

بازسازی نقشه‌ی اکوسیستم‌های زمین به صورت مجازی با توجه به عوامل محیطی

محقق: محمد مهدی دیبایی

استاد راهنما: امیرهادی مینوفام

۱۳۹۷

دانشگاه علم و فرهنگ

فهرست

۱	مقدمه
۲	تولید محتوای رویه‌ای
۲	۲.۱ مقدمه
۲	۲.۲ چرا از تولید محتوای رویه‌ای استفاده میکنیم؟
۲	۲.۳ انواع روش‌های تولید محتوای رویه‌ای
۳	۲.۳.۱ همزمان و غیرهمزمان
۳	۲.۳.۲ ضروری و اختیاری
۳	۲.۳.۳ درجه‌ی کنترل
۳	۲.۳.۴ عمومی و تطبیقی
۳	۲.۳.۵ اتفاقی و قطعی
۴	۲.۳.۶ ساختمانی و تولید و آزمایش
۴	۲.۳.۷ تولید خودکار یا همکارانه
۴	۲.۴ چالش‌ها و چشم‌اندازها
۴	۲.۴.۱ تولید محتوای رویه‌ای چندمرحله‌ای و کامل
۴	۲.۴.۲ طراحی بازی‌های مبتنی بر تولید محتوای رویه‌ای
۴	۲.۴.۳ تولید بازی‌های کامل
۵	۳ شبکه‌ی عصبی مصنوعی
۷	۴ جمع‌آوری اطلاعات زیستی جغرافیایی
۷	۴.۱ مقدمه
۷	۴.۲ زمین و زیست‌بوم‌های آن
۷	۴.۲.۱ بیابان
۷	۴.۲.۲ آب
۸	۴.۲.۳ جنگل
۸	۴.۲.۴ چمن‌زار
۸	۴.۲.۵ تندرا
۸	۴.۳ عوامل موثر در شکل‌گیری زیست‌بوم‌های زمین و الگوهای آنها
۹	۴.۳.۱ جمع‌آوری داده‌ها
۹	۴.۴ بررسی داده‌ها
۱۰	۴.۵ پردازش داده‌ها
۱۰	۴.۵.۱ یکپارچه‌سازی ساختار داده‌ها
۱۱	۴.۵.۲ نرمال‌سازی داده‌ها
۱۲	۵ طراحی و پیاده‌سازی مدل‌های هوش مصنوعی
۱۲	۵.۱ طراحی سطح بالا

۱۴.....	۵.۲ محیط آزمایش‌ها.....
۱۴.....	۵.۳ پارامترهای مدل‌ها.....
۱۵.....	۵.۳.۱ مدل زیست‌بوم‌ها.....
۱۶.....	۵.۳.۲ مدل‌های دما و میزان بارش.....
۱۷.....
۱۷.....	۵.۴ نتایج آزمایش‌ها.....
۱۷.....	۵.۴.۱ مدل زیست‌بوم‌ها.....
۱۸.....	۵.۴.۲ مدل‌های دما و میزان بارش.....
۱۹.....	۵.۵ تولید خروجی.....
۲۰.....	۶ تولید نقشه‌های جدید.....
۲۰.....	۶.۱ عوامل نقشه‌ساز.....
۲۰.....	۶.۱.۱ عامل قاره‌ساز.....
۲۲.....	۶.۱.۲ عامل کوه‌ساز.....
۲۴.....	۶.۱.۳ عامل ارتفاع تصادفی.....
۲۵.....	۶.۲ الگوریتم کلی.....
۲۷.....	۶.۳ محیط گرافیکی نقشه‌ساز.....
۲۹.....	۷ جمع‌بندی.....
۲۹.....	۸ کارهای آینده.....

۱ مقدمه

زمین، محیط زندگی انسان هاست و از ابتدا این محیط طبیعی اطراف ما الهام بخش بسیاری از فعالیتها و محتوای تولید شده توسط ما انسانها بوده است. در همین مسیر، بازیهای کامپیوتری معمولاً در محیطهایی مشابه زمین و یا الهام گرفته از آن برقرارند، و از این رو همواره نیاز به طراحی محیطهایی برای این بازیها به صورتی که مشابه محیط واقعی باشند.

حوزهی تولید رویه‌ای محتوا با هدف کاهش نیاز به صرف زمان‌های طولانی انسانی برای تولید محتوا، به خصوص در زمینه‌ی بازی‌های کامپیوتری است. از این رو، تولید نقشه‌های بازی‌ها نیز از اهداف اصلی این حوزه است و در حال حاضر در بسیاری از بازی‌های کامپیوتری از این فرایندها برای تولید نقشه‌ها استفاده می‌شود. اما این نقشه‌های تولید شده یا دارای بافت زیست‌بومی نیستند، و یا اگر هستند، به صورت الگوهای ساده‌ای از طریق تعریف شرط‌های خاص تولید می‌شوند.

در دهه‌ی اخیر شاهد رشد بیش از پیش استفاده‌های عملی از شبکه‌های عصبی مصنوعی در حوزه‌ی یادگیری ماشینی و هوش مصنوعی هستیم، چرا که این فناوری قدرت خود را در کشف الگوها اثبات کرده است و این الگو می‌توانند برای پیش‌بینی بسیاری از اتفاق‌ها استفاده شوند. این رشد مدیون داده‌های زیاد و قابل دسترس و همچنین تولید پردازنده‌های ماتریسی قوی در دهه‌ی اخیر است.

در این تحقیق ما سعی در حل مسئله‌ی تولید بافت‌ها زیست‌بومی برای نقشه‌های تولید شده توسط روش‌های تولید رویه‌ای محتوا با استفاده از مدل‌های هوش مصنوعی مبتنی بر شبکه‌های عصبی مصنوعی داریم. برای حل این مسئله از داده‌های موجود در مورد کره‌ی زمین شامل داده‌های جغرافیایی (ارتفاعات، عرض جغرافیایی، فاصله از دریا)، آب و هوا (دما و میزان بارش) و دسته‌بندی‌های زیست‌بومی کره‌ی زمین استفاده می‌کنیم که به صورت رایگان توسط سازمان‌های مرتب در اختیار عموم قرار گرفته‌اند. پس از طراحی مدل هوش مصنوعی سعی در پیاده‌سازی یک نقشه‌ساز ساده برای تولید نقشه‌ها می‌کنیم و در نهایت با اعمال مدل‌های هوش مصنوعی بر روی این نقشه‌ها موفقیت خود را می‌سنجیم.

