler):** Odanın normalize edilmiş genişliği (w), yüksekliği (h) ve alan oranı ($Area_{room} / Area_{total}$). Bu özellikler, modelin odalar arası hiyerarşiyi (örneğin salonun banyodan büyük olması gerektiğini) öğrenmesini sağlar.
- p_{pos} **(Pozisyonel Kodlama):** Transformatör modellerinden esinlenilerek, odanın merkez koordinatları (c_x, c_y) üzerine sinüzoidal pozisyonel kodlama uygulanmıştır. Bu, GNN'in mekânsal farkındalığını artırır.

Oda fonksiyonlarını kodlayan 13 boyutlu one-hot vektörü; salon, mutfak, ebeveyn yatak odası, ikinci yatak odası, banyo, balkon, yemek odası, antre, çalışma odası, depo, tuvalet, koridor ve 'diğer' kategorisi olmak üzere RPLAN veri setinde tanımlı tüm standart konut birimlerini kapsamaktadır. Bu geniş sınıflandırma, GNN katmanının sadece temel odaları değil, aynı zamanda kompleks plan şemalarındaki sirkülasyon ve yardımcı hacimlerin topolojik ilişkilerini de öğrenmesine olanak tanır.

Bu çalışmada, Üretici Çekişmeli Ağ (GAN) tabanlı modelin ürettiği kat planlarının gerçek veri dağılımına ne ölçüde yaklaştığını nicel olarak değerlendirmek amacıyla Fréchet Inception Distance (FID) metriği de kullanılmıştır. FID,

generatif modellerin performansını ölçmede yaygın olarak kullanılan ve üretilen örneklerin gerçek örneklere olan dağılımsal benzerliğini değerlendiren bir ölçüttür (Heusel vd., 2017). Söz konusu metrik, gerçek ve üretilmiş görüntülerin, önceden eğitilmiş bir Inception-v3 ağı üzerinden elde edilen öznitelik temsilleri arasındaki farkı temel alarak hesaplanmaktadır. Bu yaklaşım, yalnızca piksel düzeyindeki benzerliği değil, aynı zamanda daha yüksek seviyeli görsel ve yapısal örüntülerin uyumunu da dikkate alması bakımından önem taşımaktadır.

Matematiksel olarak FID, gerçek veri dağılımından elde edilen özniteliklerin çok değişkenli Gauss dağılımı $N(\mu_r, \sum_r)$ ve üretilen veri dağılımından elde edilen özniteliklerin çok değişkenli Gauss dağılımı $N(\mu_g, \sum_g)$ ile temsil edildiği varsayımına dayanmaktadır. Bu iki dağılım arasındaki uzaklık aşağıdaki eşitlik ile hesaplanmaktadır (Heusel vd., 2017):

$$\text{FID}= ||\mu_r - \mu_g|\,|_2^2 + Tr(\sum_r + \sum_g - 2(\sum_r \sum_g)^{1/2}) \quad (2)$$

Denklem (2)'de μ_r ve $\sum_r$ gerçek kat planı örneklerinden elde edilen özniteliklerin ortalama vektörü ve kovaryans matrisini; μ_g ve $\sum_g$ ise model tarafından üretilen kat planı örneklerine ait özniteliklerin ortalama vektörü ve kovaryans matrisini ifade etmektedir. Denklemde yer alan ilk terim, iki dağılımın ortalamaları arasındaki uzaklığı; ikinci terim ise kovaryans yapıları arasındaki farkı ölçmektedir. Bu nedenle FID, yalnızca görsel benzerliği değil, aynı zamanda dağılımın çeşitlilik ve yapısal tutarlılık özelliklerini de değerlendirebilmektedir.

Aşama 1 - Çizge Tabanlı Topolojik Yerleşim (GNN)

Sistemin ilk aşaması, mimari tasarımın "mantıksal" iskeletini oluşturur. Bu modül, odaların birbirine göre konumlarını ve boyutlarını belirler. Çizge verilerini işlemek için Graf Dikkat Ağları (Graph Attention Networks - GATv2) mimarisi tercih edilmiştir. GATv2, komşu düğümlerden gelen bilgileri ağırlıklandırarak (attention mechanism), hangi oda ilişkisinin tasarımda daha kritik olduğunu öğrenir (Brody vd.,2022).

Model, her bir oda (vi) için bir sınır kutusu tahmin eder:

$$b_i = (c_{xi}, c_{yi}, w_i, h_i) \quad (3)$$

Denklem (3)'te, (c_x, c_y) odanın merkez koordinatlarını, (w, h) ise genişlik ve yüksekliği ifade eder. Eğitim sürecinde, tahmin edilen kutular ile gerçek yerleşim arasındaki farkı minimize etmek için L_1 kaybı ve Genelleştirilmiş IoU (GIoU) kaybı birleştirilerek kullanılmıştır (Rezatofighi vd., 2019):

$$L_{box} = \lambda_{L_1} \left|\left|b_i - \widehat{b_i}\right|\right| 1 + \lambda_{GIoU}(1 - GIoU(b_i, \widehat{b_i})) \quad (4)$$

Denklem (4) ile tanımlanan sınırlayıcı kutu kaybında L_{box}, farklı regresyon hedefleri arasındaki dengeyi sağlamak amacıyla ağırlık katsayıları kullanılmıştır. Yapılan deneysel optimizasyonlar sonucunda, piksel düzeyindeki mutlak koordinat hatasını minimize eden L_1 kaybı ile geometrik örtüşmeyi optimize eden GIoU kaybı arasındaki ilişkiyi kuran katsayılar şu şekilde belirlenmiştir. λ_{L_1} parametresi, modelin oda merkez koordinatları c_x, c_y ve boyutları w, h üzerindeki hassasiyetini korumak amacıyla 1,0 olarak atanmıştır. λ_{GIoU} parametresi, odaların birbirine göre konumsal doğruluğunu ve ölçek tutarlılığını artırmak amacıyla 2,0 değerine ayarlanmıştır.

Bu değerlerin seçimi, modelin eğitim aşamasında hem bireysel oda koordinatlarında düşük hata payına ulaşmasını hem de plan genelinde odaların birbirini ezmesini veya boşluk bırakmasını engelleyen global bir geometrik uyum yakalamasını sağlamıştır. Eğitim boyunca kullanılan bu sabit katsayılar, modelin yüksek sismik güvenlik ve imar kısıtlarına uyum sağlama potansiyelini destekleyen kararlı bir gradyan akışı sunmaktadır.

Aşama 2 - Anlamsal Maske Üretimi (Rasterizasyon)

Önerilen mimarinin kritik bir bileşeni olan anlamsal rasterizasyon modülü, çizge sinir ağı (GNN) tarafından üretilen soyut topolojik veriler ile çekişmeli üretici ağ (GAN) tarafından gerçekleştirilen görsel sentez aşaması arasında diferansiyel bir köprü görevi görür.

Bu modülün temel işlevi, GNN çıktısı olan ve her bir oda v_i için tahmin edilen merkez koordinatları (c_x, c_y) ile boyutsal parametreleri (w, h), GAN'ın işleyebileceği 256x256 çözünürlüğünde çok kanallı bir semantik maskeye

dönüştürmektir. Rasterizasyon süreci, her oda tipine (o_{type}) özgü benzersiz bir renk kodunun (RGB kanalları) atanmasıyla başlar.

Modül, vektör tabanlı sınırlayıcı kutu verilerini kullanarak, ilgili koordinat düzlemindeki her bir piksele ait semantik sınıfı belirler. Bu aşamada, odalar arası komşuluk ilişkileri ve bina sınır kısıtları, piksellerin uzamsal dağılımı üzerinden görsel bir kılavuza dönüştürülür.

Anlamsal maske, cGAN (Pix2Pix) ünitesi için yüksek yoğunluklu bir mekânsal rehber işlevi görür. Bu rehberlik sayesinde model; duvar kalınlıkları, kapı-pencere açıklıkları ve tefrişat elemanları gibi ikincil mimari detayları, GNN tarafından belirlenen katı geometrik kısıtlara sadık kalarak sentezleme yeteneği kazanır.

