

استفاده از شبکه های عصبی برای تولید شبکه محاسباتی بر پایه داده های ابر نقاط: یک مطالعه مروری

نگار احمدزاده^{۱*}، علیرضا جهانگیریان^۲

۱- دانشجوی ارشد، مهندسی هوافضا، دانشگاه صنعتی امیرکبیر، تهران، negar.ahmadzadeh@aut.ac.ir

۲- استاد، مهندسی هوافضا، دانشگاه صنعتی امیرکبیر، تهران، ajahan@aut.ac.ir

خلاصه

این مقاله مروری بر مطالعات انجام شده در زمینه استفاده از شبکه های عصبی برای تولید شبکه محاسباتی بر پایه داده های ابر نقاط[†] می باشد. تقسیم بندی مناسبی با هدف بررسی عملکرد هر روش صورت گرفته است. سپس هر روش مورد مطالعه قرار گرفته و ویژگی های کلیدی آن به همراه شیوه آموزش به شبکه عصبی ذکر شده است. هر یک از این روش ها دارای مزایا و چالش هایی مانند بهبود دقت در پردازش داده های نامنظم، پیچیدگی محاسباتی، و مدیریت نویز در داده های ورودی هستند. این مقاله همچنین نظراتی که باعث بهبود پیاده سازی الگوریتم می شوند را نیز ارائه داده است.

کلمات کلیدی: ابر نقاط، شبکه عصبی، شبکه محاسباتی


۱. مقدمه

داده های ابر نقاط مجموعه ای از نقاط در فضای سه بعدی هستند که برای نمایش اشیا یا محیط های واقعی به کار می روند. هر نقطه در ابر نقاط دارای سه مولفه (X, Y, Z) است و ممکن است ویژگی های دیگری نظیر رنگ یا بردار عمود بر سطح یا ویژگی های هندسی را نیز در بر بگیرد. این داده ها معمولاً از طریق اسکنرهای سه بعدی، حسگرهای لیدار[‡]، و دیگر فناوری های تصویربرداری تولید می شوند و به دلیل قابلیت بازسازی دقیق جزئیات هندسی، کاربرد وسیعی در زمینه هایی چون واقعیت مجازی [۱][۲]، مهندسی معکوس [۳][۴]، نقشه برداری [۵][۶]، و شبیه سازی دارند.

با این حال، کار با داده های ابر نقاط به دلیل ماهیت نامنظم و پراکنده بودن آن ها چالش های بسیاری را بوجود آورده است. این داده ها معمولاً فاقد ساختارهای منظم هستند و تراکم نقاط در بخش های مختلف فضا ممکن است متفاوت باشد، که منجر به پیچیدگی پردازش و تحلیل آن ها شده است. علاوه بر این، داده های ابر نقاط اغلب حاوی نویز و نقاط ناقصی هستند

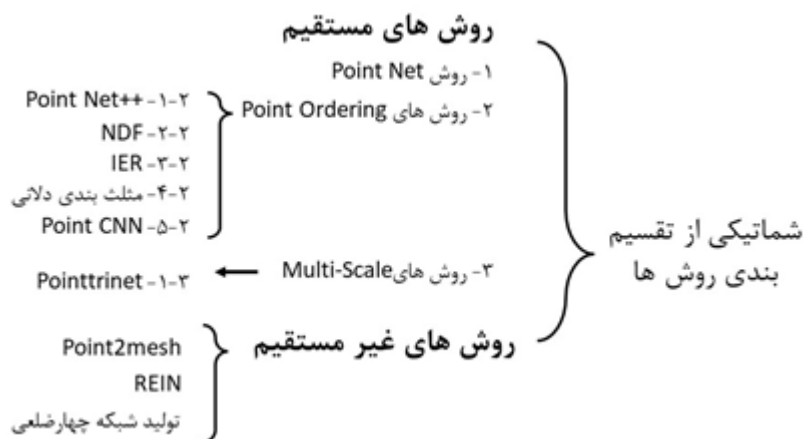
[†] Point Clouds

[‡] Lidar



که بر دقت بازسازی و تحلیل آنها می‌گذارد. به منظور مواجهه با این چالش‌ها، روش‌های متعددی از هوش مصنوعی و به‌ویژه یادگیری عمیق طی سال‌های اخیر توسعه یافته است که قابلیت‌های قابل توجهی در پردازش داده‌های ابر نقاط را به جهانیان نشان داده است.

بطور کلی روش‌هایی که در این مقاله مورد بررسی قرار گرفته اند به دو دسته کلی روش‌های مستقیم* و روش‌های غیر مستقیم† تقسیم شده اند. در روش‌ها غیر مستقیم، داده‌های ابر نقاط به ساختار منظمی تبدیل شده و شبکه عصبی ایی که بر آن پیاده شده می‌تواند آن را پردازش کند. دسته روش‌های غیر مستقیم بدن اعمال هیچ فیلتری، داده‌های نامنظم ابر نقاط را برای تولید شبکه استفاده می‌کند. این دسته به دو نوع point ordering و multi-scale تقسیم بنده می‌شود. دسته بندی اول از ابر نقاط به گونه ایی استفاده می‌کند که به مشکل بی نظمی بر نخورد و ویژگی‌های کاربردی را بتواند شناسایی کند. دسته multi-scale شبکه را به زیر مجموعه‌هایی تقسیم کرده و پردازش اطلاعات را در هر زیر مجموعه انجام می‌دهد. در ادامه به معرفی الگوریتم‌ها و بررسی ویژگی‌ها که در تصویر شماره (۱) به آنها اشاره شده است می‌پردازیم.



شکل شماره ۱- شماتیکی از روش‌هایی که در این مقاله به مطالعه آنها پرداخته شده است.

۲. معرفی الگوریتم‌ها


هر الگوریتم شامل معرفی کلی از روند اجرا، چالش‌های آموزش به شبکه‌ی هوش مصنوعی، ویژگی‌های روش و چگونگی برخورد با ابر نقاط و دسته بندی نقاط می‌شود. سپس در نهایت به بررسی مزایا و معایب هر روش پرداخته شده و پیشنهادات قابل توجه برای بهبود عملکرد شبکه عصبی مورد ذکر واقع شده است.

۱.۲. روش‌های مستقیم

در روش‌های مستقیم، بی‌نظمی و پراکندگی غیر یکنواخت نقاط مورد توجه نیست و می‌توانیم از این موضوع به راحتی گذر کنیم. همچنین این دسته روش قادر است از این ویژگی ابر نقاط به عنوان پتانسیلی برای استفاده در بررسی ویژگی‌های نقاط استفاده کرد.

