

GRJointNET: 3B Eksik Nokta Bulutları İçin Sinerjistik Tamamlama ve Parça Bölütleme

GRJointNET: Synergistic Completion and Part Segmentation on 3D Incomplete Point Clouds

Yiğit Gürses, Melisa Taşpınar, Mahmut Yurt, Sedat Özer
Bilkent Üniversitesi

Özetçe —Üç boyutlu (3B) nokta bulutları üzerinde bölütleme yapmak, otonom sistemler için önemli ve gerekli bir işlemdir. Bölütleme algoritmalarının başarısı, üzerinde işlem yapılan nokta bulutlarının niteliğine (çözünürlük, tamlık vb.) bağlıdır. Dolayısıyla, nokta bulutundaki mevcut eksiklikler, nokta bulutu tabanlı uygulamaların başarısını düşürmektedir. Bu konuda, güncel bir çalışma olan GRNet, eksik nokta bulutlarını tamamlamaya odaklanan başarılı bir algoritmadır, ancak bölütleme yeteneği yoktur. Biz bu çalışmada, GRNet üzerine geliştirdiğimiz derin öğrenme tabanlı GRJointNet algoritmasını sunmaktayız. GRJointNet hem bir nokta bulutundaki eksik noktaları tamamlamakta, hem de onun yapamadığı parça bölütlemesini de yapmaktadır. Bu işlemler elde ettikleri verileri birbirlerini desteklemek için kullanmaktadır. ShapeNet-Part veri kümesinde yapılmış deneylerimiz, GRJointNet algoritmasının nokta bulutu tamamlamada GRNet’den daha başarılı olduğunu göstermektedir. Aynı zamanda, GRNet bölütleme yapamazken, GRJointNet bu özelliği de kazanmıştır. Dolayısıyla bu çalışma nokta bulutlarının 3B bilgisayarlı görüde kullanışlılığını arttırmak adına umut vadetmektedir.

Anahtar Kelimeler—Nokta Bulutları, Tamamlama, Bölütleme.

Abstract—Segmentation of three-dimensional (3D) point clouds is an important task for autonomous systems. However, success of segmentation algorithms depends greatly on the quality of the underlying point clouds (resolution, completeness etc.). In particular, incomplete point clouds might reduce a downstream model’s performance. GRNet is proposed as a novel and recent deep solution to complete incomplete point clouds, but it is not capable of part segmentation. On the other hand, our proposed solution, GRJointNet, is an architecture that can perform joint completion and segmentation on point clouds as a successor of GRNet. Features extracted for the two tasks are also utilized by each other to increase the overall performance. We evaluated our proposed network on the ShapeNet-Part dataset and compared its performance to GRNet. Our results demonstrate GRJointNet outperforms GRNet on point completion. It should also be noted that GRNet is not capable of segmentation while GRJointNet is. This study therefore holds a promise to enhance practicality and utility of point clouds for 3D vision for autonomous systems.

Keywords—Point Clouds, Completion, Segmentation.

I. GİRİŞ


Görüntü elde etme teknolojilerindeki yeni gelişmeler ve 3B sensörlerin yaygın kullanımıyla, 3B nesne işleme algoritmalarına olan talep de artmıştır. Bu amaçla son zamanlarda çeşitli algoritmalar geliştirilmiştir [1]. Bu alanlardan birisi de