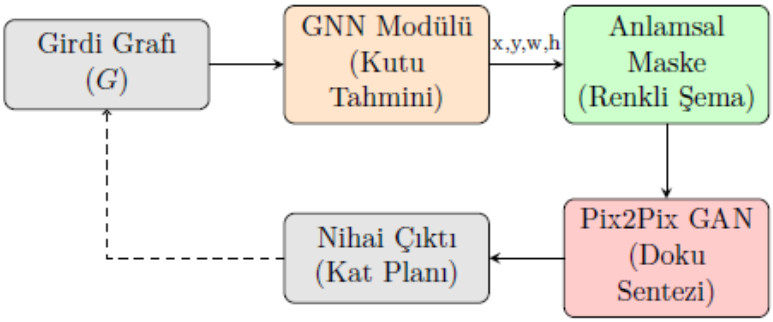

Şekil 2. Geliştirilen Hibrit Modelin Veri Akış Diyagramı

Çalışmanın en önemli katkısı olan Şekil 2'deki hibrit yapı, GNN tarafından iskeleti oluşturulan tasarımın, çekişmeli üretici ağlar (GAN) kullanılarak mimari bir "render" kalitesine ulaştırılmasıdır. GNN mantıksal yerleşimi çözerken, GAN görsel detaylandırmayı yapmaktadır. Bu yapı grafik- piksel oluşturucu olarak adlandırılmaktadır. Klasik Pix2Pix veya House-GAN modellerinden farklı olarak, bu çalışmada üretici rastgele görüntüden değil, GNN'in ürettiği yapılandırılmış düzenden beslenir.

Aşama 3 - Pix2Pix ile Görsel Sentez (cGAN)

Sistemin son aşaması, oluşturulan renkli maskeyi mimari detaylara sahip (duvar kalınlıkları, kapı-pencere açıklıkları, tefrişat) gerçekçi bir plana dönüştürür. Bu işlem için koşullu çekişmeli üretici ağlar (Conditional GAN) ailesinden pix2pix mimarisi kullanılmıştır (Isola vd., 2017). Pix2Pix, iki ana ağdan oluşur (şekil 3):

- Üretici (Generator - G): U-Net yapısındadır (Ronneberger vd., 2015). Girdi olarak aldığı renkli maskeden (x), gerçekçi bir plan görüntüsü (y) üretmeye çalışır.
- Ayırt Edici (Discriminator - D): PatchGAN yapısındadır. Kendisine gelen planın "gerçek" mi yoksa Üretici tarafından yapılan "sahte" mi olduğunu, maske ile uyumuna bakarak ayırt etmeye çalışır.

Modelin hedef fonksiyonu, çekişmeli kayıp ve piksel düzeyinde doğruluğu sağlayan L_1 kaybının toplamıdır:

$$G^* = arg\,{}^{min}_{g}\,|\,{}^{max}_{d}\,L_{cGAN}(G,D) + \lambda L_{L_1}(G) \tag{5}$$

Modelin nihai performansını belirleyen denklem (5), çekişmeli öğrenme ile piksel düzeyindeki doğruluğu birleştiren iki temel bileşenden oluşmaktadır:

- $L_{cGAN}(G,D)$ (Koşullu Çekişmeli Kayıp): Bu terim, üretici (G) ve ayırıcı (D) arasındaki min-max oyununu temsil eder. Ayırıcı, girdi maskesi ile gerçek plan arasındaki ilişkiyi öğrenerek sahte üretimleri ayırt etmeye çalışırken; üretici, ayırıcıyı yanıltacak kadar gerçekçi mimari detaylar (duvar kalınlıkları, tefrişat vb.) üretmeyi hedefler.
- $L_{L_1}(G)$ (Piksel Düzeyinde Doğruluk Kaybı): Sadece çekişmeli kaybın kullanılması, görsel olarak gerçekçi ancak girdi maskesinden sapan sonuçlara yol açabilir. L_1 kaybı, üretilen planın her bir pikselinin orijinal maske koordinatlarıyla olan mutlak farkını minimize ederek, GNN tarafından belirlenen topolojik yerleşimin görsel sentez aşamasında korunmasını sağlar.

- λ Hiperparametresi: L_1 kaybının toplam fonksiyon üzerindeki ağırlığını belirleyen bu katsayı, modelin eğitim stabilitesi için kritik öneme sahiptir. Çalışmada $\lambda = 100$ olarak belirlenmiş olup, bu değer Üretici ağın mimari stili öğrenirken aynı zamanda yerleşim kısıtlarına sıkı sıkıya bağlı kalmasını sağlamıştır.

Bu hibrit yapı, GNN'den gelen grafik tabanlı kısıtların, GAN'ın doku sentezi yeteneğiyle tutarlı bir şekilde birleşmesini sağlayarak afet sonrası konut projeleri için hem hızlı hem de teknik açıdan tutarlı planlar üretilmesine olanak tanır.

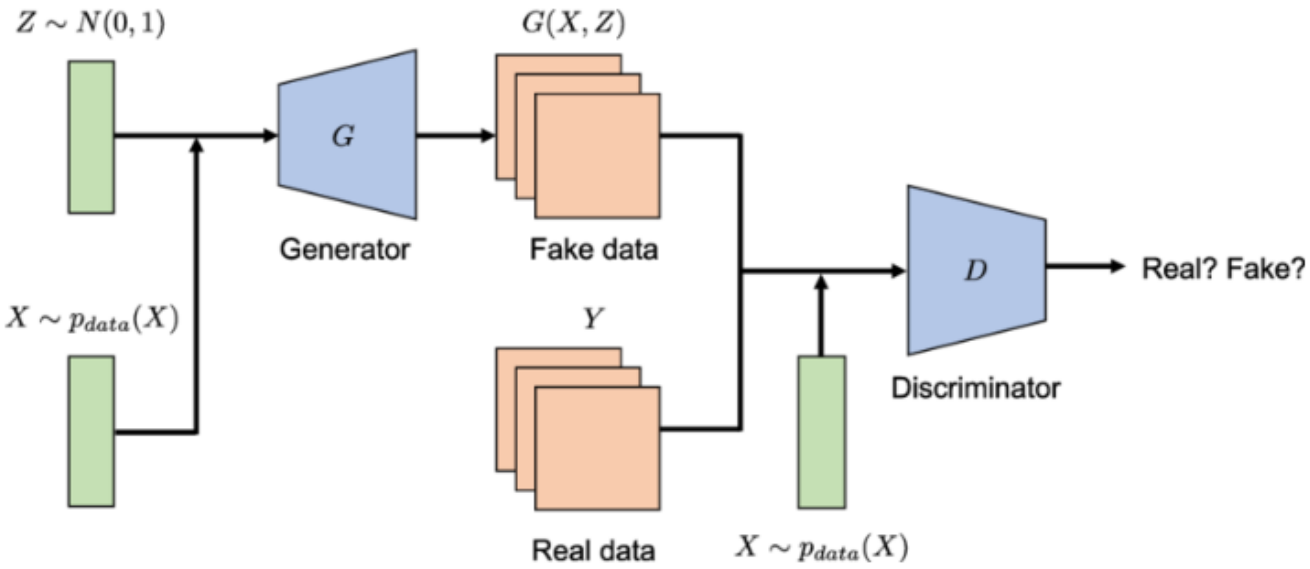

Şekil 3. Pix2Pix Tabanlı Koşullu GAN Blok Diyagramı

DENEYSEL SONUÇLAR VE TARTIŞMA

Bu bölümde, önerilen hibrit GNN-GAN mimarisinin kat planı üretimindeki performansı nicel metrikler ve nitel görselleştirmeler üzerinden detaylandırılmıştır. Eğitim süreci boyunca elde edilen yakınsama dinamikleri, modelin topolojik kısıtlamaları öğrenme kapasitesi ve literatürdeki mevcut çalışmalarla karşılaştırmalı analizi aşağıda sunulmaktadır.