* Direct methods

† Indirect methods



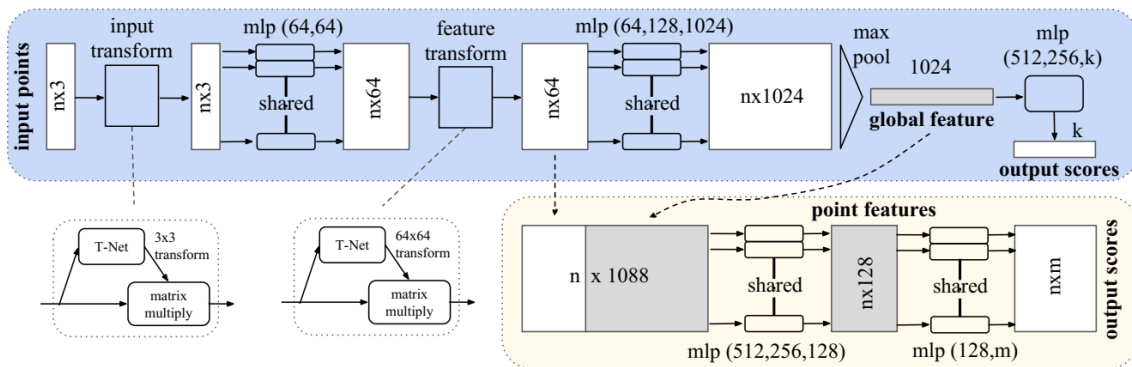
Point net روش -

اولین مقاله ارائه شده در زمینه استفاده از هوش مصنوعی و معرفی الگوریتمی که بتواند با استفاده از ابر نقاط اقدام به تولید شبکه داشته کند، در سال ۲۰۱۷ توسط چارلز و همکاران [۷] به نام Pointnet ارائه شد. این الگوریتم پایه گذار و مشوق تولید دیگر روش های مبتنی بر هوش مصنوعی برای تولید شبکه محاسباتی بوده است. در این الگوریتم با استفاده از شبکه عصبی به طور مستقیم از مختصات سه بعدی نقاط استفاده شده است. بطوریکه نیازی به تبدیل داده ها به شبکه های منظم نداریم. ابتدا هر نقطه از ابر نقاط به صورت جداگانه پردازش شده و ویژگی های آن از طریق یک شبکه عصبی چندلایه (MLP) استخراج می شود. سپس یک بردار حاوی ویژگی برای هر نقطه ساخته شده که منحصر بفرد است. در فرمول زیر می توان این تبدیل را با استفاده از توابع f و g متوجه شد:

$$f(\{x_1, \dots, x_n\}) \approx g(h(x_1), \dots, h(x_n)) \quad (1)$$

در این رابطه x_i ، h و g به ترتیب بیانگر مختصات هر نقطه، شبکه عصبی چند لایه برای استخراج ویژگی های هر نقطه و تابع Max Pooling برای ترکیب ویژگی های کل نقاط می باشند. در نهایت ویژگی تمام نقاط با هم ترکیب می شود تا یک ویژگی کلی برای کل ابر نقاط به دست آید. این ویژگی کلی نمایانگر خصوصیات ابر نقاط است و می تواند برای طبقه بندی یا تقسیم بندی مورد استفاده قرار گیرد.

برای جلوگیری از انجام تبدیلات هندسی مانند دوران، انتقال یا مقیاس دهی، الگوریتم PointNet از یک شبکه عصبی کوچک به نام T-Net استفاده می کند. این شبکه قادر است تا یک ماتریس تبدیل* را برای هر ابر نقاط پیش بینی کند. سپس این ماتریس به مختصات نقاط اعمال شده تا داده ها به شکل استاندارد تبدیل شوند. این عملیات باعث می شود که شبکه نسبت به چرخش یا جابجایی داده ها حساس نباشد. از این روش به دلیل سادگی و کارایی، می توان برای تحلیل داده های سه بعدی به طور مستقیم استفاده کرد. این عملکرد را می توان در شکل شماره ۲ مشاهده نمود.




شکل شماره ۲- دستور عملکرد الگوریتم Point Net [7]

از مزایای این روش می توان به پردازش مستقیم داده های نامنظم، عدم نیاز تبدیل به شبکه های منظم و مقاومت در برابر تغییرات هندسی اشاره کرد. اما از معایب آن می توان به حساسیت به داده های با تراکم غیر یکسان و چالش در درک ساختارهای پیچیده محلی نام برد.

برای بهبود این روش در آینده، می توان از تکنیک های پیشرفته تری برای افزایش دقت در نقاط با جزئیات محلی استفاده کرد و بهینه سازی های معماری شبکه را برای کاهش پیچیدگی محاسباتی انجام داد.

*Transformation Matrix



- روش های Multi-scale

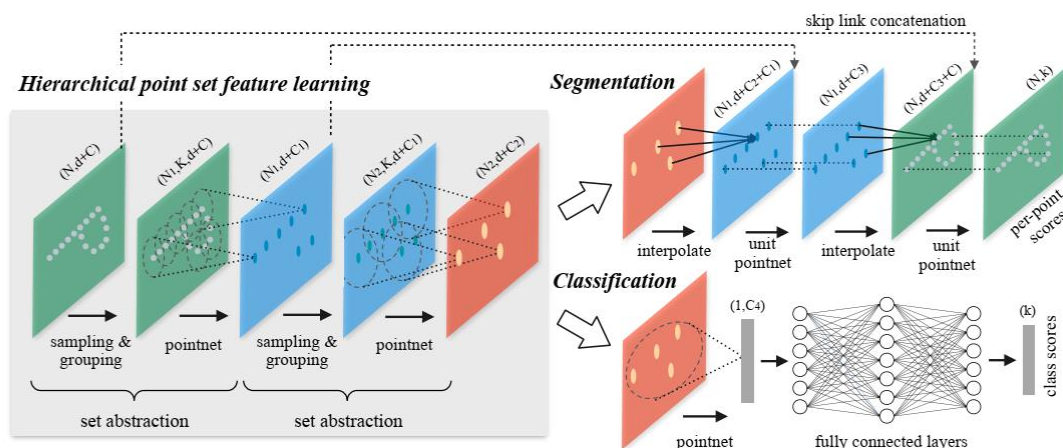
در این تقسیم بندی، میدان به مقیاس های کوچکتری تقسیم شده و شبکه محاسباتی در هر زیر میدان ایجاد می شود. سپس میدان ها با هم ترکیب شده و پردازش می شوند تا شبکه نهایی شکل بگیرد. در ادامه به بررسی روش هایی که از این تکنیک بهره برده اند، پرداخته شده است.

- روش Point Net ++

این روش نسخه بروز شده ایی از روش قبلی می باشد که در همان سال توسط چارلز و همکاران [8] نیز ارائه گردیده است. این الگوریتم یک روش پیشرفته برای پردازش داده های سه بعدی برای ابر نقاط می باشد که چالش های مرتبط با تراکم نامنظم نقاط را برطرف می کند. این نقاط، به دلیل فقدان ترتیب مشخص و تراکم نامنظم، پردازش پیچیده ای دارند. الگوریتم Point Net ++ با بهره گیری از یک ساختار سلسله مراتبی و استفاده از تکنیک هایی نظیر نمونه برداری از دورترین نقاط و گروه بندی چندمقیاسی، قادر به استخراج ویژگی های چندگانه از این داده ها است.