در نهایت با توجه به محدود بودن داده‌های موجود و ارتباط غیرخطی و پیچیده‌ی میان زیست‌بوم‌ها متوجه سختی اعمال این مدل‌های هوش مصنوعی بر محیط‌های به جز کره‌ی زمین (هرچند الهام گرفته از آن) می‌شویم. در حالی که مدل‌های ما روی کره‌ی زمین به خوبی پاسخ می‌دهند، در محیط‌های نا آشنا پاسخی با معیار موفقیت پایین از آنها دریافت می‌شود.

۲ تولید محتوای رویه‌ای

۲.۱ مقدمه

تولید محتوای رویه‌ای^۱ را به عنوان روشی الگوریتمی برای تولید محتوای تعریف میکنند که در موارد عام، اشاره به محتوای مورد استفاده در بازی‌های ویدیویی را دارد.

یک واژه‌ی کلیدی در این تعریف، کلمه‌ی «محتوا^۲» است که باید به صورت مشخص تر تعریف شود. در تعریف تخصصی، محتوا اشاره به موجودیت‌هایی دارد که در بازی وجود دارند که شامل مراحل، کاراکترها، خودروها، قوانین بازی، بافت‌ها، صداها، نقشه‌ها و دیگر موارد می‌شود. موتور بازی‌سازی به خودی خود یک محتوا به حساب نمی‌آید، در نتیجه تولید محتوای رویه‌ای در مورد تولید یک موتور بازی‌سازی نیست. همچنین نحوه‌ی رفتار شخصیت‌های غیرانسانی^۳ در بازی‌ها نیز که معمولن با الگوریتم‌های هوش مصنوعی پیاده‌سازی می‌شود نیز بخشی از محتوای مورد تولید توسط PCG نیست.

کلمات «تولید^۴» و «رویه‌ای^۵» نیز اشاره به این دارند که ما برای تولید چیزی، از الگوریتم‌ها یا رویه‌های کامپیوتری استفاده می‌کنیم. یک روش «تولید محتوای رویه‌ای»، روشی است که ورودی‌هایی را مربوط به محتوای مورد نظر می‌گیرد و اجرا می‌شود و خروجی‌ای تولید می‌کند که یک نوع محتوا است. یک سیستم تولید محتوای رویه‌ای، سیستمی است که در آن از روش‌های تولیدی استفاده می‌شود تا به صورت جامع‌تر محتوا را تولید کند.

۲.۲ چرا از تولید محتوای رویه‌ای استفاده میکنیم؟

اولین دلیلی که برای استفاده از تولید محتوای رویه‌ای به ذهن میرسد، از بین بردن نیاز به طراح‌های انسانی است که زمان خود را صرف تولید محتوای بازی کنند. نیروی انسانی گران و کند است به نسبت کامپیوترها، و هرروزه شاهد این هستیم که نیاز بیشتری به نیروهای انسانی وجود دارد. میزان ساعات انسانی که انسان‌ها صرف تولید محتوای بازی‌ها میکنند به صورت ثابت در حال افزایش بوده است و امروزه معمول است که کمپانی‌های بزرگ بازی‌سازی، صداها نفر را برای تولید محتوا در طول زمان چند سال استخدام کنند تا محتوای بازی‌هایشان را تولید کنند. می‌توان با استفاده از الگوریتم‌های تولید محتوای رویه‌ای نیاز به اکثر این افراد را کاهش داد و محصولاتی با کیفیت هم‌سطح و یا بالاتر را در زمان کوتاه‌تر و ارزان‌تر تولید کرد.

البته این روش‌ها قرار بر گرفتن کامل جای طراحان و هنرمندان را ندارند، بلکه در بسیاری از موارد این روش‌ها به عنوان ابزاری برای کمک به انسان‌ها برای افزایش سرعت و عدم نیاز به کارهای تکراری رو روتین طراحی و استفاده می‌شوند.

همچنین، این متدها به دلیل نداشتن تعصب‌های ذهنی و احساسی ما انسان‌ها، میتوانند دامنه‌ی خلاقیت بازتری داشته باشند. هرچند انسان‌ها خلاق هستند و میتوانند محتوایی خلاقانه تولید کنند، اما کامپیوترها به دلیل داشتن دید وسیع‌تر و نداشتن وابستگی‌های احساسی و یا الحام‌گیری از دیگر انسان‌ها، میتوانند محتوایی تولید کنند که دور از ذهن انسان‌ها، اما کاربردی باشند.

۲.۳ انواع روش‌های تولید محتوای رویه‌ای

روش‌های مختلفی با رویکردهای متفاوت برای حل مسئله‌ی تولید محتوای رویه‌ای وجود دارند. در این قسمت به دسته بندی‌ای جامع از این روش‌ها می‌پردازیم.

Procedural Content Generation	۱
Content	۲
NPC: Non-player Character	۳
Generation	۴
Procedural	۵

۲.۳.۱ همزمان و غیرهمزمان

محتوا می‌تواند به صورت همزمان^۱، در حینی که بازیکن در حال انجام بازی یا کاوش محیط است تولید شود، یا به صورت غیرهمزمان^۲، در یک مرحله تولید و سپس استفاده شود. تولید غیرهمزمان محتوا می‌تواند برای تولید محتواهای پیچیده و عمیق مانند نقشه‌ها استفاده شود. مثالی از بازی‌هایی با تولید محتوای همزمان، Left 4 Dead 2 است که در این بازی، برای مهیج نگه‌داشتن بازی و درگیر نگه‌داشتن بازیکن، با توجه به رفتارهای او و نحوه‌ی بازی او، محتوای داخل بازی تغییر کرده و خود با بازیکن وفق می‌دهد.