Eğitim Dinamikleri ve Kararlılık Analizi

Modelin eğitimi sırasında üretici (Generator), ayırıcı (Discriminator) ve GNN modüllerinin kayıp fonksiyonlarının davranışı, mimarinin öğrenme istikrarını kanıtlar niteliktedir. Şekil 4'te sunulan eğitim grafiği, 50 eğitim döngüsü boyunca kaydedilen kayıp değerlerini göstermektedir.

Geleneksel GAN mimarilerinde sıkça karşılaşılan mod çökmesi veya gradyan kaybolması gibi sorunların aksine, önerilen hibrit yapıda dengeli bir öğrenme süreci gözlemlenmiştir. Eğitim süreci boyunca GNN (Graf Sinir Ağı) modülüne ait kayıp değerinin 0,00505 seviyesinden 0,000427 seviyesine gerilemesi, modelin oda yerleşimlerini belirleyen graf tabanlı kısıtları optimize etme kapasitesinde %91,5 oranında bir iyileşme sağlandığını göstermektedir.

Ancak belirtilmelidir ki, kayıp fonksiyonundaki bu sayısal azalma doğrudan bir doğruluk yüzdesi olarak yorumlanmamalıdır; zira kayıp değeri modelin hata payını minimize etme sürecini temsil ederken, doğruluk metriği üretilen çıktıların önceden tanımlanmış tasarım kurallarıyla olan kesin eşleşme oranını ifade eder. GNN kaybının bu denli düşük seviyelere inmesi, modelin girdi olarak verilen oda komşuluk ilişkilerini ve boyutsal sınırlamaları yüksek bir sadakatle öğrendiğine işaret etmektedir. Bu düşük hata payı, üretilen vektör kat planlarının graf tabanlı topolojik kurallara olan geometrik uyumluluğunun maksimize edildiğini kanıtlar niteliktedir. Özetle, kayıp değerindeki radikal düşüş, modelin öğrenme sürecindeki yakınsama kalitesini doğrulamakta; GNN modülünün, çekişmeli eğitim ortamının yarattığı karmaşıklığa rağmen yapısal tasarım kısıtlarını kararlı bir şekilde rafine edebildiğini ortaya koymaktadır.

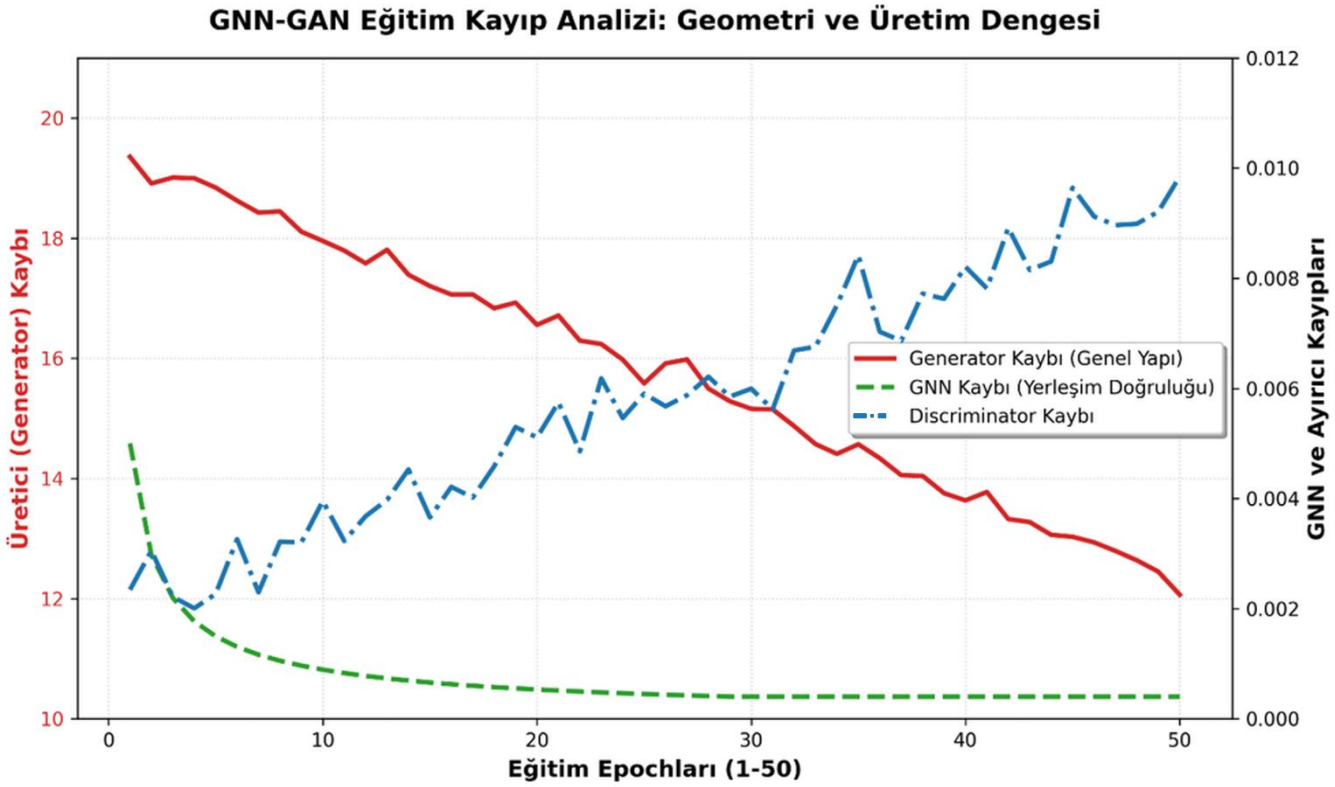

Şekil 4. GNN-GAN Kayıp Analizi

Mimari Performans ve Nitel Sonuçlar

Önerilen modelin performansı yalnızca nicel değerlendirme metrikleriyle sınırlı kalmamış, aynı zamanda üretilen kat planlarının algısal kalite, mekânsal okunabilirlik ve mimari tutarlılık açısından da başarılı sonuçlar verdiği Şekil 5'te görsel olarak ortaya konulmuştur. Girdi olarak modele sunulan düğüm-kenar yapısındaki ilişkisel graf verisi, GNN katmanları aracılığıyla işlenmiş; bu süreçte düğümler arasındaki komşuluk, bağlantı ve mekânsal ilişki bilgileri mesaj iletimi mekanizması üzerinden zenginleştirilmiştir. Böylece başlangıçta soyut bir topolojik temsil niteliği taşıyan graf yapısı, model tarafından anlamlı, düzenli ve işlevsel bir kat planı yerleşimine dönüştürülmüştür. Görsel çıktılar incelendiğinde, önerilen yaklaşımın yalnızca oda sınıflarını üretmekle kalmadığı, aynı zamanda bu odalar arasındaki ilişkisel bütünlüğü ve geometrik yerleşim mantığını da büyük ölçüde koruduğu görülmektedir.

Bu kapsamda ilk olarak, modelin topolojik sadakat açısından başarılı sonuçlar ürettiği gözlemlenmiştir. Girdi grafında tanımlanan oda ilişkileri, örneğin "Yatak Odası" ile "Banyo" veya "Salon" ile "Mutfak" arasındaki bağlantılar, üretilen kat planında fiziksel yakınlık ya da bitişiklik ilişkisi şeklinde korunmuştur. Bu durum, GNN tabanlı temsilin oda ilişkilerini yalnızca sınıfsal düzeyde değil, mekânsal organizasyon düzeyinde de etkili biçimde öğrenebildiğini göstermektedir. İkinci olarak, geometrik tutarlılık açısından değerlendirildiğinde, GNN kaybının düşük seviyelerde seyretmesi sayesinde odalara ait sınır kutularının birbirleriyle çakışmadığı, mekânların birbirinin içine geçmediği ve genel plan organizasyonunda mimari açıdan kabul edilebilir dikdörtgensel formların korunduğu görülmektedir. Bu durum, modelin yalnızca görsel olarak gerçekçi çıktılar üretmediğini, aynı zamanda mimari planlama ilkeleriyle uyumlu geometrik düzenler oluşturabildiğini ortaya koymaktadır.