این الگوریتم، ابتدا نقاطی از مجموعه اصلی را به عنوان نقاط مرجع انتخاب می کند. بطوریکه باعث می شود نقاط انتخاب شده به طور یکنواخت کل فضا را پوشش دهند. نقاط مرجع انتخاب شده، به عنوان مرکز نواحی محلی مورد استفاده قرار می گیرند. برای هر نقطه مرجع، نقاط نزدیک به آن (بر اساس شعاع تعریف شده) به عنوان نقاط همسایه گروه بندی می شوند. این گروه بندی ها به الگوریتم کمک می کنند تا ویژگی های محلی ناحیه را استخراج کند. برای هر ناحیه محلی که در مرحله قبل تعریف شده است، یک نسخه کوچک از شبکه PointNet اجرا می شود. این شبکه عصبی ویژگی های محلی هر ناحیه را استخراج کرده و آن ها را به بردارهای ویژگی تبدیل می کند.

Point Net ++ از روش گروه بندی در مقیاس های مختلف استفاده می کند تا بتواند ویژگی های هندسی را در اندازه ها و مقیاس های متفاوت استخراج کند. این ویژگی به شبکه کمک می کند تا تغییرات تراکم نقاط را مدیریت کند. شکل شماره 3 ترتیب پیاده سازی این الگوریتم را نشان می دهد.



شکل شماره ۳- دستور عملکرد الگوریتم Point Net ++ [8]

یکی از معادلات مهم در PointNet++ به صورت زیر تعریف می شود که نشان دهنده تابع مجموعه ای است که نقاط را به یک بردار نگاشت می کند:




$$f(x_1, x_2, \dots, x_n) = \gamma(\max_{i=1, \dots, n} \{h(x_i)\}) \quad (2)$$

در این فرمول γ ، h ، x_i و \max به ترتیب نشان دهنده مختصات هر نقطه، شبکه عصبی چند لایه برای استخراج ویژگی های هر نقطه، عملیاتی برای فشرده سازی ویژگی های نقاط برای از بین بردن ترتیب و تابعی نهایی باری تبدیل ویژگی های فشرده شده به خروجی مطلوب می باشند. دقت بالا در داده های نامنظم، انعطاف پذیری در تراکم بالا نقاط از بارز ترین مقادیر این الگوریتم به حساب می آید. اما پیچیدگی محاسباتی زیاد و بروز حساسیت به انتخاب بردار ویژگی های باعث توجه به سایر های های شده است که در ادامه مورد بررسی قرار خواهند گرفت.

- روش NDF*

از دیگر روش های جدید و نوین برای بازسازی سطح توسط ابر پراکنده ایی از نقاط با استفاده از هوش مصنوعی می توان به روش NDF [9] اشاره کرد. در این روش ابر نقاط به عنوان ورودی به الگوریتم داده شده، سپس یک شبکه عصبی فاصله هر نقطه تا نزدیکترین سطح را محاسبه می کند. به این عمل یادگیری فیلد فاصله گفته می شود که کلید اصلی برای تولید شبکه در این الگوریتم به حساب می آید. این شبکه عصبی برای یادگیری فیلد فاصله از داده های ورودی استفاده می کند. مختصات نقاط (X, Y, Z) را به همراه ویژگی های یادگیری شده از ابر نقاط ورودی دریافت شده و فاصله آن نقطه تا نزدیکترین سطح محاسبه می شود. سپس از یک شبکه عصبی پیشی سه بعدی برای نگاشت ابر نقاط به فیلد فاصله استفاده می شود تا در حد امکان، سطح را بطور پیوسته بازسازی کند. این عملیات در شکل شماره ۴ قابل مشاهده است. برای آموزش این شبکه عصبی، مجموعه ای از داده های ابر نقاط و سطوح واقعی به مدل داده می شود. در طول آموزش، شبکه سعی می کند فاصله ای که برای هر نقطه پیش بینی کرده است را با فاصله واقعی که از داده های به دست آمده مقایسه کند. سپس برای ارزیابی مدل از یک تابع هزینه استفاده می شود که اختلاف بین فاصله پیش بینی شده توسط مدل و فاصله واقعی را اندازه گیری می کند. این تابع معمولاً بر اساس فاصله اقلیدسی یا دیگر متریک های فاصله تعریف می شود.




Input



NDF

شکل شماره ۴- نمونه ایی از دریافت ابر نقاط و تبدیل آن به سطوح پیوسته در الگوریتم NDF [9] پس از محاسبه فیلد فاصله برای نقاط مختلف در فضا، سطوح با استفاده از روش های خاصی بازسازی می شوند. برای استخراج دقیق سطح از فیلد فاصله، نقاط روی سطح شیء پیش بینی شده و سپس از این نقاط برای تولید یک مش سه بعدی استفاده می شود. این کار معمولاً با استفاده از الگوریتم هایی مانند Marching Cubes یا دیگر روش های تبدیل ابر نقاط

* Neural Unsigned Distance Fields



به مش انجام می شود که نقاط پیش بینی شده را به هم متصل می کنند تا سطح شیء را تشکیل دهند. الگوریتم Marching Cubes با استفاده از مقادیر فاصله در یک شبکه مکعبی، سطح شیء را استخراج می کند. البته می توان از روش مثلث بندی دلانی نیز برای ایجاد مش استفاده نمود.

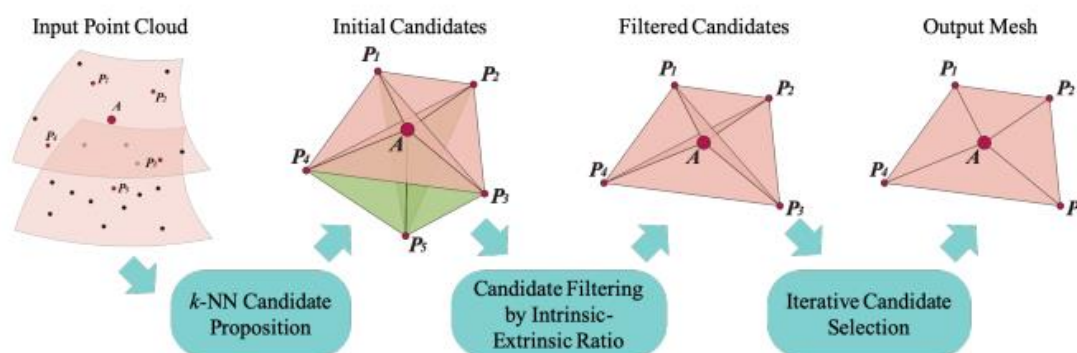
بازسازی دقیق سطوح پیچیده و باز، ایجاد و حفظ پیوستگی سطح و انعطاف پذیری بالا در مقابل پردازش داده های پراکنده و دارای نویز از فواید استفاده از این روش می باشد. در عین حال، پیچیدگی محاسباتی این الگوریتم و زمان پردازش بالا از نقاط ضعف این روش به حساب آمده که با استفاده از روش های بهینه سازی قابل بهبود می باشد.