3B tabanlı nokta bulutlarının işlenmesidir. 3B nesneler, yaygın olarak 3B nokta bulutları ile gösterilir, zira nokta bulutları aynı sahneyi önemli ölçüde daha düşük veri boyutu ile etkili bir şekilde temsil ederek tanımlayabilir [2]. Fakat, sensörlerle elde edilen 3B nokta bulutları, ışık yansımaları, ortamdaki nesnelerin birbirinin önüne gelmesi, sensör çözünürlüğü ve görüntüleme açısı gibi farklı faktörlerden dolayı eksik olmaya meyillidir [1], [2]. Eksik nokta bulutları üzerinde çalışmak durumunda kalan algoritmaların performansları düşük kalmakta ve bu nedenle de, bu algoritmaların bir ön işleme olarak tamamlanmalarına ihtiyaç duyulmaktadır. Bu amaçla, son zamanlarda önerilen derin öğrenme tabanlı algoritmalarından birisi de GRNet’tir [1]. Bu tip 3B nokta bulutu tamamlayan algoritmaların sonuçları, giriş verisi olarak 3B segmentasyon yapan başka algoritmalara verilebilir. Ancak bu tip çok aşama gerektiren işlemler hem daha maliyetlidir hem de daha uzun zaman almaktadır. O nedenle tercih edilebilecek, alternatif bir yöntem ise hem nokta bulutu tamamlama yapan kısmın, hem de segmentasyon yapan kısmın aynı derin öğrenme tabanlı ağ tarafından aynı anda, uçtan uca yapılmasıdır. Bu çalışmada, 3B eksik nokta bulutlarının eş zamanlı tamamlanma ve bölütlenmesini amaçlayan yeni bir mimari sunmaktayız ve sunduğumuz mimariyi GRJointNET olarak adlandırmaktayız. GRJointNET, 3B evrişimli katmanlardan, çok katmanlı algılayıcılardan (MLP), üç türevlenebilir ızgaralama katmanından (ızgaralama, ters ızgaralama ve kübik özellik örnekleme) ve özgün bir sinerjik özellik toplanması yönteminden yararlanmaktadır (Bknz. Sekil 1). Bu yöntemde, girdi olarak verilen nokta bulutlarındaki eksik bölgeler tamamlanırken, aynı zamanda oluşturulan nokta bulutlarındaki noktalar da kümelenip bölütlenmektedir.

Sunduğumuz yöntemin içerdiği yenilikler şu şekilde özetlenebilir: (1) GRNet tamamlamanın yanında bölütleme yapamaz iken, GRJointNet hem bölütleme hem tamamlamayı sinerjik bir şekilde yapabilmektedir. (2) GRJointNet, GRNet’ten farklı olarak, son katmanda eksik nokta tamamlaması yaparken, bölütleme tahminlerini de kullanır. (3) Shape-Net Part dataseti üzerinde sonuçlarını karşılaştırmalı olarak gösterir.

II. İLGİLİ ÇALIŞMALAR

Birçok yeni çalışma, 3B bir nesneyi bölütleyebilmek ve tamamlayabilmek amaçlı çeşitli derin nöral ağ modelleri ortaya sunmuştur [5]–[8]. Bu alanda nokta bulutu tabanlı araştırmalara öncülük eden çalışmalardan birisi PointNet’dir [5]. Her ne kadar bu tip, 3B nokta uzayı tabanlı modeller bölütleme görevinde belirli bir seviyeye kadar başarı göstermiş olsalar da, performansları nokta bulutundaki noktaların bütünlüğünün



Şekil 1: a) Temel alınan yöntemin (GRNet [1]) mimarisi ve b) sunduğumuz yöntemin (GRJointNet) mimarisi gösterilmektedir. GRJointNet, girdi olarak tamamlanmamış bir nokta bulutunu alır ve bu bulut verisini, iki farklı dal üzerinden (tamamlama ve bölütleme) işleyerek tamamlanmış ve bölütlenmiş bir nokta bulutu üretir.

ne kadar olduğuna dayanır [2]. Ancak, 3B nokta bulutları, önceden de belirtildiği gibi birçok sebepten dolayı eksik olmaya meyillidir. Diğer bir deyişle, 3B nokta bulutları üzerinde çalışırken bölütleme gibi uygulamalarda, öncelikle eksik nokta bulutlarını tamamlamak, ayrı bir görev olarak değerlendirilir.