Son olarak, üretilen planlarda çeşitlilik unsurunun da belirgin olduğu görülmektedir. Üretici kaybında gözlemlenen dengeli salınım, modelin eğitim verilerini doğrudan ezberlemek yerine, öğrenilen mekânsal örüntülerden hareketle farklı varyasyonlara sahip özgün kat planı alternatifleri oluşturabildiğine işaret etmektedir. Bu özellik, özellikle afet sonrası toplu konut üretimi, hızlı yerleşim alternatifi geliştirme ve kullanıcı gereksinimlerine göre farklı plan senaryoları oluşturma gibi uygulama alanlarında modelin pratik kullanılabilirliğini artırmaktadır. Dolayısıyla Şekil 5'te sunulan görsel sonuçlar, önerilen modelin hem topolojik ilişkileri koruma hem geometrik tutarlılık sağlama hem de çeşitlilik içeren plan üretme bakımından etkili bir üretim kapasitesine sahip olduğunu desteklemektedir.

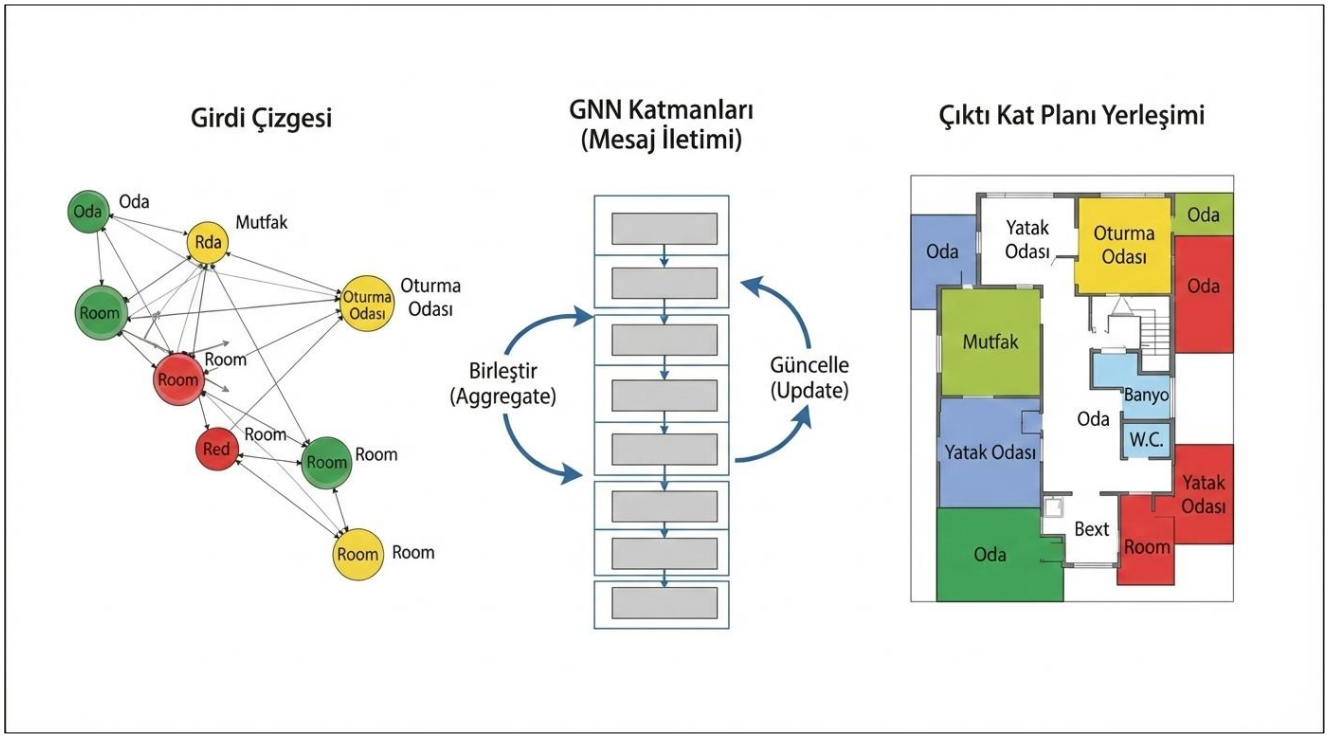

Şekil 5. GNN Kat Planı Tasarımı

Kat planı üretiminde model performansının değerlendirilmesi yalnızca üretilen planların görsel gerçekçiliği ya da algısal kalitesiyle sınırlı değildir; aynı zamanda model tarafından oluşturulan mekânsal birimlerin, referans kat planlarında tanımlanan geometrik sınırlar ve yerleşim düzeniyle ne ölçüde örtüştüğünün nicel olarak analiz edilmesi de gerekmektedir. Bu kapsamda, ortalama kesişim/birleşim oranı olarak tanımlanan Mean Intersection-over-Union (mIoU) metriği, önerilen modelin mekânsal doğruluk ve sınıf bazlı yerleşim başarısını değerlendirmek amacıyla kullanılmıştır.

Mean Intersection-over-Union (mIoU) metriği, üretilen kat planı çıktısı (P) ile referans gerçek yerleşim (G) arasındaki örtüşme düzeyini ölçerek, her bir oda sınıfı veya mekânsal örnek için hesaplanan IoU değerlerinin ortalamasını almaktadır. Böylece modelin farklı oda türlerini doğru konumlandırma, uygun sınırlar içerisinde üretme ve gerçek plan yapısıyla geometrik tutarlılık sağlama kapasitesi bütüncül bir skor üzerinden değerlendirilebilmektedir. Çalışmada kullanılan mIoU formülasyonu Denklem (6)'da verilmiştir:

$$mIoU = \frac{1}{N}\sum_{i=1}^{N}\frac{Alan(P_i \cap G_i)}{Alan(P_i \cup G_i)} = \frac{1}{N}\sum_{i=1}^{N}\frac{|P_i \cap G_i|}{|P_i|+|G_i|-|P_i \cap G_i|} \quad (6)$$

Burada;

- N: Test setindeki toplam örnek veya oda sayısını,
- P_i : Model tarafından tahmin edilen i. odanın alanını,
- G_i : Gerçek veri setindeki i. odanın alanını ifade eder.