- روش IER*

یکی از بهترین ایده های برای تولید شبکه در روش IER معرفی شده است. این روش که توسط مینقاو و همکاران [۱۰] ارائه شده است قادر است تا از یک شبکه عصبی برای فیلتر کردن مثلث های نادرست استفاده کند. این الگوریتم ابتدا اقدام به تشکیل گراف K-nn شامل نزدیکترین همسایه های هر نقطه می کند. هدف این است که مجموعه ای از مثلث های کاندیدا ایجاد شود که کل سطح را پوشش دهند. در نهایت، برای هر نقطه تعداد زیادی مثلث کاندیدا ساخته می شود. برخی از این مثلث ها به درستی سطح جسم را پوشش می دهند و برخی دیگر نادرست هستند (مانند مثلث هایی که نقاطی از سطوح مختلف یا نزدیک به هم اما مستقل را به هم متصل می کنند). سپس دسته ای از مثلث های نادرست در مناطقی مانند ساختارهای نازک، سطوح نزدیک به هم یا بخش های فضایی مجاور (که مستقل از هم هستند) ظاهر می شوند. این مرحله پایه ای و بسیار مهم است، زیرا مثلث های کاندیدا از روی ابر نقاط ساخته می شوند و این مثلث ها مشخص می کنند که کدام نقاط به هم متصل هستند و می توانند به طور دقیق سطح جسم را تشکیل دهند. اکنون با استفاده از معیار IER مثلث های نادرست که نماینده سطح واقعی نیستند را شناسایی و حذف خواند شد.

برای یک مثلث با سه رأس u, v, w و IER به شکل زیر گسترش می شود:


$$IER(u, v, w) = \frac{d_G(u, v) + d_G(u, w) + d_G(v, w)}{d_E(u, v) + d_E(u, w) + d_E(v, w)} \quad (3)$$



شکل شماره ۵- تصویری از نحوه پیاده سازی الگوریتم IER [10]

این فرمول مجموع فاصله های ژئودزیک و اقلیدسی بین هر جفت رأس های مثلث را در نظر می گیرد. پس از محاسبه معیار IER برای هر جفت نقطه در هر مثلث، مثلث هایی که IER آن ها بزرگ تر از یک مقدار آستانه (τ) است، به عنوان مثلث های نادرست فیلتر می شوند. این آستانه معمولاً مقدار مشخصی بزرگ تر از ۱ است که تعیین می کند که چه مثلث هایی باید حذف

* Intrinsic-Extrinsic Ratio



شوند. مثلث‌هایی که IER آن‌ها بزرگ‌تر از این آستانه هستند، به دلیل اینکه نقاطشان به سطوح متفاوت یا بخش‌های غیرمرتبط تعلق دارند، حذف می‌شوند. این مثلث‌ها معمولاً در مناطقی با ساختارهای نازک، سطوح نزدیک به هم، یا بخش‌های مجاور که نباید به هم متصل شوند، ظاهر می‌شوند.


پس از فیلتر کردن مثلث‌های نادرست با استفاده از نسبت IER در مرحله قبلی، مثلث‌های باقی‌مانده (که به احتمال زیاد سطح واقعی جسم را پوشش می‌دهند) باید بر اساس برخی معیارها مرتب شوند تا در نهایت بتوان مش نهایی تکمیل کرد. دو معیار اصلی برای مرتب‌سازی مثلث‌ها وجود دارد:

- فاصله تا سطح واقعی
- مثلث‌هایی که به سطح مرجع نزدیک‌تر هستند، اولویت بالاتری دارند. این معیار کمک می‌کند مش نهایی زودتر تشکیل شود.
- طول لبه‌های مثلث
- مثلث‌هایی که لبه‌های کوتاه‌تری دارند، در اولویت قرار می‌گیرند. مثلث‌های با لبه‌های کوتاه معمولاً نماینده‌ی خوبی برای بخش‌های یکنواخت سطح هستند و به جلوگیری از ایجاد مش‌های نامنظم کمک می‌کنند.
- پس از مرتب‌سازی، مثلث‌ها به‌صورت تدریجی به مش نهایی اضافه می‌شوند. اما قبل از اضافه کردن هر مثلث، دو شرط مهم دیگر باید بررسی شوند:
- عدم تداخل مثلث‌ها
- مثلث جدید نباید با مثلث‌هایی که قبلاً به مش اضافه شده‌اند، تداخل داشته باشد. یعنی هیچ‌یک از لبه‌های مثلث نباید با لبه‌های مثلث‌های قبلی تقاطع داشته باشد.
- لبه‌های مانفولد
- هر لبه در مش نهایی باید به حداکثر دو مثلث متصل باشد. اگر اضافه کردن مثلث جدید باعث شود که یک لبه بیش از دو مثلث داشته باشد (یعنی لبه غیرمانفولد شود)، آن مثلث پذیرفته نمی‌شود. این فرایند مرتب‌سازی و اضافه کردن مثلث‌ها به‌طور مداوم تکرار می‌شود تا تمام مثلث‌های صحیح به مش نهایی اضافه گردند. در نهایت، تمام مثلث‌های صحیح انتخاب شده و مش نهایی ساخته می‌شود که نماینده‌ای دقیق از سطح واقعی جسم است.
- نقاط قوت این روش شامل دقت بالا، حفظ جزئیات و قابلیت تطبیق با داده‌های غیر یکنواخت است. در حالیکه حساسیت به تنظیمات از دلایل اصلی ایجاد ضعف در این روش می‌باشد.

- روش مثلث بندی دلانی* بر پایه شبکه عصبی

روش‌های ساده و آکادمیک تولید مش همیشه مورد توجه پژوهش‌گران جوان واقع شده است. به همین دلیل ماری و همکاران [11] مطالعات خود را بر روی پیاده سازی مثلث بندی دلانی با استفاده از هوش مصنوعی را در سال 2021 شروع کردند و موفق شدند الگوریتم مناسبی را ارائه دهند. روشی که آنها معرفی کردند ابر نقاط را به عنوان ورودی دریافت کرده و همسایگی ژئودزیک هر نقطه را محاسبه می‌کند. این کار با انتخاب نزدیک‌ترین همسایه‌های هر نقطه آغاز می‌شود. سپس فاصله اقلیدسی محاسبه گردیده و با اعمال یک شبکه عصبی می‌توانیم همسایه‌هایی که روی سطح جسم واقع شده است را شناسایی کنیم. به این کار شناسایی همسایگی ژئودزیک می‌گویند. خروجی این شبکه عصبی به شکل عددی بین 0 و 1 برای هر همسایه است. این عدد بیان می‌کند هر همسایه چقدر احتمال دارد که یکی از نزدیک‌ترین همسایه‌های ژئودزیک باشد. این مرحله پایه‌ای برای مراحل بعدی است، زیرا شناسایی دقیق همسایگی‌های ژئودزیک محلی باعث می‌شود که در