Son zamanlarda yapılan ve birbirinden bağımsız olan birçok çalışma, derin nöral mimariler kullanarak eksik nokta bulutlarının tamamlanabileceğini başarıyla göstermiştir [1]–[4]. Bu çalışmalardan bazıları, ham nokta bulutları üzerinde çok-katmanlı-algılayıcılar (MLP) kullanarak tamamlama işlemini gerçekleştirmektedir [2], fakat bu tip MLP tabanlı yöntemler, MLP’lerin bağlam bilinçli olmayan mimarilerinden dolayı noktalar arasındaki uzaysal korelasyonları anlamakta zorluk çekerler. Bu sebeple, daha güncel ve yeni olan çalışmalar, nokta bulutlarını vokselize ederek 3B CNN’lerden (evrişimli nöral ağ) yararlanmayı amaçlamışlardır. Ancak bu tip çalışmalarda, vokselleştirme sürecindeki geometrik bilgi kaybından kaynaklı performans düşüşleri görülebilmektedir [9]–[11]. Yakın zamanda sunulan bir yaklaşım olan GRNet [1], geometrik ve yapısal bilgiyi korumak amaçlı, nokta bulutlarını orta mimaride 3B ızgaralarla temsil eden bir model sunmaktadır. GRNet amacıyla göreceli olarak başarılı olsa da, hem tamamlama hem de bölütleme fonksiyonlarını aynı anda yerine getiren uçtan uca bir mimariye sahip değildir.

Bu bildiride, GRNet yapısını geliştirerek, hem tamamlama hem de bölütleme fonksiyonlarını aynı anda yerine getiren uçtan uca bir mimari sunmaktayız ve mimarimizi GRJointNET olarak adlandırmaktayız. GRJointNET, GRNet tabanlı olup, onu geliştirmek amaçlı tasarlanmış ve GRNET yapısına bölütleme fonksiyonunu da kazandırmıştır.

III. ÖNERİLEN MİMARİ


Sunduğumuz yöntemin (GRJointNet) mimarisi Şekil 1’de verilmiştir. Bu mimaride, beş temel bileşen bulunmaktadır. Bu beş bileşen sırasıyla, ileri ızgaralama, ters ızgaralama, kübik özellik örnekleme, 3B evrişimli sinir ağı ve çok katmanlı algılayıcı olarak isimlendirilmiştir.

1) *İleri İzgaralama*: 2B ve 3B evrişimlerini, düzensiz nokta bulutları üzerinde direkt olarak uygulamak verimli değildir, o nedenle öncelikle verinin 3B ızgara (grid) yapısı üzerine yerleştirilmesi tercih edilen bir yöntemdir. Bu yöntemi vokselleştirme olarak tanımlayabiliriz. Vokselleştirme işleminden sonra, 2B ve 3B evrişim operasyonlarını direkt olarak kullanabiliriz. Fakat, bu süreç tersinir olmadığından vokselleştirme yöntemleri doğaları gereği geometrik veya anlamsal bilgi kaybına yol açarlar. Dolayısıyla biz, bu çalışmada, düzensiz 3B nokta bulutlarını düzenli 3B ızgaralara çevirmek amacıyla bu çalışmaya türevlenebilir bir geri ızgaralama katmanı dahil ettik. Hedeflenen 3B ızgara, girdi olarak verilen tüm nokta bulutunu kapsayan ve düzenli bir küp şeklini alan, N^3 adet ayrı köşeden oluşmaktadır (burada N ızgaranın bir boyut üzerindeki köşe sayısını belirtmektedir). Bu ızgaradaki her bir hücre, her biri bir ağırlık değerine sahip olan 8 farklı köşe içerir. Toplam köşe sayısı N^3 ’tür ve $V = \{v_i\}_{i=1}^{N^3}$, $W = \{w_i\}_{i=1}^{N^3}$, $v_i = (x_i, y_i, z_i)$ olarak tanımlanırlar. Burada W hücre değerlerini tutarken, V kümesi de ilgili hücrelerin köşe koordinatlarını saklamaktadır. v_i i indeksli 3B noktayı tanımlar. Eğer nokta bulutu nesnesinden bir nokta 8 köşeli bir hücre içerisinde yer alırsa, bu nokta için köşelerin ağırlıkları şu şekilde belirlenir:

$$w_i^p = (1 - |x_i^v - x|)(1 - |y_i^v - y|)(1 - |z_i^v - z|) \quad (1)$$

burada x nokta bulutundan gelen bir örneğin x-eksenindeki izdüşümünü, y y-eksenindeki izdüşümünü, z ise z-eksenindeki izdüşümünü belirtmektedir. x_i^v , y_i^v , z_i^v ise ilgili noktanın komşu olduğu bir köşeyi tanımlar. Köşenin son ağırlığı w_i sonrasında şu şekilde hesaplanır: $w_i = \sum_{p \in N(v_i)} \frac{w_i^p}{|N(v_i)|}$, burada $N(v_i)$, v_i köşesine komşu noktaların kümesidir. Bir p noktasının v_i ’ye komşu olma koşulu $|x_i^v - x| < 1$, $|y_i^v - y| < 1$, $|z_i^v - z| < 1$ olarak yazılabilir.

2) *Ters İzgaralama*: Ters ızgaralama, verilen 3B bir ızgaradan $P^s = \{p_i^s\}_{i=1}^m$ seyrek nokta bulutunu yaratma işlemidir. p_i^s noktaları şu şekilde hesaplanır: $p_i^s = (\sum_{j \in N(v_i)} w_j v_j) / (\sum_{j \in N(v_i)} w_j)$, burada $N(v_i)$, p_i^s noktasına komşu olan köşelerin kümesini; w_j , $N(v_i)$ ’deki v_j köşesinin



Şekil 2: GRJointNet ile GRNet 3B CNN yapılarının karşılaştırılması. Soldaki şekil GRJointNet'te kullanılan 3B CNN yapısını, sağdaki şekil GRNet'te kullanılan 3B CNN yapısını göstermektedir.

ağırlığını; v_j ise bu köşenin uzaydaki pozisyonunu göstermektedir.

3) **Küçük Özellik Örneklemesi:** 3B nokta bulutu üzerinde çalışan klasik MLP bazlı yöntemler [5], yerel uzaysal özellikleri hesaba katmadıkları için, komşu noktalar arasında global ve yerel bilgi kaybından mağdur olurlar. Bu sorunu gidermek için, sunduğumuz yöntemde, kübik özellik örneklemesi tekniğini kullanmaktayız. Bu yöntem, seyrek nokta bulutundaki her nokta için ızgaradan ilgili özellikleri toplar. Kısacası, p_i noktasını çevreleyen sekiz komşu köşenin özellikleri birleştirilir ve o noktaya göre MLP'nin girdisi (o_p^i) şu şekilde oluşturulur: $o_p^i = [p_i, f_1^i, f_2^i, \dots, f_8^i]$. Burada o_p^i MLP'nin p_i noktasına göre alınan girdisini, f_j^i ise 3B CNN'den p_i 'yi çevreleyen köşelerin özellik haritasını göstermektedir. Dikkat ediniz ki kübik özellik örneklemesi, 3B CNN'deki ilk üç transpoze edilmiş evrişimli katmandan özellik haritaları alır ve nokta başına her kanaldan 8 özellik örnekler.

4) **3B Evrişimli Sinir Ağı:** Hem GRNet hem de GRJointNet birer 3B CNN yapısı içermektedirler. Bu iki 3B CNN yapısı arasındaki fark, Şekil 2 üzerinde karşılaştırmalı olarak görülebilir. Sunulan yaklaşımdaki 3B CNN, bir gizyazar-gizçözer yapısı içermektedir. Gizyazar, her birinde ikili dolgulama ve toptan normalleştirme yapılan, çekirdek büyüklüğü 4 olan bir maksimum örneklem katmanı ve bir sıran ReLU etkinliğini içeren 4 adet 3B evrişimli katmandan meydana gelir. Onu, tamamen bağlanmış katmanlar takip eder (kullanılan katmanların boyutu 1024 ve 2048'dir). Gizçözer ise, her birinde ikili dolgulama, tekil adım kaydırma ve toptan normalleştirme yapılan ve bir sıran ReLU etkinliğini içeren 4 adet transpoze edilmiş evrişimli katmandan oluşur. 3B CNN'in genel formülasyonu şu şekilde tanımlanmıştır: $W' = 3DCNN(W)$; burada W eksik nokta bulutunun ileri ızgaralamadan çıktısıdır ve W' onun tamamlanmış halidir. Zira 3B CNN tamamlanmamış nokta bulutundaki eksik olan noktaları tamamlar.