۲.۳.۲ ضروری و اختیاری

از روش‌های تولید محتوای رویه‌ای می‌توان برای تولید محتواهای ضروری بازی، مثل اجسام یا قوانینی که برای به پایان رساندن و پیش‌روی بازی الزامی هستند استفاده کرد، و یا از آن برای تولید محتوای اختیاری و جانبی استفاده کرد. در تولید محتوای ضروری، باید ضمانتی وجود داشته باشد که محتوای تولید شده اشتباه نیست، اما در مورد محتوای اختیاری همچنین نیازی مطرح نیست.

۲.۳.۳ درجه‌ی کنترل

در روش‌های تولید محتوای رویه‌ای، میتوان میزان کنترل روی نتیجه‌ی تولید شده توسط روش را به صورت‌های متفاوت را می‌توان در اختیار داشت. برخی از روش‌ها از یک عدد تصادفی کار خود را شروع می‌کنند و هرزمان که یک عدد تکراری به آنها داده شود، خروجی تکراری تولید می‌کنند. در این روش‌ها کنترل در حداقل خود است و استفاده کننده از روش نمی‌تواند مشخصات محتوای مورد نظر را مشخص کند یا تغییر دهد. اما در برخی روش‌ها می‌توان پارامترهایی را برای محتوا تعریف کرد تا محتوای تولید شده از آنها تبعیت کند.

۲.۳.۴ عمومی و تطبیقی

محتوای عمومی، بدون در نظر گرفتن بازیکن تولید می‌شوند اما محتوای تطبیقی، با توجه به رفتار بازیکن تولید می‌شوند. اکثر بازی‌ها از روش‌های عمومی برای تولید محتوای رویه‌ای استفاده میکنند اما برخی بازی‌ها مثل بازی Galactic Arms Race از روش تطبیقی برای تولید اسلحه‌های جذاب برای کاربران استفاده می‌کند که با توجه به تاریخچه‌ی استفاده‌ی بازیکن از اسلحه‌ها، اسلحه‌هایی که می‌توانند برای کاربر جذاب‌تر باشند را در اختیار او قرار میدهند.



تصویر ۲.۱: تصویر نمایانگر سلاح‌های تولید شده با تولید رویه‌ای محتوا از بازی Galactic Arms Race

۲.۳.۵ اتفاقی و قطعی

در روش‌های قطعی، می‌توان یک خروجی را مکررن با دادن ورودی‌های ثابت بازتولید کرد، اما در روش‌های اتفاقی، معمولن ممکن نیست یک خروجی را دو بار تولید کرد چرا که به صورت درونی از اطلاعات تصادفی استفاده می‌کنند.

Online ۱
Offline ۲

۲.۳.۶ ساختمانی و تولید و آزمایش

در روش ساختمانی، در یک اجرا کل محتوا تولید می‌شود، مثال معمول آن تولید نقشه‌ی بازی‌ها است که به صورت تک مرحله‌ای ساخته می‌شوند. در مقابل، در روش تولید و آزمایش، در هر مرحله محتوایی تولید می‌شود، سپس برای کیفیت آزمایش می‌شود و تا زمانی که کیفیت مناسب مورد نظر بدست نیاید، محتوا بازتولید می‌شود.

۲.۳.۷ تولید خودکار یا همکارانه

در تولید خودکار، تمام مراحل تولید محتوا را خود روش انجام می‌دهد. البته که باید روش ورودی‌هایی را از انسان‌ها بگیرد تا بتواند کار خود را انجام دهد، اما در میان کار، انسان‌ها دخالتی در تولید محتوا ندارند. اما روشی دیگر که جدیداً مورد توجه قرار گرفته است، تولید همکارانه محتواست که در آن، روش‌های تولید محتوای رویه‌ای به کمک انسان‌ها به صورت همکارانه محتوا را تولید می‌کنند. برای مثال، ممکن است یک انسان نقشه‌ی کلی یک مرحله را طراحی کند، و کامپیوتر نقصان‌های آن را برطرف و جزئیاتی به آن اضافه کند.

۲.۴ چالش‌ها و چشم‌اندازها

مانند دیگر مباحث مورد تحقیق، تولید محتوای رویه‌ای نیز دارای چشم‌اندازهایی است که به تحقیق‌های کنونی این چشم‌اندازها را از اهداف عالی خود می‌بینند. این چشم‌اندازها را می‌توان به عنوان چالش‌های موجود و مسائل حل نشده‌ی این مبحث نیز دانست.

۲.۴.۱ تولید محتوای رویه‌ای چندمرحله‌ای و کامل

چشم‌انداز موجود برای این ایده، این است که با ارائه‌ی مجموعه‌ای از قوانین و یک موتور بازی‌سازی به الگوریتم تولید محتوای رویه‌ای، یک بازی کامل شامل تمامی محتوا و مراحل بازی تولید کند که این محتوا و مراحل با یکدیگر هماهنگی داشته باشند، به گونه‌ای که محیط بازی قابل باور و قابل درک توسط انسان باشد.

۲.۴.۲ طراحی بازی‌های مبتنی بر تولید محتوای رویه‌ای


ایده‌ای ارائه شده این است که بتوانیم بازی‌هایی بسازیم که تولید محتوای رویه‌ای بخشی اساسی و کلیدی از بازی باشد و بدون آن، بازی معنی‌ای نداشته باشد و نتوان تولید محتوای رویه‌ای را به سادگی با چیزی جایگزین کرد.

۲.۴.۳ تولید بازی‌های کامل

در این آخرین سطح، ایده تولید بازی‌های کامل است. نه تنها محتوا و مراحل بازی، بلکه قوانین بازی، سیستم پاداش‌دهی و هرچیز مربوط به بازی شامل تولید آن می‌شود. تا به حال تلاش‌هایی برای تولید قوانین بازی‌ها شده است اما معمولاً این قوانین بسیار ساده هستند.