* Delaunay Triangulation

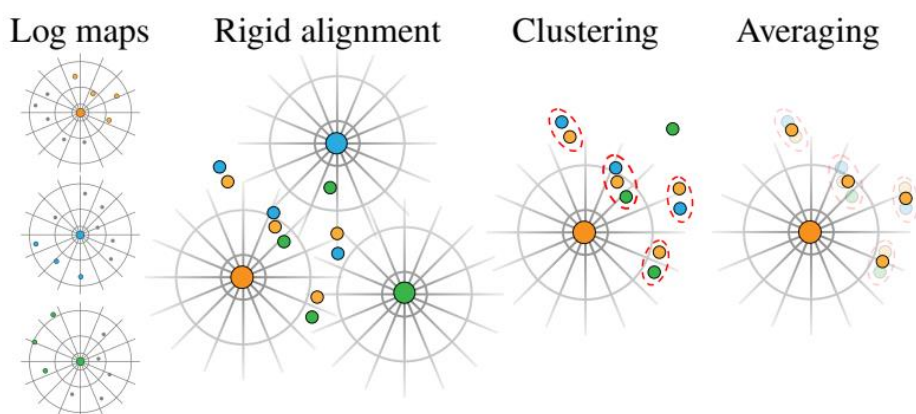


مراحل بعدی، مثلث بندی دلآونی و نگاشت های لگاریتمی دقیق تر انجام شود و مش نهایی کیفیت بالاتری داشته باشد. در مرحله بعد، نگاشتی لگاریتمی* از تکه های ۳ بعدی همسایگی های ژئودزیک به یک فضای ۲ بعدی صورت میپذیرد. بدین گونه که روشی ریاضی برای تبدیل یک سطح منحنی به یک فضای ۲ بعدی پیاده سازی می شود. برای بهبود دقت نگاشت لگاریتمی، دو نوع خطا محاسبه می گردد:

- خطای مختصات دوبعدی
- تفاوت بین مختصات نگاشت پیش بینی شده توسط شبکه و نگاشت صحیح برای هر نقطه محاسبه و مینیمم می شود.
- خطای فاصله ژئودزیک
- تفاوت فاصله ژئودزیک واقعی هر نقطه تا مرکز با فاصله پیش بینی شده در نگاشت دوبعدی محاسبه و به حداقل می رسد. پس از اعمال تطبیق، مجموعه مختصات دوبعدی نقاط مشترک بین تکه های همسایه ایجاد شده که باید آنها را در یک گروه قرار دهیم تا از ایجاد نویز جلوگیری کنیم. به این مرحله خوشه بندی می گویند. در نهایت از نقاط هر خوشه یک مقدار میانگین گرفته شده تا بهترین تخمین برای معرفی نقطه مشترک معرفی گردد. در شکل شماره (۵) زیر می توان خلاصه ای از روند الگوریتم تا به اینجا را مشاهده کرد.


مثلث بندی دلآنی برای نقاط هر گروه اعمال می گردد. ویژگی مثبت مثلث بندی دلآنی، تضمین با کیفیت بودن مثلث ها در فضای دو بعدی است. نتیجه این کار یک مجموعه مثلث های دلآنی برای هر تکه می باشد که به آنها عناصر سطح دلآونی (DSE) گفته می شود. هر سطح دلآنی، مجموعه ای از مثلث های دلآنی بوده که حول نقطه مرکزی برای هر خوشه ساخته شده است. اما وجود بعضی مثلث ها در بیش از یک سطح دلآنی کار را مشکل ساز می کند. یعنی، مثلث های مربوط به نقاط مشترک بین تکه های همسایه ممکن است چندین بار ظاهر شوند. به همین دلیل مثلث ها را به سه دسته عمده زیر تقسیم بندی می کنند:

- مثلث هایی که در سه DSE ظاهر شده اند.
- مثلث هایی که در دو DSE ظاهر شده اند.
- مثلث هایی که تنها در یک DSE ظاهر شده اند.




شکل شماره ۶- تصویری از نحوه پیاده سازی الگوریتم مثلث بندی دلآنی بر پایه شبکه عصبی [11]

* log map



برای تشکیل یک مش که در آن هر لبه دقیقاً به دو مثلث متصل باشد، نیاز است که مثلث‌های تولیدشده در هر سطح دلانی، بیش از یکبار ظاهر شده باشند.



شکل شماره ۷- تصویری از نحوه پیاده سازی الگوریتم مثلث بندی دلانی بر پایه شبکه عصبی [11]

مرحله آخر مربوط به ارزیابی مش و نمایش نتیجه نهایی است. برای ارزیابی مش تولیدشده، چند معیار کلیدی مورد استفاده قرار می‌گیرد:

- درصد لبه‌های غیرمانفولد یا NW^* :

این معیار درصد لبه‌هایی از مش را نشان می‌دهد که بیش از دو مثلث به یک لبه متصل شده‌اند یا لبه‌ای بدون اتصال مناسب باقی مانده است. این معیار به طور مستقیم کیفیت مش را ارزیابی می‌کند. درصد پایین‌تر نشان‌دهنده مش‌های باکیفیت‌تر است.

- فاصله چمفر یا CD^\dagger :

این معیار برای ارزیابی دقت بازسازی سطح استفاده می‌شود. فاصله چمفر تفاوت بین نقاط مش بازسازی‌شده و ابر نقاط را اندازه‌گیری می‌کند. فاصله کمتر نشان‌دهنده دقت بالاتر در بازسازی سطح است.

- خطای زاویه‌ای نرمال یا NR^\ddagger :

این معیار زاویه بین نرمال‌های سطح مش بازسازی‌شده و نرمال‌های سطح اصلی را اندازه می‌گیرد. زاویه کمتر به معنای همخوانی بیشتر سطح بازسازی‌شده با سطح اصلی می‌باشد.

از مزایای این روش می‌توان به ایجاد مش دقیق، حفظ دقت هندسی و استفاده از نگاهت‌های لگاریتمی اشاره کرد. همچنین این روش در مواجهه با داده‌های غیر یکنواخت عملکرد مناسبی دارد. معایب شامل حساسیت به هندسه‌های پیچیده، چالش در بخش‌های نازک، و وابستگی به داده‌های آموزشی مناسب است.


- روش Point CNN

روش دیگر برای پردازش ابر نقاط و ایجاد مش، روش PointCNN می‌باشد که توسط یانگیان و همکاران [12] ارائه شده است. این الگوریتم از یک شبکه عصبی پیچشی دارای سلسله مراتب برای یادگیری ویژگی‌های ابر نقاط استفاده می‌نماید. بطوریکه یادگیری این ویژگی‌ها بصورت لایه‌ای انجام می‌پذیرد و در هر لایه ویژگی‌های پیچیده‌تری محاسبه می‌شود. این عملیات یادگیری بر روی ویژگی‌های محلی، انتخاب همسایه‌های محلی، کاهش تعداد نقاط و تکرار عملیات در چندین لایه انجام می‌پذیرد. فرض کنید داده‌های ورودی شامل ۱۰۲۴ نقطه باشد. در لایه اول الگوریتم، ممکن است تعداد نقاط به ۵۱۲ کاهش یابد اما ویژگی‌های این ۵۱۲ نقطه عمق بیشتری پیدا می‌کند. این عملیات تا لایه‌های بعدی ادامه پیدا می‌کند تا جایی که تعداد کمی از نقاط باقی می‌ماند. این ساختار پیچشی سلسله مراتبی به PointCNN اجازه می‌دهد تا هم