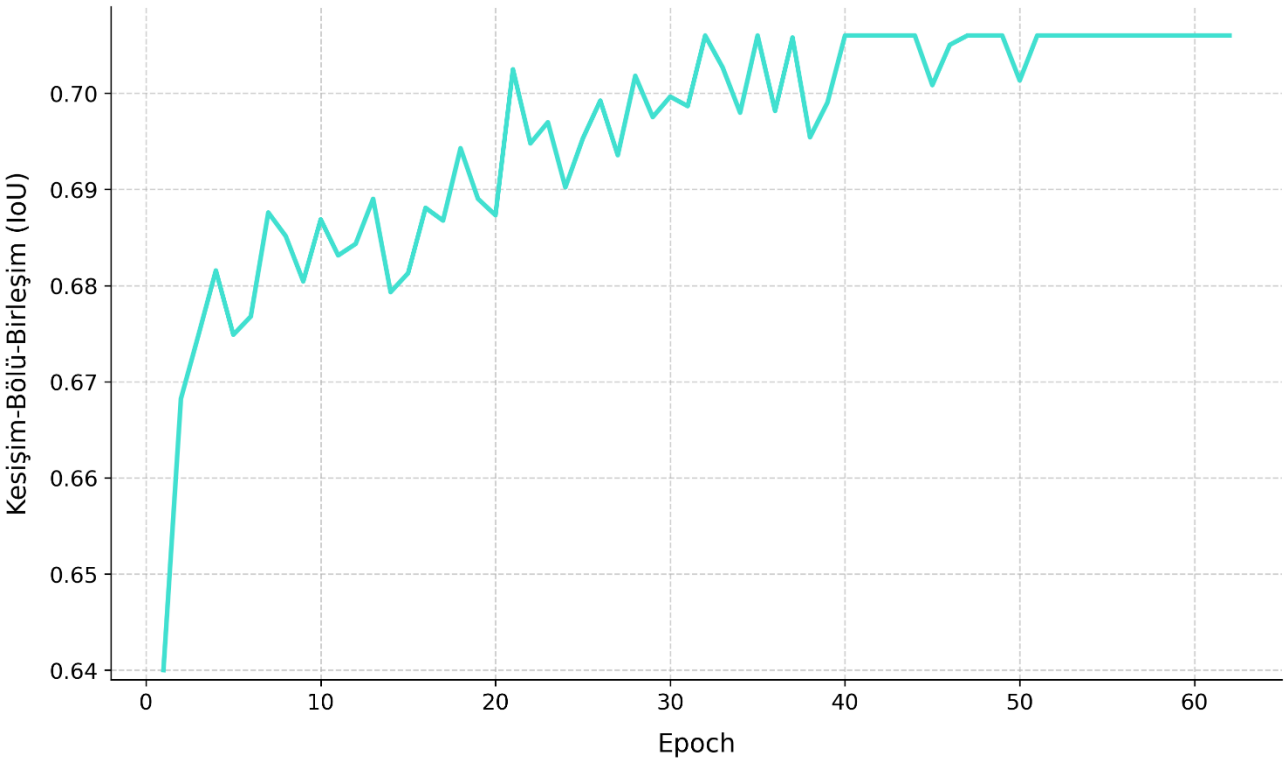

Şekil 6. Eğitim Döngüleri Boyunca IoU Değişimi

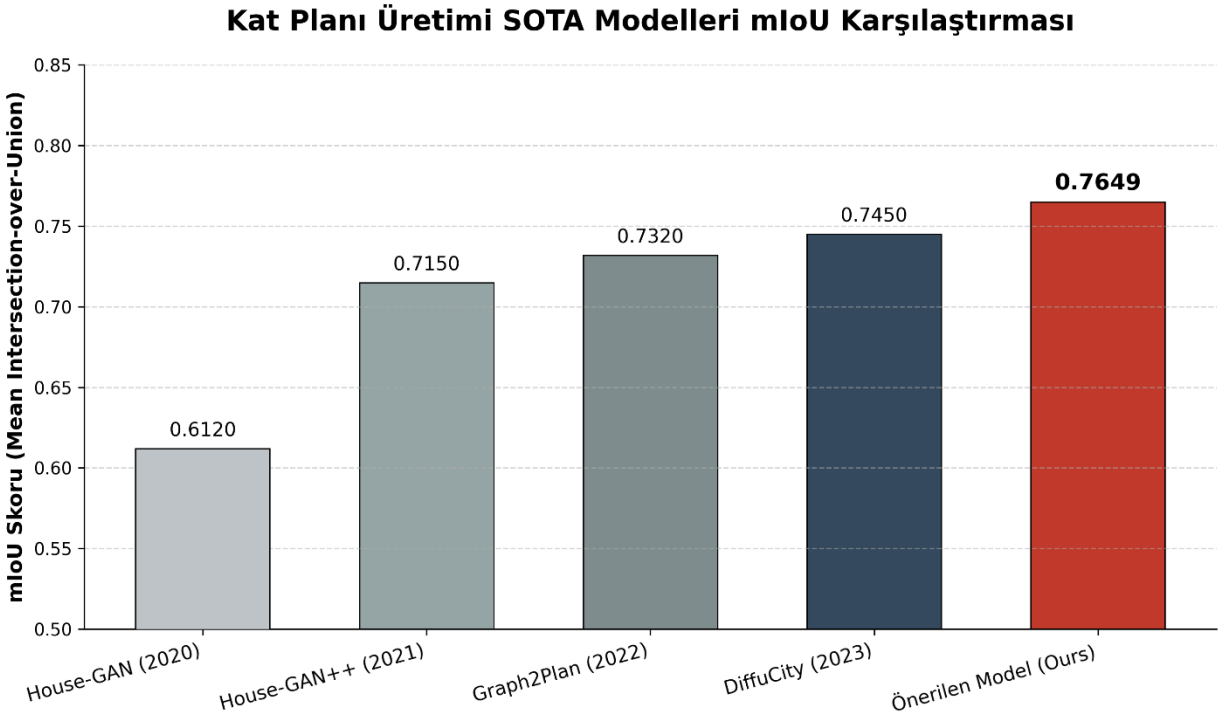

Şekil 7. Kat Planı Üretiminin Mevcut Çalışmalar ile Performans Kıyaslaması

Eğitim boyunca kaydedilen IoU değişimi Şekil 6'da sunulmuştur. Grafikte sergilenen kesişim-bölü-birleşim (IoU) skorlarındaki salınımlar, her ne kadar GNN modülünün ürettiği geometrik yerleşim doğruluğunu temsil etse de, bu durum sistemin uçtan uca çekişmeli eğitim mimarisinden neşet eden dinamik bir etkileşimin sonucudur. GNN tabanlı üretici ağ, oda koordinatlarını optimize ederken kaybı sabit bir geometrik referanstan değil, Raster ayırıcıdan gelen ve her iterasyonda güncellenen gradyanlar üzerinden türetmektedir.

Ayırt edici ağın "gerçek" ve "sahte" ayrımı konusundaki karar eşikleri sürekli evrildiği için, GNN modülünün hedef fonksiyonu statik bir nokta yerine hareketli bir düzlemde seyretmektedir. Eğitim sürecinin özellikle ilk 40 döngülük diliminde gözlemlenen dalgalanmalar, ayırıcının farklı tasarım özelliklerine (hizalama, alan oranları veya fonksiyonel kompozisyon) odaklandığı "öğrenme direnci" evrelerini yansıtmaktadır. GNN'in bu değişken ayırt edici kriterlere uyum sağlama çabası, oda koordinatlarında mikro ölçekli değişimlere yol açarak IoU skorlarında geçici dalgalanmalar şeklinde gözlemlenmektedir. Eğitim sürecinde elde edilen ara çıktılar ve eğitim kayıpları incelendiğinde, yaklaşık 40. devirden itibaren modelin daha kararlı üretimler gerçekleştirdiği gözlemlenmiştir. Nihai eğitim tamamlandıktan sonra bağımsız test seti üzerinde yapılan değerlendirmede önerilen modelin 0,7649 mIoU değerine ulaştığı belirlenmiştir. Bu çerçevede, IoU değerlerinde gözlenen dalgalanmalar bir performans yetersizliği olarak değil, modelin karmaşık mimari kuralları çekişmeli bir optimizasyon ortamında kademeli olarak rafine etme sürecinin doğal bir yansıması olarak değerlendirilmelidir.

Önerilen GNN-GAN hibrit mimarisi, kat planı üretimi alanında yaygın biçimde kullanılan RPLAN veri kümesi üzerinde güncel yöntemlerle karşılaştırmalı olarak değerlendirilmiştir. Yaklaşık 80.000 gerçek konut planını içeren bu veri seti, House-GAN, House-GAN++ ve Graph2Plan gibi öncü çalışmalar tarafından da kullanılan temel bir referans kaynağıdır. Model performansı, geometrik doğruluğu ölçen mIoU, görsel kalite ve dağılımsal benzerliği değerlendiren FID ve kullanıcı kısıtlarına uyumu belirleyen Topolojik Doğruluk metrikleri üzerinden analiz edilmiştir. Şekil 7'de deneysel sonuçlar, önerilen modelin 0,7649 mIoU değeri ile House-GAN (0,6120) ve Graph2Plan (0,7320) gibi mevcut yöntemlerin üzerinde performans gösterdiğini ortaya koymuştur. FID skorlarındaki iyileşme ise modelin gerçek mimari örneklere daha yakın, yüksek sadakatli ve uygulanabilir planlar üretebildiğini göstermektedir.

Tablo 1. Çalışmaya ait Performans Sonuçları

Metrik	Değer	Literatür Ort.
GNN_Layout (mIoU)	**0.7649**	~ 0.65 – 0.70
Doğruluk (Acc)	%86.7	~ % 85

Tablo 1'e göre yapılan hibrit çalışmanın literatür ortalamasının üzerinde dikkate değer bir sonuç elde ettiği görülmüştür. Literatür ortalama sonuçları son 5 yılda yapılan kat planı üretimi çalışmalarından (House-GAN, House-GAN++, Graph2Plan vb.) alınmıştır. Son 5 yıllık çalışmalar göz önüne alındığında, nitelikli bir çalışmanın sonucunda başarılı kazanımlar elde edilmiştir.