۳ شبکه‌ی عصبی مصنوعی

با الحام از شبکه‌های عصبی مغز، از سال ۱۹۴۳ اولین مدل‌های ریاضی برای پیاده‌سازی شبکه‌های عصبی مصنوعی^۱ شکل گرفتند. ایده‌ی پیاده‌سازی شبکه‌های عصبی مصنوعی در کامپیوتر از ابتدا تا دهه‌ی اخیر، نتوانسته بود به صورت کاربردی استفاده شود چرا که قدرت محاسباتی کافی برای پیاده‌سازی این مدل‌ها در کامپیوتر به اندازه کافی وجود نداشت. اما در دهه‌ی اخیر با پیشرفت کارت‌های گرافیک^۲ ها که امکان محاسبات همزمان ماتریسی را با سرعت بسیار بالا به همراه دارند، این حوزه‌ی تحقیقاتی بیش از پیش مورد توجه قرار گرفته و در حال پیشرفت است.



تصویر ۳.۱: تصویری ساده‌سازی شده از ساختار کلی یک شبکه‌ی عصبی مصنوعی

شبکه‌های عصبی مصنوعی به طور کلی متشکل از لایه‌هایی هستند که با وزن‌هایی (که در مرحله‌ی محاسباتی با ماتریس پیاده‌سازی می‌شوند) به یکدیگر متصل هستند، و معمولن هر لایه دارای یک تابع فعال‌ساز^۳ است که معمولن یک تابع غیر خطی است. همچنین اضافه کردن گرایش^۴ پس از ضرب وزن‌ها در هر لایه یکی از روش‌های معمول برای افزایش کارایی شبکه عصبی است.

از میان این لایه‌ها، اولین لایه را لایه‌ی ورودی^۵، لایه‌ی آخر را لایه‌ی خروجی^۶ و لایه‌های میانی را لایه‌های پنهان^۷ می‌نامیم.

به طور کلی مسائلی که در چهارچوب شبکه‌های عصبی حل می‌شوند را می‌توان به صورت زیر توصیف کرد:

هر لایه از شبکه‌ی عصبی مصنوعی دارای مجموعه بردارهایی از وزن‌ها، گرایش‌ها و یک تابع فعال‌ساز است. اگر خروجی هر لایه را l_i نام دهیم و لایه‌ها در رنج $i \in [0, L]$ باشند، تعریف زیر را داریم:

$$l_i = f_i(w_i \cdot l_{i-1} + b_i)$$

در این تعریف f_i تابع فعال‌ساز، w_i وزن‌ها و b_i گرایش‌های لایه‌ی i هستند. لایه‌ی ورودی را لایه‌ی صفر در نظر می‌گیریم که تعریف آن به صورت زیر است:

$$l_0 = x$$

که x داده‌های ورودی شبکه هستند. لایه‌ی خروجی را با l_L نشان می‌دهیم که نمایانگر آخرین لایه است.

هدف در شبکه‌ی عصبی پیدا کردن پارامترهای بهینه‌ای است که بتوانند به ازای ورودی‌های x خروجی‌های مناسب y را بدهند. این کار باید به ورودی‌هایی که شبکه تا به حال ندیده اجماع پیدا کند، یعنی به ازای ورودی‌هایی \hat{x}_i که شبکه تا به حال ندیده، و ما پاسخ‌های آنها را می‌دانیم، انتظار می‌رود پس از عملیات بهینه‌سازی شبکه بتواند خروجی مناسب را تولید کند.

Artificial Neural Networks	۱
GPU	۲
Activation Function	۳
Bias	۴
Input Layer	۵
Output Layer	۶
Hidden Layer	۷

روش معمول بهینه‌سازی شبکه‌های عصبی، تکنیکی به اسم پس‌انتشار^۸ است که در آن، پس از اعمال یک ورودی (یا مجموعه ورودی) به شبکه‌ی عصبی، خروجی آن را مشاهده می‌کنیم و با خروجی صحیح مقایسه می‌کنیم، میزان خطای شبکه را نسبت به پاسخ واقعی حساب می‌کنیم و این میزان خطا را به صورت زنجیره‌وار در مشتق ضرب‌های ماتریسی انجام شده در هر لایه ضرب می‌کنیم و پارامترها را با این مقدار بروز رسانی می‌کنیم تا شبکه را به سمتی هدایت کنیم که برای این ورودی، خروجی‌هایی نزدیک‌تر به خروجی صحیح تولید کند. معمولاً خطای شبکه با استفاده از «خطای میانگین مربعات» استفاده می‌کنیم که به صورت زیر تعریف می‌شود.

$$C = \frac{1}{2n} \sum_x \|y(x) - l_L(x)\|^2,$$

که $y(x)$ پاسخ صحیح مربوط به ورودی x ، n تعداد جفت‌های ورودی و خروجی و $l_L(x)$ خروجی نهایی شبکه‌ی عصبی برای ورودی x است.

۴ جمع آوری اطلاعات زیستی جغرافیایی

۴.۱ مقدمه

لازمه‌ی هر سیستم شبیه‌سازی، جمع‌آوری داده و تبدیل آنها به اطلاعاتی جامع و کاربردی برای تحلیل و استخراج معنا از آنهاست. در این تحقیق نیز، داده‌های جغرافیایی، زیستی، اطلاعات آب و هوا و دیگر داده‌های مرتبط را جمع‌آوری کردیم و دست به تحلیل آنها زدیم. همچنین، لازمه‌ی تحلیل معنایی این داده‌ها، داشتن درکی مناسب از زمین‌شناسی و تاثیر شرایط متفاوت بر نوع زیست‌بوم‌های زمین است. در این بخش به برخی از این ادراک و داده‌های مورد استفاده و روش‌های جمع‌آوری و تولید آنها می‌پردازیم.

۴.۲ زمین و زیست‌بوم‌های آن

زیست‌بوم‌ها^۱ مناطق بزرگ بومی^۲ هستند که حیوانات و گیاهان خود را با آن وفق می‌دهند. این مناطق را با مشخصاتی همچون دما، آب و هوا، پستی و بلندی‌ها، خاک و زندگی گیاهی آنها تفکیک می‌کنند.