* Non-watertight Edges

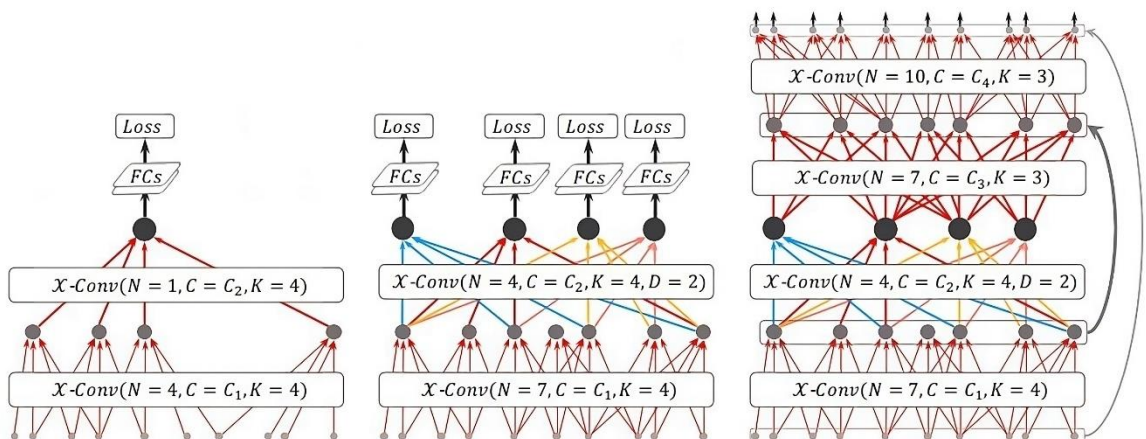
† Chamfer Distance

‡ Normal Reconstruction Error



ویژگی‌های محلی را از داده‌های نقطه‌ای استخراج کند و هم به مرور ویژگی‌های کلی‌تر و پیچیده‌تر در مورد شکل دست پیدا کند. سپس باید الگوریتم را آموزش دهیم. آموزش شبکه شامل تنظیم وزن‌های مدل بر اساس داده‌های آموزشی است تا بتواند به درستی وظایفی مانند طبقه‌بندی را انجام دهد. برای این کار، از یک الگوریتم یادگیری و بهینه‌سازی استفاده می‌شود که وزن‌های شبکه را با توجه به داده‌های ورودی و برچسب‌های هدف تنظیم کند. اولین گام در آموزش شبکه تعریف تابع هدف می‌باشد. سپس از یک الگوریتم بهینه‌سازی استفاده شده تا با توجه به گرادیان تابع هدف نسبت به وزن‌ها، تغییرات لازم را در وزن‌ها اعمال کند و مقدار تابع هدف به حداقل برساند. آموزش شبکه به صورت تکراری انجام می‌شود، یعنی چندین بار داده‌های آموزشی از طریق شبکه عبور داده شده و وزن‌های شبکه به‌روزرسانی می‌شوند. پس از اتمام آموزش، مدل باید با استفاده از داده‌های تست که در طول آموزش و اعتبارسنجی استفاده نشده‌اند، آزمایش شود. در نهایت شبکه از طریق داده‌های لایه‌های عمیق‌تر پردازش شده تا به خروجی نهایی منجر شود. شماتیکی از روند الگوریتم را می‌توان در شکل شماره (۷) مشاهده کرد.


از نقاط قوت این الگوریتم می‌توان به عدم حساسیت نسبت به ترتیب نقاط، قابلیت یادگیری ویژگی‌های پیچیده و سازگاری با داده‌های نامنظم اشاره کرد. اما پیچیدگی محاسباتی بالا منجر شده تا دیگر روش‌ها مورد توجه قرار بگیرند.



شکل شماره ۸ - تصویری از نحوه پیاده‌سازی الگوریتم Point CNN [12]


- روش‌های Point ordering

اولویت قرار دادن برخی نقاط در دامنه میدان باعث می‌شود توجه بیشتری به نقاط بحرانی و نواحی پیچیده شود. به همین دلیل با بررسی ویژگی‌های نقاط، برخی از آنها را به عنوان نقاط با پتانسیل بالا برای تشکیل سلول‌های مناسب شناسایی می‌کنیم و در شبکه نهایی قابل رویت هستند. در ادامه به بررسی روشی که زیر مجموعه Point ordering می‌باشد، پرداخته شده است.



Pointtrinet روش -

نیکولاس و همکاران [13] روش pointtrinet را در سال ۲۰۲۰ ارائه دادند که قادر است شبکه ایی ۳ بعدی متشکل از سلول های مثلثی را با استفاده از دو شبکه عصبی به نام های (۱) شبکه پیشنهاد دهنده* و (۲) شبکه طبقه بندی†، ایجاد کند. شبکه پیشنهاد دهنده وظیفه دارد که از میان این نقاط، نقاطی را که می توانند با هم یک مثلث تشکیل دهند انتخاب کند. این شبکه با استفاده از اطلاعات موجود در داده های ابر نقاط (مانند موقعیت نسبی نقاط و ویژگی های مکانی آنها) تعیین کند که چه نقاطی به هم نزدیک تر هستند و به احتمال زیاد می توانند یک مثلث معتبر تشکیل دهند. فرض کنید مجموعه ای از ابر نقاط دارید که باید به صورت مثلثی در شبکه مرتب شوند. شبکه پیشنهاد دهنده ابتدا نقاطی را که در همسایگی یکدیگر قرار دارند شناسایی کرده و به عنوان کاندیدای تشکیل یک مثلث جدید انتخاب می کند. سپس شبکه طبقه بندی وظیفه دارد تصمیم بگیرد که آیا این مثلث ها باید در شبکه نهایی لحاظ شوند یا خیر. شبکه طبقه بندی مانند یک فیلتر عمل می کند که فقط مثلث های معتبر را تأیید می کند. این شبکه بررسی می کند که آیا این سه نقطه واقعاً می توانند یک مثلث معتبر و صحیح در شبکه نهایی تشکیل دهند یا خیر، و در صورت تأیید، آن را به شبکه اضافه کند. این دو شبکه به صورت تکراری و ترکیبی از هم کار می کنند. به جای بررسی تمامی نقاط، شبکه پیشنهاد دهنده تعداد محدودی نقاط کاندیدا را پیشنهاد داده، که این امر پیچیدگی محاسباتی را به شدت کاهش می دهد. شبکه طبقه بند باعث می شود که فقط مثلث هایی که از نظر توپولوژیکی و هندسی معتبر هستند در شبکه نهایی لحاظ شوند، که بهبود کیفیت شبکه تولید شده را تضمین می کند. انعطاف پذیری مناسب در تولید مثلث ها بدون نیاز به تعریف دستی مثلث های کاندید و کاهش پیچیدگی محاسباتی از مزایا بارز این الگوریتم می باشد. در حین حال، ایجاد حفره در شبکه نهایی به دلیل نادیده گرفتن برخی نقاط از بزرگترین نقاط ضعف این روش به شمار می آید.




شکل شماره ۹- تصویری از شبکه تولید شده توسط Point CNN [13]

برای بهبود این روش در آینده، می توان از الگوریتم های یادگیری قوی تری برای هماهنگی دقیق تر نقاط کاندید استفاده کرد. همچنین بهبود روش مثلث بندی می تواند باعث کاهش ایجاد حفره در شبکه نهایی شود.