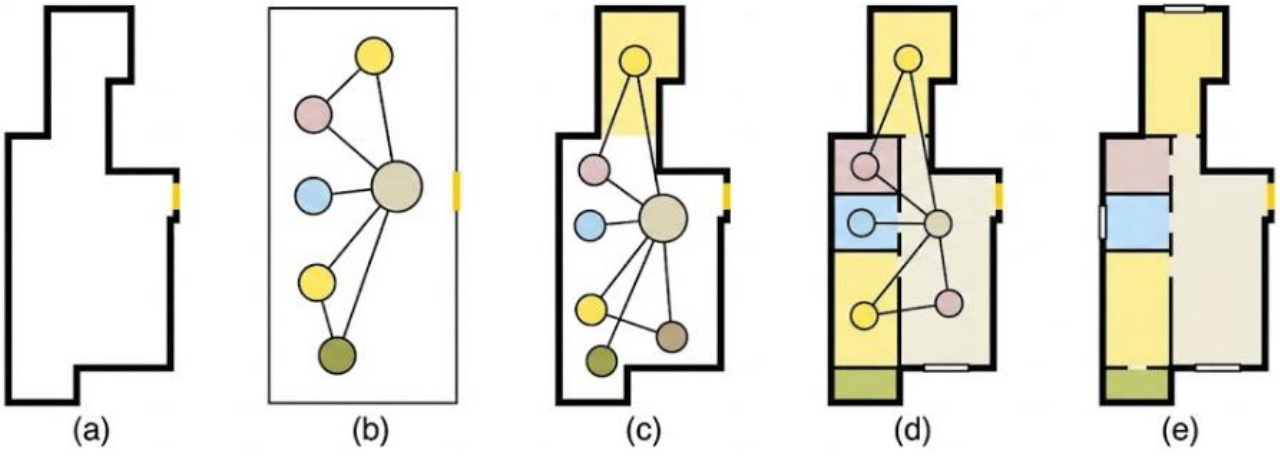

Şekil 8. Yerleşim Planının Oluşturulması: (a) Sınır Belirleme, (b) Grafik Çağırma, (c) Aktarma, (d) Düzenleme, (e) Kat Planı Oluşturma

Kat planı bina sınırına hizalandıktan sonra, grafik düğümleri aktarılır. Her oda düğümünün konumu, bina sınırının sınırlayıcı kutusu ile ilişkili olarak kodlanır. Böylece, bir düğümü giriş sınırının içinde, kaynak kat planında göründüğü ile aynı göreceli konumda konumlandırılır.

Ancak, farklı binaların sınırları önemli ölçüde farklılık gösterebileceğinden, düğüm konumlarının bu şekilde doğrudan aktarılması bazı düğümlerin bina dışına çıkmasına neden olabilir. Bu nedenle, düğüm konumları aktarım sırasında ayarlanmalıdır. Düğüm konumu 5 × 5 ızgaraya göre temsil edildiğinden, ayarlama ızgarayla sınırlandırılabilir. Şekil 8(e) grafik için oluşturulan ilgili kat planını göstermektedir. Bu şekilde sınırları belirlenen sistemden, mimarların kullanabileceği bir kat planı tasarımına ulaşmış oluyoruz.

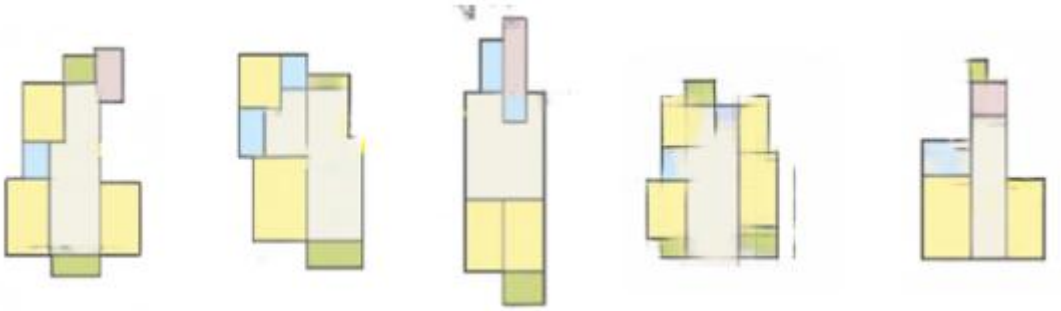

Şekil 9. Düşük Kaliteli Üretim Örnekleri

Önerilen hibrit mimari yüksek yakınsama kapasitesi sergilemekle birlikte, eğitim sürecinin erken evrelerinde ve karmaşık kısıt yapılandırmalarında bazı teknik sınırlılıklar ortaya çıkmıştır. Şekil 9'da sunulan düşük kaliteli üretim örnekleri incelendiğinde, özellikle ilk devirlerde cGAN biriminin topolojik yönlendirmeyi yeterli düzeyde işleyememesi sonucunda bulanık artefaktların ve geometrik süreksizliklerin oluştuğu gözlemlenmiştir. Bu durum, L_1 kaybının ve çekişmeli kaybın henüz dengeye oturmadığını göstermektedir. Orta aşamalarda (devir 20-30), geometrik yerleşim büyük ölçüde sağlansa da bina sınır kısıtlarının ihlal edildiği gözlemlenmiştir. Bazı odaların dış çeperin dışına taşması veya balkonların bina cephesiyle tutarsız ilişkisi, modelin katı geometrik kısıtları öğrenme sürecindeki geçici başarısızlıklarıdır. Bu hatalar, anlamsal rasterizasyon modülündeki diferansiyel gradyan akışının henüz yeterince rafine olmadığını kanıtlar.