زیست‌بوم‌ها اکوسیستم^۳ نیستند، بلکه هر زیست‌بوم می‌تواند شامل تعدادی اکوسیستم‌های متفاوت باشد. اکوسیستم‌ها اجتماعی از جانداران و غیرجانداران در یک محیط است که با ارتباط با یکدیگر زندگی میکنند و با یکدیگر تعامل دارند. اگر با دقت مشاهده کنید، می‌توان اکوسیستم‌های متفاوتی را در یک زیست‌بوم تشخیص داد، هرچند که تمام این اکوسیستم‌های موجود در یک زیست‌بوم دارای شباهت‌هایی هستند.

در مجموع، پنج دسته بندی بزرگ از زیست‌بوم‌ها وجود دارد که به توضیح مختصری از آنها می‌پردازیم.

۴.۲.۱ بیابان

بیابان‌ها حدود ۲۰ درصد از سطح زمین را پوشش می‌دهند و مشخصه‌ی شاخص آنها، میزان بسیار ناچیز یا نبود باران است. بیابان‌ها معمولاً دارای دماهای بسیار بالایی هستند که ناشی از نبود پوشش گیاهی، پوشش ابر، میزان رطوبت ناچیز و تابش مستقیم خورشید به سطح زمین است. پوشش خاکی سطحی و سنگی است که به دلیل نبود شستگی سنگ‌ها است و تعداد محدودی از انواع گیاهان را پشتیبانی می‌کند.

گیاهانی که در این مناطق رشد می‌کنند معمولاً کاکتوس‌ها و بوته‌هایی هستند که دارای توانایی نگه‌داری آب هستند. همچنین این گیاهان کمتر برگ دارند و از ساقه‌هایشان برای فتوسنتز^۴ استفاده می‌کنند.

۴.۲.۲ آب

زیست‌بوم‌های آبی به دو دسته‌ی زیست‌بوم‌های آب‌شیرین (برکه‌ها، دریاچه‌ها، رود و چشمه‌ها) و زیست‌بوم‌های دریایی (اقیانوس‌ها، صخره‌های مرجانی و پایرودها) تقسیم می‌شوند و جمعاً حدود ۷۳ درصد سطح زمین را پوشش می‌دهند.

نوع زندگی در این زیست‌بوم‌ها بسته به مشخصاتی چون میزان نور وارد شده به آب، میزان نمک محلول در آب، فشار و دما بستگی دارد. در زیست‌بوم‌هایی که دارای تابش بیشتر نور هستند، زندگی‌های گیاهی بیشتر مورد رشد هستند و جلبک‌ها و پلانکتون‌ها جمعیت بیشتری را متشکل هستند. بدنه‌های آبی که در فصل سرما یخ‌میزند، یا در فصل خشک و گرم خشک می‌شوند معمولاً دارای تنوع جاندارانی کمتری هستند.

Biome	۱
Ecological	۲
Ecosystem	۳
Photosynthesis	۴

۴.۲.۳ جنگل

جنگل‌ها پوششی ۳۰ درصدی را بر سطح زمین دارند و از ارزش فوق‌العاده‌ای برای زندگی و زمین برخوردارند. جنگل‌ها ذخیره‌گاه کربن هستند و تاثیر مهمی در کنترل آب و هوا دارند. این زیست‌بوم منبع مهمی برای بسیاری از مواد اولیه‌ی مورد نیاز انسان‌هاست و باور بر این است که جنگل‌ها دارای بیشترین تنوع زیستی هستند، به طوری که یک بخش کوچک از جنگل‌های بارانی می‌تواند محل زندگی میلیون‌ها حشره، پرنده، حیوانات و گیاهان باشد.

دمای زیست‌بوم‌های جنگلی معمولاً در طول سال بسیار بالا هستند، ولی در سطح جنگل دما بسیار خنک تر است، چرا که وجود پوشش گیاهی انبوه از تابش مستقیم نور خورشید به سطح خاکی کف جنگل جلوگیری می‌کند. میزان رطوبت و بارش بسیار زیاد است و خاک سست، در معرض هوا، بسیار اسیدی و مشمول از مواد ارگانیک در حال تجزیه است.

۴.۲.۴ چمنزار

این مناطق مورد پوشش گونه‌های محدودی از چمن‌ها هستند، همراه با درخت‌هایی با فاصله‌های زیاد. مثالی بارز از این نوع زیست‌بوم، چمنزارهای ساوانای آفریقا هستند که حدود یک سوم از کل قاره را پوشش می‌دهند. عوامل متفاوتی برای جلوگیری چمنزارها برای تبدیل شدن به جنگل وجود دارند که شامل عوامل آب و هوایی، عوامل خاکی، حیوانی و انسانی هستند.

خاک‌های این زیست‌بوم‌ها لایه‌های نازکی دارند و آب زیادی را در خود نگه نمی‌دارند. تغذیه‌ی اصلی گیاهان در این زیست‌بوم، از مواد ارگانیک در حال پوسیدگی و تجزیه‌ی چمن‌های مرده است. میزان باران متعادل است و به اندازه‌ای نیست که باعث سیل‌های بزرگ شود.

دما در این نوع زیست‌بوم‌ها مفرط است، با تابستان‌های به شدت گرم و زمستان‌های منجمد کننده.

۴.۲.۵ تندرا

سردترین زیست‌بوم زمینی، تندرا است که دارای کمترین ظرفیت برای تنوع گونه‌هاست. این زیست‌بوم دارای میزان بارش بسیار کم و دمایی منجمد کننده است، و حدود ۲۰ درصد از سطح زمین را پوشش می‌دهد.

گیاهان موجود در تندراها کوتاه هستند و نزدیک به یکدیگر رشد می‌کنند، که شامل خزه‌ها، بوته‌ها و گل‌سنگ‌ها هستند که برای فتوسنتز در دماهای بسیار پایین نیز وفق داده شده‌اند.