* Proposal Network

† Classification Network



۲.۲. روش های غیر مستقیم

همانطور که قبل تر بیان شد، روش های غیر مستقیم نمی توانند عملیات مناسبی بر روی داده های ابر نقاط انجام دهند. زیرا ابر نقاط دارای ماهیت غیر منظم هستند که استفاده از آنها را به چالش بزرگی تبدیل کرده است. این روش با تبدیل و دسته بندی نقاط می تواند عملیات مناسبی را با استفاده از شبکه عصبی برای تولید شبکه بر روی آنها پیاده سازی کند.

- روش Point2mesh


روش دیگری که بسیار مورد توجه قرار گرفته، روش mesh2point نام دارد که در سال ۲۰۲۰ توسط رانا و همکاران [14] معرفی شد. این روش حاوی تکنیک مبتنی بر شبکه عصبی عمیق برای بازسازی سطح مش با استفاده از ابر نقاط می باشد. این فرآیند با استفاده از یک مش اولیه که تخمین ساده ایی از شکل ابرنقاط است شروع می شود. سپس به کمک شبکه عصبی، شبکه ایجاد شده دچار تغییر شده تا به شکل نهایی ابرنقاط در آید. مش اولیه دارای نقشه ی ساده ایی است که ابر نقاط را توصیف می کند، اما دقیق یا پیچیده نیست. سپس شبکه عصبی، مش اولیه را به تدریج به سمت ابر نقطه منطبق می کند تا مش نهایی به دست آید. این کار توسط عملیاتی به نام shrink wrap صورت می پذیرد. بطوریکه هر بار یک سری تغییرات کوچک در موقعیت رأس های مش اعمال می شود. این شبکه نه تنها مش را به ابر نقطه نزدیک می کند، بلکه سعی می کند ویژگی های ساختاری مانند رشد نرم، پیوستگی، و تکرارهای هندسی را نیز حفظ کند. البته فرآیند بهینه سازی و تغییر مش در چندین مرحله و به صورت تکراری انجام می شود. ابتدا شبکه عصبی فاصله بین مش فعلی و ابر نقطه را محاسبه می کند تا ببیند چقدر مش به شکل نهایی نزدیک شده است.



شکل شماره ۱۰- تصویری از شبکه تولید شده توسط Point2mesh [۱۴]

یکی از ویژگی های مهم Point2Mesh این است که در طی این فرآیند، شبکه می تواند نویزها و بی نظمی های هندسی را که ممکن است در ابر نقطه وجود داشته باشند، حذف کند. در نهایت، پس از طی کردن تمام مراحل بهینه سازی، یک مش نهایی که سطح آن با ابر نقطه ورودی همخوانی دارد، تولید می شود.

از مزایای روش Point2Mesh می توان به حذف نویز و تکمیل نواحی گم شده در حین تکمیل تصویر برداری ها برای ایجاد ابر نقاط اشاره کرد. اما در عین حال این روش نیاز به داده های آموزشی خارجی ندارد و می تواند همخوانی مناسبی را برای داده های ناقص فراهم سازد. اما از معایب آشکار این روش می تواند به زمانبر بودن پیاده سازی الگوریتم و عدم توانایی برای ایجاد مش اولیه برای هندسه های پیچیده اشاره نمود.



- روش REIN

برای تولید یک شبکه سه بعدی یکپارچه، استفاده از روش REIN که توسط رانگل و همکاران [15] در سال ۲۰۲۰ ارائه شده، توصیه می‌گردد. این روش قادر است با دریافت ابر نقاط و پیاده سازی یک شبکه عصبی تکراری، مش سه بعدی تولید کند. این الگوریتم به صورت پایین به بالا و به صورت مرحله به مرحله، مش را با استفاده از اطلاعات موجود در ابر نقطه‌ها تولید می‌کند. ابتدا بردار پنهان* از ابر نقاط با استفاده از الگوریتم point Net ایجاد می‌شود. یک بردار به عنوان نماینده کل ساختار ابرنقاط عمل می‌کند بطوریکه اطلاعاتی نظیر شکل کلی، موقعیت نقاط و ویژگی‌های محلی را در بر می‌گیرد. فشرده‌سازی اطلاعات باعث می‌شود که الگوریتم بتواند با کارایی بهتری کار کند. سپس الگوریتم شروع به کار می‌کند و در هر بار تکرار نقاط را از ابرنقطه خوانده و با توجه به بردار پنهان، مش را ایجاد می‌کند. ترتیب ورود نقاط به شبکه اهمیت دارد و معمولاً الگوریتم به صورت ترتیبی نقاط را وارد می‌کند تا بتواند بهترین ساختار را از طریق ارتباط با نقاط قبلی بسازد. با معرفی هر نقطه جدید، وضعیت مش به‌روزرسانی می‌شود. این یعنی پس از ورود نقطه جدید، الگوریتم بررسی می‌کند که این نقطه چگونه می‌تواند به نقاط قبلی متصل شود تا بخشی از سطح مش را تشکیل دهد. اتصالاتی که بین نقاط جدید و نقاط قبلی شکل می‌گیرد، به ایجاد اضلاع مش کمک می‌کند. این اضلاع نمایانگر بخش‌هایی از سطح جسم هستند که به مرور با ورود نقاط بیشتر، مش کامل‌تری ایجاد می‌کنند. سپس عملیات نهایی برای تکمیل و ارزیابی مش تولید شده انجام می‌شود. این مراحل شامل ارزیابی کیفیت مش نهایی، تولید خروجی، و در نهایت بهبود و تصحیح مش با استفاده از روش‌های بازبینی و اصلاح می‌باشد. برای ارزیابی کیفیت مش تولید شده از معیارهای مختلفی از جمله معیار فاصله، مقایسه نرمال‌های سطح[†] و مقایسه نقاط و سطح مش استفاده شده است. پس از عبور از این مرحله، مش تولید شده در یک فایل سه بعدی ذخیره شده تا برای تحلیل و شبیه سازی مورد استفاده قرار گیرد.


از مزایای استفاده از این روش می‌توان به انعطاف پذیری بالا نسبت به پذیرش تعداد بالایی از ابر نقاط، بالا بودن دقت در بازسازی سطوح پیچیده و نوآوری استفاده از بردار پنهان به عنوان نماینده از ویژگی‌های هندسه اشاره کرد. با وجود این مزایا، پیچیدگی بالا محاسبات، حساس بودن الگوریتم به پذیرش داده‌های دارای نویز و نیازمندی به استفاده از حافظه زیاد ما را بر آن داشت تا به استفاده از روش‌های دیگری روی آوریم.