5) **Çok Katmanlı Algılayıcı (MLP):** Sunulan yöntemdeki MLP mimarisi, en sondaki tamamlanmış ve bölüntülenmiş nokta bulutu ile seyrek nokta bulutu arasındaki sapmayı kullanarak seyrek nokta bulutundan ince detayları kurtarmayı amaçlar. MLP mimarisi, sırasıyla boyutları 12, 1000, 2000 ve 3584 olan dört adet tamamen bağlı (FC) katmanı kapsar.

6) **Eşleştirme Algoritması:** GRJointNet'in başarısının, GRNet'inkinden yüksek olabilmesi, bölütleme ızgarasını oluşturan ters evrişimli ağların da iyi öğrenebilmesine bağlıdır. Bu

amaçla, seyrek nokta bulutunu bölütledik ve bu bölütlemeyi çapraz entropi yitimi ile geri yayılım içinde kullandık. Eşleştirme algoritması, şu şekilde çalışır: $c_x^p = N(p_x + 1)$, $c_y^p = N(p_y + 1)$, $c_z^p = N(p_z + 1)$, ve $b^p = {}_nBI_n[c_x^p, c_y^p, c_z^p]$. Burada c_x^p, c_y^p ve c_z^p , p noktasının N^3 boyutundaki bir bölütleme ızgarasında içine düşeceği hücrenin indekslerini belirtmektedir. BI_n , elde edilen n bölütleme ızgarasının n 'incisini belirtir ve n numaralı bölütleme kategorisinin uzaysal olasılıklarını bulundurmaktadır. b^p ise p noktasına eşleştirme algoritması sonunda atanan bölütleme kategorisini belirtir.

A. Yitim Fonksiyonları

Gerçek referans değer ile tamamlanmış/bölütlenmiş nesneler arasındaki *Chamfer mesafesi* şu şekilde tanımlanır:

$$L_{CD} = \frac{1}{n_G} \sum_{g \in G} \min_{m \in M} \|g - m\|_2^2 + \frac{1}{n_M} \sum_{m \in M} \min_{g \in G} \|g - m\|_2^2 \quad (2)$$

G 'deki her nokta için, L_2 mesafesine dayanarak M 'deki en yakın nokta hesaplanır. Bu L_2 mesafesine yitimde yer verilir. Aynı süreç M 'deki her nokta için tekrarlanır. Bölütleme yitimi için *kategorik çapraz entropi* kullanıldı.

$$L_{CE} = - \sum_i t_i \log \left(\frac{e^{s_i}}{\sum_j e^{s_j}} \right) \quad (3)$$


Tamamlanmış nokta bulutları ilk oluşturulduklarında bölütleme için referans değerlerine sahip olmadıklarından; referans değerleri orijinal, tam ve bölütleme etiketlerine sahip olan nokta bulutlarından hesaplanır. Oluşturulan bulutlardaki her nokta, tam buluttaki kendisine en yakın noktanın bölütlenme etiketine atanır. Sonrasında, hem seyrek hem yoğun nokta bulutlarında bölütleme tahminleri, çapraz entropi ile oluşturduğumuz referans değerleriyle karşılaştırılır. GRNet'i eğitmek için, sadece yitim fonksiyonu olarak kullanılan Chamfer mesafesini kullanmak, tahmin edilen noktaların nesnenin geometrisine uyup uymadığını kontrol etmekte yetersiz kalmaktadır. Bu sebeple yalnızca Chamfer mesafesi kullanan ağlar, girdi ve çıktı noktalarının mesafesini en aza indiren bir ortalama şekil vermeye eğilimlidir. Bu da söz konusu nesnenin detaylarına dair bir bilgi kaybına neden olur. Nokta bulutları sıralanmamış olduklarından üzerlerinde direk olarak L_1 / L_2 yitim fonksiyonu veya çapraz entropi uygulamak zorlaşır; ancak, GRNet [1] tarafından sunulan ızgaralama yöntemi, bu problemin üstesinden, sıralanmamış 3B nokta bulutlarını 3B ızgaralara çevirerek gelir. Dolayısıyla, GRNet *İzgaralama Yitim Fonksiyonu* adı verilen bir yitim fonksiyonu sunar. Bu yitim fonksiyonu, 3B ızgaralara ait iki değer kümesinin arasındaki L_1 mesafesi olarak tanımlanır. Başka bir deyişle:

$$L_{Izgaralama}(W^{tahmin}, W^{gt}) = \frac{1}{N^3_G} \sum \|W^{tahmin} - W^{gt}\|. \quad (4)$$

Burada, $W^{tahmin}, W^{gt} \in R^{N^3_G}$ iken, $G_{tahmin} = \langle V^{tahmin}, W^{tahmin} \rangle$ ve $G_{gt} = \langle V^{gt}, W^{gt} \rangle$ olarak tanımlanmış bir şekilde, gerçek referans değeri (G_{gt}) olan ve tahmin edilen (G_{tahmin}) nokta bulutlarına ızgaralama uygulanarak elde edilen 3B ızgaralardır. Ayrıca, N_G , 3B ızgaraların çözünürlüğüne denk gelir. En son kullanılan yitim fonksiyonu (L) ise, şu şekilde tanımlıdır: $L = L_{CD} + L_{CE} + L_{Izgaralama}$.

IV. DENEYLER

GRNet ve GRJointNet performansları, ShapeNet-Part veri kümesi [12] üzerinde seçilen dört kategori için karşılaştırılmıştır. GRNet tamamlama yapmak üzerine tasarlanmış bir



Şekil 3: Önerilen GRJointNet modelinin uçak, araba, sandalye ve tabanca kategorileri için ikişer örnek üzerinde eksik nokta bulutu tamamlama sonuçları, eksik, seyrek ve yoğun nokta bulutları için gösterilmiştir.

algoritma olduğu için, deneylerimizi hem tamamlama hem de bölütleme amaçlı olacak şekilde ayrı ayrı gerçekleştirdik. Tüm algoritmalar 50 devir üzerinden eğitildi. Her iki ağ üzerinde de Adam optimizasyon tekniği kullanıldı. Tamamlama deneylerinde ShapeNet-Part veri kümesinden toplamda 11705 adet eğitim örneği, ve 2768 adet test örneği kullanılmıştır. Sonuçlar, Tablo I üzerinde rastgele seçilen dört sınıf üzerinden karşılaştırılmıştır. Tabloda, karşılaştırma birimi olarak ortalama Chamfer mesafesi kullanılmıştır; daha küçük değerler, daha iyi sonuçlar anlamına gelmektedir. Parça bölütleme deneyinde ise GRNet'in bölütleme özelliğinin olmamasından dolayı, sonuçlarımızı sadece GRJointNet için görsel olarak dört farklı kategoriden ikişer örnek kullanarak Şekil 3 üzerinde göstermekteyiz. Şekil üzerinde, ilk satır referans resimlerini, ikinci satır girdi olan eksik nokta bulutlarını, üçüncü ve dördüncü satır ise sırasıyla modelin çıktısı olan seyrek ve yoğun nokta bulutlarını bölütleme sonuçlarıyla birlikte göstermektedir.