۴.۳ عوامل موثر در شکل‌گیری زیست‌بوم‌های زمین و الگوهای آنها

شکل‌گیری هر یک از زیست‌بوم‌ها بر روی زمین، بر اساس شرایطی مورد تاثیر قرار می‌گیرد که این شرایط شامل دما، آب و هوا، ارتفاع و میزان بارش هستند.

الگویی نیز میان عرض جغرافیایی^۱ (فاصله از خط استوا) هر نقطه از زمین، همراه با ارتفاع آن نقطه از سطح دریا و دمای آن نقطه نیز وجود دارد، در نتیجه می‌توانیم با داشتن عرض جغرافیایی و ارتفاع، حدسی در مورد دمای هر نقطه بزنیم. همچنین ارتباطی میان عرض جغرافیایی، ارتفاع و فاصله از دریا، با میزان بارش هر نقطه وجود دارد؛ پس می‌توانیم با پیدا کردن این الگو، تنها با دانستن عرض جغرافیایی، فاصله از دریا و ارتفاع هر نقطه، دما و میزان بارش آن، که از مهم‌ترین عوامل در تشخیص نوع زیست‌بوم آن هستند را حدس بزنیم.





برای پیدا کردن این الگو، از شبکه‌های عصبی که بیش از این توضیح دادیم استفاده می‌کنیم که به طور خاص برای تشخیص الگوها بسیار مناسب هستند. با این کار، می‌توانیم تنها با داشتن برخی مشخصات اولیه به دما، میزان بارش و نوع زیست‌بوم هر نقطه دست پیدا کنیم که این باعث ساده شدن کار ما در مرحله‌ی استفاده از نقشه‌ها و همچنین تولید آنها می‌شود.

برای این کار ابتدا لازم است مجموعه داده‌هایی از دما، ارتفاع، میزان بارش و نوع زیست‌بوم‌های زمین جمع‌آوری کنیم و سپس با ارائه‌ی ارتفاع، عرض جغرافیایی و فاصله هر نقطه از دریا به شبکه‌ی عصبی به عنوان ورودی، و ارائه‌ی دما، میزان بارش و نوع زیست‌بوم به عنوان خروجی‌های مورد نظر، شبکه را برای پیش‌بینی و تشخیص الگوی بین این داده‌ها آموزش دهیم.

۴.۳.۱ جمع‌آوری داده‌ها

برای جمع‌آوری داده‌ها از منابع مختلفی استفاده کردیم که در زیر اشاره مختصری به هریک از آنها می‌کنیم.

- برای اطلاعات دمای نقاط مختلف کره‌ی زمین، از مجموعه داده‌ی تولید شده توسط دانشگاه Delaware استفاده کردیم که اطلاعات دمایی هر نقطه از زمین را از سال‌های ۱۹۰۰ تا ۲۰۱۷ میلادی را شامل می‌شود. [لینک دسترسی به داده‌ها](#).
- برای اطلاعات میزان بارش نیز از مجموعه داده‌های مشابهی از دانشگاه Delaware استفاده میکنیم که همان محدوده سال‌های ۱۹۰۰ تا ۲۰۱۷ را پوشش می‌دهد. [لینک دسترسی به داده‌ها](#).
- برای ارتفاع، از داده‌های شاتل فضایی ناسا که با نام ^۱SRTM به صورت عمومی منتشر شده‌است استفاده می‌کنیم. [لینک دسترسی به داده‌ها](#).
- برای دسته بندی زیست‌بوم‌های زمین، از مجموعه داده‌ی ^۲TEOW که شامل دسته بندی‌های اکوسیستمی کوچک زمین همراه با زیست‌بوم‌های آنهاست استفاده می‌کنیم. [لینک دسترسی به داده‌ها](#).



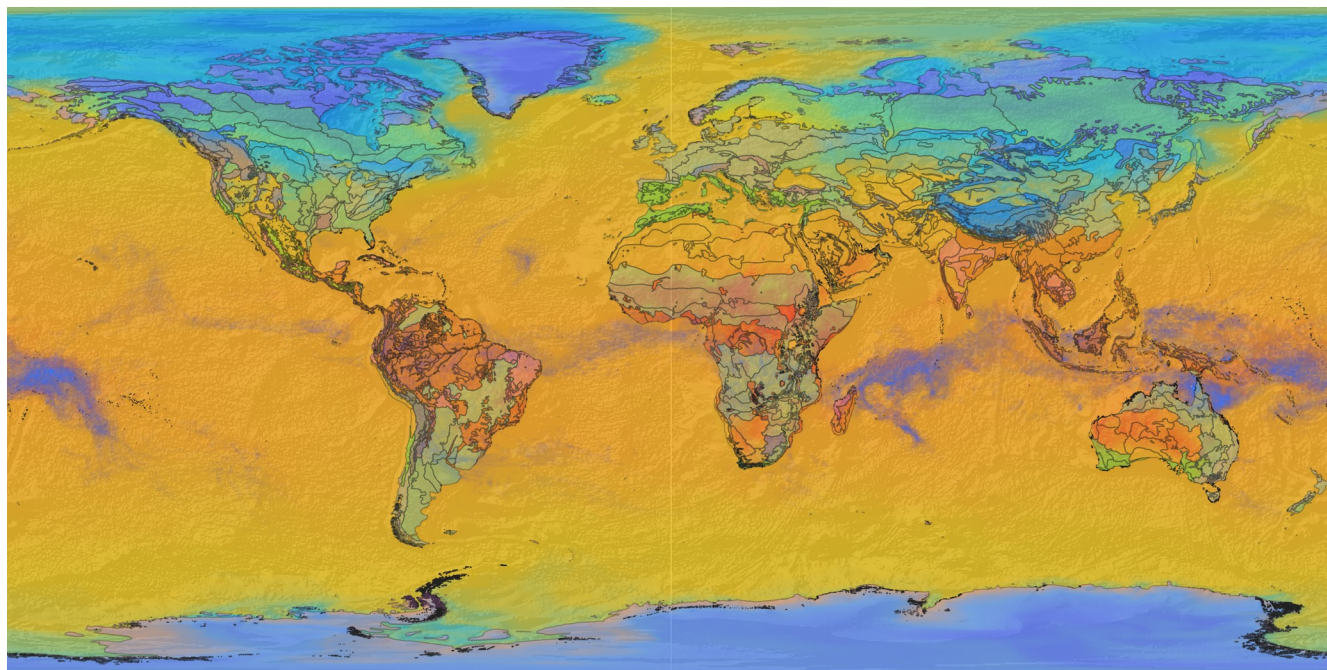
تصویر ۴.۱: به ترتیب از بالا چپ، ساعت‌گرد: نقشه‌ی زیست‌بوم‌های زمین، نقشه‌ی بارش، نقشه‌ی ارتفاعات و نقشه‌ی دما