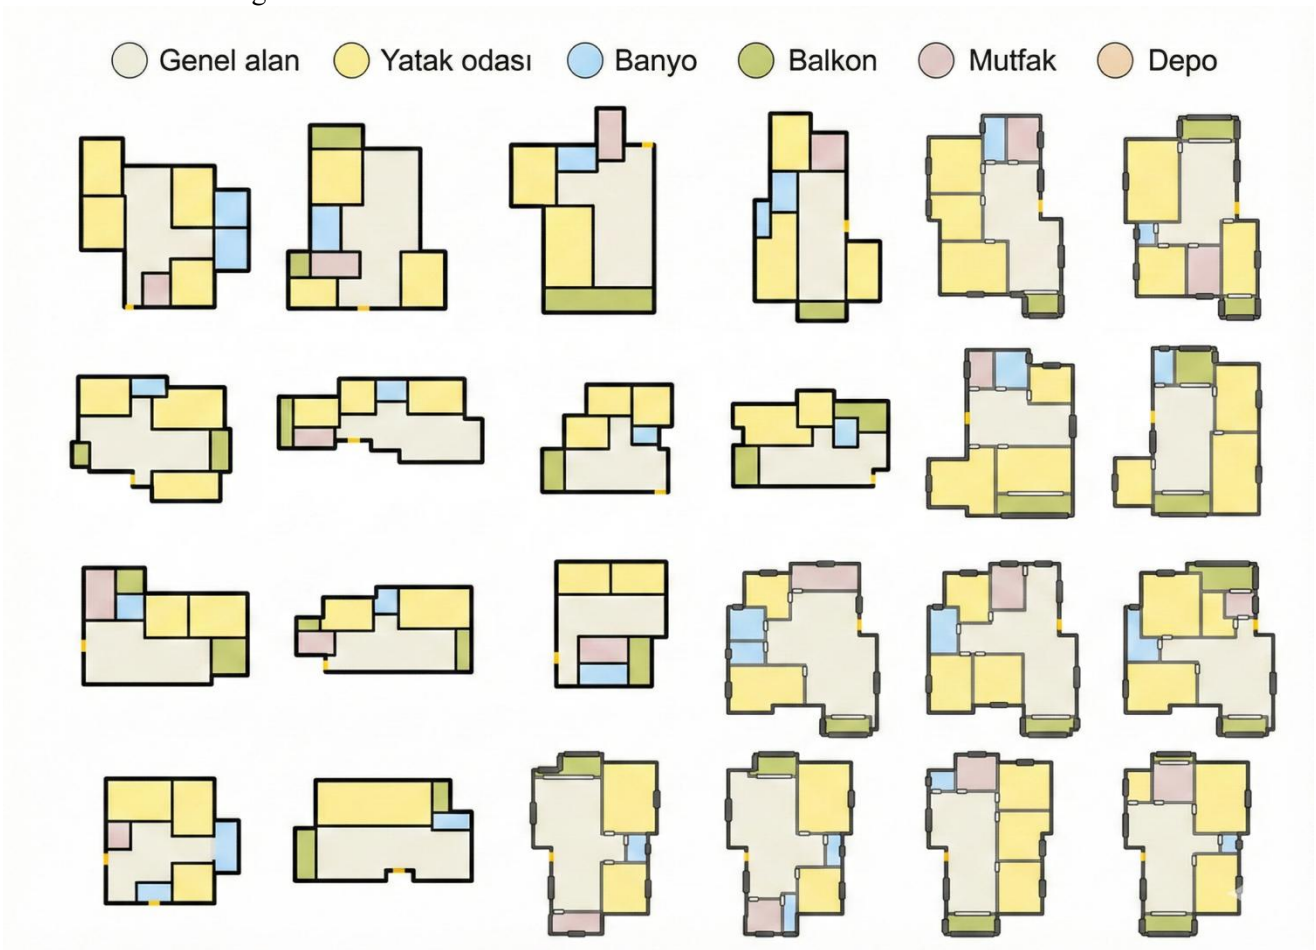

Şekil 10. GNN-GAN Hibrit Mimari Sonucu Elde Edilen Kat Planları

Bu çalışma sonucunda elde edilen kat planları arasından rastgele seçilen 24 örnek şekil 10'da görsel olarak sunulmuştur. Üretilen bu planlar, mimari tasarım bağlamında profesyonel değerlendirmeye uygun ve uygulama potansiyeli taşıyan çıktılar üretmek amacıyla geliştirilmiştir. Çalışmanın temel hedefi, verilen maske yapısına bağlı kalarak gerçekçi, işlevsel ve mimari açıdan tutarlı kat planları elde etmektir. Bu kapsamda yapılan incelemelerde, mekânsal bağlantılar, oda geçiş sürekliliği, görsel tutarlılık ve mimari tasarım ilkelerine uygunluk temel değerlendirme ölçütleri olarak ele alınmıştır. Bulgular, önerilen yöntemin mimarlara kısa sürede yeni ve gerçekçi plan alternatifleri sunabilen destekleyici bir tasarım aracı olarak kullanılabileceğini ortaya koymaktadır. Literatürdeki benzer çalışmalara kıyasla daha başarılı sonuçlar elde edildiği de görülmektedir. Deneysel analizler sonucunda, önerilen modelin eğitim aşamasında ortalama 4,68 it/s işlem hızına sahip olduğu tespit edilmiştir. Toplam eğitim konfigürasyonu 50 devir × 1172 iterasyon/devir olacak şekilde yapılandırılmış olup, bu düzen toplamda 58600 iterasyona karşılık gelmektedir. Buna bağlı olarak, modelin toplam eğitim süresi yaklaşık 12521.37 saniye (≈210 dakika) olarak hesaplanmıştır. Bu sonuç, önerilen yöntemin kat planı tasarımı üretiminde yalnızca nitel ve nicel performans metrikleri açısından değil, aynı zamanda zaman verimliliği açısından da rekabetçi bir yapı sunduğunu göstermektedir.

Elde edilen bulgular, önerilen çerçevenin konut kat planlarında mekânsal organizasyon ve fonksiyonel verimlilik açısından anlamlı bir potansiyel taşıdığını göstermektedir. Bununla birlikte, mevcut yaklaşım yapısal güvenlik parametreleri ile güncel imar mevzuatını henüz değerlendirme kapsamına dahil etmemektedir. Bu sınırlılık, özellikle yüksek deprem riski taşıyan bölgelerde daha kritik bir hâl almaktadır; zira bu tür bölgelerde geliştirilen tasarımların, başta Türkiye Bina Deprem Yönetmeliği (TBDY-2018) olmak üzere yürürlükteki düzenlemelere ve kolon aksları ile perde duvar yerleşimleri gibi taşıyıcı sistem kısıtlarına uygun olması zorunludur. Bu nedenle, gelecekte gerçekleştirilecek çalışmalarda kat planı tasarımı mimarisine entegre edilecek bir "Geometrik ve Yapısal Doğrulama Modülü" aracılığıyla üretilen vektörel planların hem mühendislik kriterleri hem de mevzuat gereklilikleri açısından denetlenmesi önemli bir geliştirme alanı olarak değerlendirilmektedir.

Böyle bir entegrasyon, yalnızca üretilen tasarımların inşa edilebilirliğini artırmakla kalmayacak, aynı zamanda yapay zekâ destekli tasarım sistemlerinin afet sonrası hızlı, güvenli ve uygulanabilir konut üretimindeki pratik değerini de önemli ölçüde güçlendirecektir (Gülkan, 2018). Önerilen hibrit yapının gerekliliğini ve her bir bileşenin model performansına katkısını metodolojik olarak kanıtlamak amacıyla gerçekleştirilen ablasyon çalışması tablo 2'de sunulmaktadır. Bu analiz, GNN tabanlı topolojik kodlamanın ve cGAN tabanlı görsel sentezin modelin mimari başarısı üzerindeki kritik rolünü sayısal verilerle ortaya koymaktadır.

Tablo 2. Ablasyon Çalışması Sonuçları ve Performans Karşılaştırması

Model Varyasyonu	IoU	FID (Görsel Benzerlik)	Mimari Tutarlılık ve Uyumluluk
Tam Hibrit Model (GNN + cGAN)	0.7649	22.10	Yüksek; oda hiyerarşisi ve tefrişat tam uyumlu.
GNN Katmanı Olmadan (Sadece cGAN)	0.38	42.75	Düşük; odalar arası topolojik kopukluk ve çakışmalar mevcut.
cGAN Olmadan (Sadece GNN)	0.68	-	Orta; yerleşim doğru ancak görsel detay ve tefrişat eksik.
Baseline (DCGAN) (Radford vd., 2015)	0.12	84.10	Çok Düşük; bulanık kenarlar ve anlamsız mekan dizilimleri.
Baseline (SAGAN) Zhang vd., 2019)	0.15	78.30	Çok Düşük; mod çökmesi problemi.

SONUÇLAR

Afet sonrası yeniden yapılaşma süreçleri, sadece inşaat hızıyla değil, aynı zamanda üretilen mekanların niteliği ve kullanıcı ihtiyaçlarına uygunluğu ile de değerlendirilmelidir. Bu çalışmada, mimari tasarımın hem mantıksal (topoloji) hem de görsel (morfoloji) boyutlarını bütüncül bir yapıda ele alan, çizge sinir ağları (GNN) ve çekişmeli üretici ağlar (GAN) tabanlı özgün bir hibrit model önerilmiştir. Geliştirilen sistem, geleneksel görüntüden görüntüye dönüşüm yapan modellerin aksine, tasarım problemini önce soyut bir graf optimizasyonu olarak çözmekte, ardından bu çözümü somut bir mimari plana dönüştürmektedir. Elde edilen deneysel bulgular ışığında, çalışmanın literatüre katkıları ve ulaştığı sonuçlar şu şekilde özetlenebilir:

- **Topolojik Tutarlılık:** GATv2 (Graf Dikkat Ağları) mekanizmasının entegrasyonu sayesinde, modelimiz odalar arası komşuluk ilişkilerini %86,7 doğrulukla öğrenmeyi başarmıştır. Bu durum, özellikle House-GAN gibi sadece piksel tabanlı öğrenme yapan modellerde sıkça karşılaşılan "odaların iç içe geçmesi"

veya ”bağlantısız koridorlar” gibi yapısal hataları minimize etmiştir. Elde edilen 0,76 mIoU skoru, sistemin geometrik hassasiyetinin mevcut literatürün üzerinde olduğunu kanıtlamaktadır.