- روش تولید شبکه‌های چهارضلعی بلوکی


از دیگر روش‌های مورد توجه در دنیا محاسبات می‌توان به استفاده از یک شبکه عصبی پیچشی برای تولید شبکه‌های چهارضلعی بلوکی در هندسه‌های ۲ بعدی اشاره کرد. این روش اولین بار توسط یوژیانگ و همکاران [16] معرفی شد. در این روش ابتدا با تعریف مدل هندسی، تولید شبکه پس‌زمینه مثلثی و تخصیص مختصات و بردارهای چارچوب به هر نقطه از شبکه شروع می‌شود. سپس این نقاط و بردارها برچسب‌گذاری شده و به‌عنوان داده‌های ورودی برای آموزش شبکه عصبی پیچشی مورد استفاده قرار می‌گیرند. شبکه عصبی پس از یادگیری از داده‌های آموزشی، قادر است خطوط جداسازی و ساختارهای تکین را در مدل‌های جدید تشخیص داده و شبکه‌های چهارضلعی تولید کند. در نهایت، خطوط جداسازی ایجاد شده و با تقسیم مدل به زیرناحیه‌های بلوکی، شبکه نهایی ایجاد می‌شود. پس از چندین دور آموزش، شبکه به تدریج یاد می‌گیرد که بردارهای چارچوبی را که در نزدیکی خطوط جداسازی قرار دارند شناسایی کند. پس از اتمام مرحله آموزش،

* latent vector

† Point normal similarity



شبکه عصبی پیچشی آموزش دیده و آماده می‌شود تا با داده‌های جدید کار کند و ساختارهای تکین را به طور خودکار شناسایی کند.




شکل شماره ۱۱- نمونه ایی از روند پیاده سازی الگوریتم تولید شبکه چهارضلعی بر پایه شبکه عصبی [۱۶]

دقت بالا و سرعت بیشتر، خودکار سازی فرآیند و وجود پایداری مطلوب در تحلیل های عددی ما را بر آن داشت تا از این الگوریتم استفاده بهینه ایی داشته باشیم. با این وجود، نقاط ضعفی از جمله نیاز به آموزش های تکراری و پیچیدگی های تنظیمات غیر قابل چشم پوشی هستند. با این حال استفاده از تکنیک های یادگیری تطبیقی می تواند به شبکه کمک کند تا بدون نیاز به آموزش مجدد، برای هندسه های جدید بهتر عمل کند. همچنین توسعه الگوریتم هایی که نیاز به داده های آموزشی کمتری داشته باشند، می تواند کارایی و دقت روش را افزایش دهد.

۳. نتیجه گیری

بهره گیری از هوش مصنوعی در پردازش داده های ابر نقاط بی شک باعث افزایش کارایی و بهبود عملکرد در بازسازی سه بعدی و تولید شبکه های محاسباتی منجر شده است. الگوریتم هایی مانند PointNet و PointNet++ با پردازش مستقیم ابر نقاط، نیاز تبدیل این داده ها به شبکه های منظم را از بین برده و با انعطاف پذیری بیشتر، توانسته داده های نامنظم را با دقت بالا مدیریت کنند. با این حال، این روش ها همچنان با چالش های مهمی مواجه هستند. یکی از چالش های اساسی، پیچیدگی محاسباتی این الگوریتم ها می باشد. شبکه های عصبی، به ویژه در پردازش داده های بزرگ و پیچیده مانند ابر نقاط، نیازمند منابع پردازشی و محاسباتی قدرتمند و حافظه بالا هستند. این امر باعث می شود اجرای این الگوریتم ها برای داده های عظیم و جزئیات دقیق، بسیار زمان بر و پرهزینه باشد. همچنین، روش های فعلی در مواجهه با داده های ناقص و یا حاوی نویز، بهبود بیشتری نیاز دارند.


از دیگر چالش ها می توان به وجود تراکم نامنظم نقاط اشاره نمود. داده های ابر نقاط معمولاً در برخی نواحی تراکم و چگالی بالایی دارند. این عدم یکنواختی چگالی می تواند درک صحیح ساختارهای پیچیده را برای الگوریتم ها دشوار سازد و منجر به کاهش دقت در محاسبات و اعمال تغییرات شود. در نهایت، یکی از مسائل مهم دیگر حساسیت به هندسه های



بسیار پیچیده و نازک است. امید بود با به کار گیری شبکه های عصبی برای تولید شبکه بتوانیم بر این مشکل فائق آییم اما چنین نیست! این شبکه های عصبی هنوز قادر به بازسازی و تحلیل ساختار های نازک نیست. علاوه بر این، زمان آموزش و تنظیم پارامترهای شبکه به عنوان یکی دیگر از مشکلات بزرگ، نیازمند بهینه سازی های بیشتری است. در نتیجه، اگرچه هوش مصنوعی به طور قابل توجهی قابلیت های پردازش، تحلیل ابر نقاط را افزایش داده، اما چالش های مرتبط با پیچیدگی محاسباتی، مدیریت داده های ناقص و نامنظم، و بهبود دقت در ساختارهای پیچیده نشان می دهند که پیشرفت های بیشتر در این حوزه ضروری می باشد.

۴. مراجع

1. Diab, A., et al. (2022). "Deep learning for LiDAR point cloud classification in remote sensing." *Sensors* **22**(20): 7868.
2. Yue, X., et al. (2018). A lidar point cloud generator: from a virtual world to autonomous driving. Proceedings of the 2018 ACM on international conference on multimedia retrieval.
3. mGarrido, D., et al. (2021). Point cloud interaction and manipulation in virtual reality. 2021 5th International Conference on Artificial Intelligence and Virtual Reality (AIVR).
4. Zhang, W., et al. (2022). "Point cloud computing algorithm on object surface based on virtual reality technology." *Computational Intelligence* **38**(1): 106-120.
5. Kubátová, D., et al. (2023). "Data Preparing for Reverse Engineering." *Advances in Science and Technology* **132**: 320-329.
6. Wang, R., et al. (2023). "Improving point cloud classification and segmentation via parametric veronese mapping." *Pattern Recognition* **144**: 109784.
7. Qi, C. R., et al. (2017). Pointnet: Deep learning on point sets for 3d classification and segmentation. Proceedings of the IEEE conference on computer vision and pattern recognition.
8. Qi, C. R., et al. (2017). "Pointnet++: Deep hierarchical feature learning on point sets in a metric space." *Advances in Neural Information Processing Systems* **30**.
9. Chibane, J. and G. Pons-Moll (2020). "Neural unsigned distance fields for implicit function learning." *Advances in Neural Information Processing Systems* **33**: 21638-21652.
10. Liu, M., et al. (2020). Meshing point clouds with predicted intrinsic-extrinsic ratio guidance. *Computer Vision–ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part VIII* **16**, Springer.
11. Rakotosaona, M.-J., et al. (2021). Learning delaunay surface elements for mesh reconstruction. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.
12. Li, Y., et al. (2018). "Pointcnn: Convolution on x-transformed points." *Advances in Neural Information Processing Systems* **31**.



13. Sharp, N. and M. Ovsjanikov (2020). Pointtrinet: Learned triangulation of 3d point sets. Computer Vision–ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part XXIII 16, Springer.
14. Hanocka, R., et al. (2020). "Point2mesh: A self-prior for deformable meshes." arXiv preprint arXiv:2005.11084.
15. Daroya, R., et al. (2020). REIN: Flexible mesh generation from point clouds. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops.
16. Zhou, Y., et al. (2023). "Quadrilateral Mesh Generation Method Based on Convolutional Neural Network." Information 14(5): 273.