۴.۴ بررسی داده‌ها

پس از جمع‌آوری داده‌ها، به بررسی آنها با استفاده از ابزار پردازش داده‌های جغرافیایی می‌پردازیم. برای این کار از نرم‌افزار QGIS استفاده می‌کنیم و داده‌های دریافت شده را به صورت ظاهری بررسی می‌کنیم (تصویر ۴.۱). در مرحله‌ی بعد این داده‌ها را به صورت لایه‌هایی بر روی یکدیگر قرار می‌دهیم. در این مرحله ممکن است نیاز به تغییراتی در سیستم‌های مختصات داده‌ها احساس شود. در مورد

۱ Shuttle Radar Topography Mission
۲ Terrestrial Ecoregions of the World

داده‌های ما، داده‌ها دارای سیستم‌های مختصات متفاوت از یکدیگر بودند و در نتیجه لازم شد تا آنها را به سیستم مختصاتی یکسانی^۳ تبدیل کنیم. نتیجه تصویر ۴.۲ است.



تصویر ۴.۲: همسان‌سازی نقشه‌های مختلف به صورت لایه‌هایی بر روی یکدیگر

۴.۵ پردازش داده‌ها

پس از جمع‌آوری داده‌ها، لازم است آن‌ها را در قالب فرمتی جامع قرار دهیم تا بتوانیم از داده‌ها در کنار یکدیگر استفاده کنیم. همچنین برای استفاده‌ی این داده‌ها در پیاده‌سازی مدل هوش مصنوعی، لازم است داده‌ها را در صورت لزوم به حالت عددی، و در حالت عددی، نرمال‌سازی کنیم.

۴.۵.۱ یکپارچه‌سازی ساختار داده‌ها

در مرحله‌ی اول ساختاری یک‌پارچه تعریف کرده و داده‌های در دست را در این ساختار قرار می‌دهیم. ساختار مورد نظر ما به شکل زیر است:

جدول ۴.۱: ساختار تعریف شده برای جمع‌آوری داده‌ها در یک قالب یک‌پارچه.

#	longitude	latitude	biome	elevation	distance_to_water	temp_winter_1900	precip_winter_1900	temp_spring_1900	precip_spring_1900
0	-179	-89	10	3007	1.0	-33.95	53.20	-55.63	0.4
1	-179	-88	10	3110	1.0	-32.85	54.30	-53.63	0.23
2	-179	-87	10	3008	1.0	-31.40	56.50	-51.2	0.56

برای یکپارچه‌سازی داده‌های خام اولیه و درج آنها در این ساختار از ابزارهای کتابخانه‌ی pandas زبان پایتون استفاده کردم و می‌توان فرایند کلی این عمل را به صورت زیر خلاصه کرد:

۱. خواندن اطلاعات خام دما و بارش نقاط مختلف جهان برای سال‌های ۱۹۰۰ تا ۲۰۱۷: این اطلاعات به صورت فایل‌های جدولی با فرمت CSV هستند و از pandas.read_csv برای خواندن این اطلاعات استفاده کردم.

۲. خواندن اطلاعات خام نقشه‌ی اکوسیستم‌های زمین: این اطلاعات با فرمت جغرافیایی Shapefile در اختیار عموم قرار گرفته است که پس از خواندن آن، با اعمال دو عملیات جغرافیایی Buffer و Dissolve عیب‌های آن گرفته شده است. این عیب‌ها عبارتند از نقاطی تداخل اکوسیستم‌ها در نقشه‌ی خام. برای خواندن این اطلاعات و پردازش آنها از کتابخانه‌های GeoPandas و Shapely استفاده کردم.

۳. خواندن اطلاعات خام ارتفاعات سطح زمین: این اطلاعات با فرمت TIFF عرضه شده است و با استفاده از کتابخانه‌ی Rasterio می‌توان این اطلاعات را پردازش کرد.

۴. دریافت نقشه‌ی ساده‌ی قاره‌های کره‌ی زمین برای تشخیص خشکی و دریا: این نقشه در کتابخانه‌ی geopandas به صورت پیش‌فرض پشتیبانی می‌شود.

۵. به ازای هر نقطه‌ی جغرافیایی بر روی کره‌ی زمین که در عرض جغرافیایی بین -۹۰ تا ۹۰ و طول جغرافیایی بین -۱۸۰ تا ۱۸۰ هستند، اطلاعات موجود در نقشه‌های متفاوت را در از نقشه‌ها خوانده و در کنار یکدیگر قرار می‌دهیم. همچنین، برای بدست آوردن فاصله‌ی هر نقطه از دریا، با استفاده از کتابخانه‌ی Shapely و نقشه‌ی قاره‌ها، می‌توانیم این فاصله را محاسبه و به اطلاعات خود اضافه کنیم.

۶. ساخت یک قالب داده از اطلاعات محاسبه و جمع‌آوری شده و ذخیره‌ی آن روی حافظه‌ی بلندمد

نتیجه‌ی این عملیات یک فایل یکپارچه است که تمامی داده‌های مورد نیاز را در یک قالب ساده در خود جمع می‌کند. از این پس، در مراحل بعدی همیشه از این ساختار داده استفاده خواهیم کرد.