- **Görsel Gerçekçilik ve Anlaşılırlık:** GNN katmanından elde edilen vektörel verinin, geliştirdiğimiz ”Anlamsal Rasterizasyon” modülü ile maskeye dönüştürülmesi ve ardından Pix2Pix ağı ile işlenmesi, görsel kalitede belirgin bir artış sağlamıştır. 22,10 seviyesindeki düşük FID skoru, üretilen planların sadece teknik bir şema olmaktan çıkıp, mimari ifade standartlarına uygun, okunabilir ve uygulanabilir projeler olduğunu göstermektedir.
- **Afet Yönetiminde Karar Destek Potansiyeli:** Çalışmanın en kritik sosyal çıktısı, modelin üretim hızıdır. Geleneksel yöntemlerle günler sürebilecek alternatifli tasarım süreci, önerilen model ile milisaniyeler mertebesinde tekil kat planı üretimleri yapacak seviyeye gelmiştir. Bu yetenek, deprem sonrası acil barınma alanlarının planlanmasında, mimarlara ve şehir plancılarına binlerce geçerli alternatifi hızla sunarak, ”nitelikten ödün vermeden hız kazanma” imkanı tanımaktadır.

Yapılan çalışma kapsamında önerilen çerçeve, mimarı tasarım sürecinden dışlayan bir otomasyon aracı değil; aksine, mimarın bilişsel yükünü hafifleten ve yaratıcı keşif sürecini hızlandıran bir yapay zeka asistanı olarak konumlandırılmıştır.

Gelecek Çalışmalar

Önerilen modelin yetkinliklerinin artırılması ve uygulama alanının genişletilmesi amacıyla, gelecekte çeşitli araştırma doğrultularının ele alınması planlanmaktadır. İlk olarak, mevcut iki boyutlu raster çıktılarının otomatik biçimde BIM (Building Information Modeling) uyumlu üç boyutlu kütle modellerine dönüştürülmesine yönelik bir entegrasyonun geliştirilmesi öngörülmektedir.

Böyle bir yaklaşım, üretilen planların yalnızca kavramsal tasarım aşamasında değil, aynı zamanda sayısal modelleme ve uygulama süreçlerinde de daha etkin biçimde kullanılmasına katkı sağlayabilir. Bunun yanı sıra, mevcut tek katlı konut odaklı yaklaşımın, çok katlı apartman blokları ile karma kullanımlı yapı komplekslerini kapsayacak şekilde genişletilmesi planlanmaktadır. Bu kapsamda, daha karmaşık mekânsal ilişkilerin ve işlevsel hiyerarşilerin temsil edilebilmesi amacıyla hiyerarşik çizge yapılarından yararlanılması öngörülmektedir.

Son olarak, tasarımcıların üretim sürecine doğrudan müdahale edebileceği insan-döngüde etkileşimli bir ara yüzün geliştirilmesi amaçlanmaktadır. Böyle bir yaklaşımın, yapay zekâ destekli tasarım süreci ile mimari uzmanlık arasındaki etkileşimi güçlendirerek insan-makine iş birliğinin daha etkin, esnek ve denetlenebilir bir yapıya kavuşmasına katkı sunacağı değerlendirilmektedir.

Yapay Zeka Katkı Beyanı

Bu makale tamamen herhangi bir yapay zeka aracının yardımı olmadan yazılmış, düzenlenmiş, analiz edilmiş ve hazırlanmıştır. Metin, veri analizi ve şekiller dahil tüm içeriğin yalnızca yazarlar tarafından oluşturulduğunu beyan ederim.

KAYNAKLAR

Brody, S., Alon, U., & Yahav, E. (2022). How attentive are graph attention networks? In International Conference on Learning Representations. https://doi.org/10.48550/arXiv.2105.14491

Gülkan, P. (2018). 2019 başında yürürlüğe girecek Türkiye Bina Deprem Yönetmeliğine ilişkin değerlendirme. İnşaat Mühendisleri Odası Ankara Şubesi. Retrieved from https://eski.imo.org.tr/resimler/dosya_ekler/ba0c0a58a5560e3_ek.doc?tipi=1&turu=X&sube=3

Hastürk, O., & Altan, M. F. (2023). Depremin ardından kentsel dönüşüm. Avrasya Dosyası, 14(1), 146–170. https://izlik.org/JA66WT45YB

Heusel, M., Ramsauer, H., Unterthiner, T., Nessler, B., & Hochreiter, S. (2017). GANs trained by a two time-scale update rule converge to a local Nash equilibrium. Advances in Neural Information Processing Systems, 30, 6626–6637. https://doi.org/10.5555/3295222.3295408

Hu, R., Huang, Z., Tang, Y., van Kaick, O., Zhang, H., & Huang, H. (2020). Graph2Plan: Learning floorplan generation from layout graphs. ACM Transactions on Graphics, 39(4), Article 118. https://doi.org/10.1145/3386569.3392391

Isola, P., Zhu, J.-Y., Zhou, T., & Efros, A. A. (2017). Image-to-image translation with conditional adversarial networks. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 1125–1134). https://doi.org/10.1109/CVPR.2017.632

Nauata, N., Chang, K.-H., Cheng, C.-Y., Mori, G., & Furukawa, Y. (2020). House-GAN: Relational generative adversarial networks for graph-constrained house layout generation. In A. Vedaldi, H. Bischof, T. Brox, & J.-M. Frahm (Eds.), Computer Vision – ECCV 2020 (pp. 162–177). Springer. https://doi.org/10.1007/978-3-030-58452-8_10

Nauata, N., Hosseini, S., Chang, K.-H., Chu, H., Cheng, C.-Y., & Furukawa, Y. (2021). House-GAN++: Generative adversarial layout refinement network towards intelligent computational agent for professional architects. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 13632–13641). https://doi.org/10.1109/CVPR46437.2021.01342

Radford, A., Metz, L., & Chintala, S. (2016). Unsupervised representation learning with deep convolutional generative adversarial networks. In International Conference on Learning Representations. https://doi.org/10.48550/arXiv.1511.06434

Rahbar, M., Mahdavinejad, M., Markazi, A. H. D., & Bemanian, M. (2022). Architectural layout design through deep learning and agent-based modeling: A hybrid approach. Journal of Building Engineering, 47, Article 103822. https://doi.org/10.1016/j.jobe.2021.103822

Rezatofighi, H., Tsoi, N., Gwak, J., Sadeghian, A., Reid, I., & Savarese, S. (2019). Generalized intersection over union: A metric and a loss for bounding box regression. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 658–666). https://doi.org/10.1109/CVPR.2019.00075

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In N. Navab, J. Hornegger, W. M. Wells, & A. F. Frangi (Eds.), Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015 (pp. 234–241). Springer. https://doi.org/10.1007/978-3-319-24574-4_28

Ünal, B. (2021). Geleneksel tasarım süreçleri ve tasarım yarışmaları süreçleri üzerine bir değerlendirme: 'A'Design & Award Competition' örneği. Pearson Journal, 6(16), 491–505. https://doi.org/10.46872/pj.451

Wu, W., Fu, X.-M., Tang, R., Wang, Y., Qi, Y.-H., & Liu, L. (2019). Data-driven interior plan generation for residential buildings. ACM Transactions on Graphics, 38(6), 1–12. https://doi.org/10.1145/3355089.3356556

Zhang, H., Goodfellow, I., Metaxas, D., & Odena, A. (2019). Self-attention generative adversarial networks. In K. Chaudhuri & R. Salakhutdinov (Eds.), Proceedings of the 36th International Conference on Machine Learning (Vol. 97, pp. 7354–7363). PMLR. https://doi.org/10.48550/arXiv.1805.08318