V. SONUÇLAR

Bu bildiride, eksik nokta bulutlarının tamamlanması ve parçalı olarak bölütlenmesi için sinerjistik bir derin öğrenme tabanlı yöntem önerilmiştir. Önerilen yöntem, tamamlama kategorisinde altın standart olan yöntem (GRNet) ile eşit veya daha iyi performans elde ederken, aynı zamanda tamamlanan nokta bulutunun bölütlemesini de başarıyla yapabilmektedir. Gerçek dünyada karşılaşılan birçok otonom sistem uygulamasında toplanan veriler çoğunlukla eksiktir. Bu göz önünde bulundurulduğunda, yalnızca bir işe odaklanan modellerin artık yetersiz olacağı söylenebilir. Bunun yerine, bu bildiride önerilen yöntem gibi, toplanan verinin farklı özelliklerini kullanarak (pozisyon, mesafe vb.) birden fazla otonom sistem tabanlı işi yapabilen [13], [14], daha kullanışlı ve efektif modeller geliştirilebilir. Bunun bir sebebi, farklı işlerin ortak çıkarılmış

özellikleri kullanabilmesi ve diğer işlerin sonuçlarından çıkarılan özellikleri de, belli aşamalarda girdi olarak alabilmesidir.

BİLGİLENDİRME

Bu makale, TÜBİTAK'ın 2232 Uluslararası Üstün Araştırmacılar Bursu Programından yararlanılarak hazırlanmıştır (Proje No: 118C356). Ancak makalenin tüm sorumluluğu makalenin yazarına aittir. TÜBİTAK'tan alınan mali destek, yayının içeriğinin bilimsel anlamda TÜBİTAK tarafından onaylandığı anlamına gelmez.

KAYNAKLAR

- [1] H. Xie, H. Yao, S. Zhou, J. Mao, S. Zhang, W. Sun, "GRNet: Gridding residual network for dense point cloud completion", ECCV 2020
- [2] Z. Huang, Y. Yu, J. Xu, F. Ni, and X. Le, "Pf-net: Point fractal network for 3d point cloud completion", CVPR, 2020.
- [3] M. Liu, L. Sheng, S. Yang, J. Shao, and S. Hu, "Morphing and sampling network for dense pointcloud completion", AAAI, 2019.
- [4] T. Groueix, M. Fisher, V. G. Kim, B. C. Russell, and M. Aubry, "Atlasnet: A papier-mache approach to learning 3d surface generation", 2018.
- [5] C. R. Qi, H. Su, K. Mo, and L. J. Guibas, "Pointnet: Deep learning on point sets for 3d classification and segmentation", CVPR, 2017.
- [6] L. P. Tchapmi, C. B. Choy, I. Armeni, J. Gwak, and S. Savarese, "Segcloud: Semantic segmentation of 3d point clouds", 3DV, 2017.
- [7] D. Maturana and S. Scherer, "Voxnet: A 3d convolutional neural network for real-time object recognition", IROS, 2015.
- [8] A. Abbasi, S. Kalkan, Y. Sahillioğlu, "Deep 3D semantic scene extrapolation", The Visual Computer, 2019.
- [9] A. Dai, C. R. Qi, and M. Nießner, "Shape completion using 3d-encoder-predictor cnns and shape synthesis", CVPR, 2017.
- [10] X. Han, Z. Li, H. Huang, E. Kalogerakis, and Y. Yu, "High-resolution shape completion using deep neural networks for global structure and local geometry inference", ICCV, 2017.
- [11] Z. Wang and F. Lu, "Voxsegnet: Volumetric cnns for semantic part segmentation of 3d shapes", TVCG, 2018.
- [12] L. Yi, V. G. Kim, D. Ceylan, I. Shen, M. Yan, H. Su, C. Lu, Q. Huang, A. Sheffer, L. J. Guibas, et al. A scalable active framework for region annotation in 3d shape collections. ACM Transactions on Graphics (TOG), 35(6):210, 2016
- [13] D. Gozen, S. Ozer, "Visual Object Tracking in Drone Images with Deep Reinforcement Learning", IEEE, ICPR 2020.
- [14] B. M. Albaba, S. Ozer, "SyNet: An Ensemble Network for Object Detection in UAV Images", IEEE, ICPR 2020.

TABLE I: GRNET VS GRJOINTNET SONUÇLARI

	GRNet	GRJointNet
araba	6.26 / 2.92	6.18 / 3.00
uçak	5.70 / 1.49	3.27 / 1.50
sandalye	5.52 / 2.92	4.58 / 2.36
tabanca	13.07 / 1.83	12.71 / 1.85