۴.۵.۲ نرمال‌سازی داده‌ها

در مرحله‌ی بعد، در جهت آماده‌سازی اطلاعات برای استفاده در مدل‌های هوش مصنوعی باید آنها را نرمال‌سازی کنیم. نرمال‌سازی فرایندی که طی آن، داده‌ها از بازه‌ی اصلی خود که می‌تواند اعدادی دلخواه باشد (حتی اعداد میلیونی)، به بازه‌ی مشترک و مورد پردازش (معمولاً بین صفر تا یک) انتقال می‌دهیم.

برای این کار، هر ستون از اطلاعات را به صورت جداگانه نرمال‌سازی می‌کنیم چرا که می‌خواهیم اطلاعات مربوط به هر ستون را از بازه‌ی پیش‌فرض خود به بازه‌ی قابل پردازش توسط مدل هوش مصنوعی ببریم. برای این کار در جهت سادگی کار، از فرمول نمره‌ی استاندارد^۲ استفاده می‌کنیم:

Data Frame	۱
Standard Score	۲

$$\frac{X - \mu}{\sigma}$$

در اینجا، μ میانگین جمعیت آماری و σ انحراف معیار است. برای محاسبه‌ی این مقادیر از کتابخانه‌ی `numpy` استفاده می‌کنیم:

```
(x - numpy.mean(x)) / numpy.std(x)
```

توجه کنید که این عملیات تنها برای داده‌های عددی اعمال می‌شود، به این معنا که این عملیات برای اعدادی که نماینده‌ی یک گونه یا نوع هستند تحت تاثیر این عمل نخواهند بود. برای مثال، اعداد موجود در ستون `biome` که نماینده‌ی هر بیوم هستند و ارزش عددی ندارند، تحت تاثیر این عمل نیستند.

بدین ترتیب، اطلاعات ما بدین شکل تغییر می‌کنند:

جدول ۴.۲: داده‌های نرمال‌سازی شده با استفاده از نمره استاندارد

#	longitude	latitude	biome	elevation	distance_to_water	temp_winter_1900	precip_winter_1900	temp_spring_1900	precip_spring_1900
0	-2.258304	-1.5794	10	1.483790	-0.863818	-1.128507	0.082717	-1.819871	-0.686706
1	-2.258304	-1.56201	10	1.566310	-0.863818	-1.079921	0.099819	-1.746688	-0.689508
2	-2.258304	-1.54462	10	1.484591	-0.863818	-1.015876	0.134022	-1.657649	-0.683903

۵ طراحی و پیاده‌سازی مدل‌های هوش مصنوعی

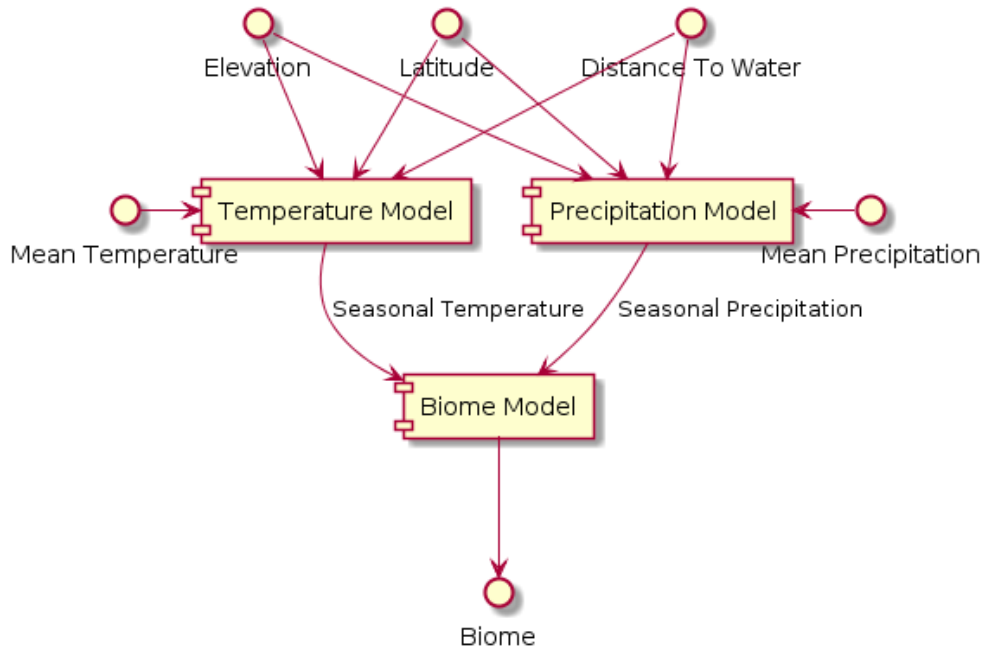
در مرحله‌ی بعد نیاز به طراحی مدل‌های هوش مصنوعی برای پیش‌بینی زیست‌بوم‌های نقشه بر اساس داده‌های ورودی داریم. در این بخش از الگوریتم‌های یادگیری ماشینی^۱، و به طور خاص‌تر از شبکه‌های عصبی مصنوعی استفاده خواهیم کرد.

۵.۱ طراحی سطح بالا

در سطح بالا، سه مدل هوش مصنوعی طراحی خواهیم کرد که هر کدام وظیفه‌ی انجام بخشی از کار را دارند. (تصویر ۵.۱)

۱. مدل اول مسئول دریافت داده‌های مربوط به ارتفاع، فاصله از دریا، عرض جغرافیایی و میانگین دمای کلی نقشه‌ی موردنظر برای هر نقطه، و تولید حدسی برای دمای چهار فصل آن نقطه در طول سال است.
۲. مدل دوم نیز مشابه مدل اول، با ورودی‌های یکسان، اما خروجی آن حدسی برای میزان بارش نقاط در چهار فصل سال است.
۳. مدل آخر، ارتفاع، فاصله از دریا، عرض جغرافیایی، دمای چهار فصل و میزان بارش چهار فصل هر نقطه‌را (که توسط مدل‌های قبلی کامل شده‌اند) دریافت کرده و حدسی در مورد زیست‌بوم نقطه مورد نظر تولید میکند.

Models



تصویر ۵.۱: شمای سطح بالای مدل‌های یادگیری ماشینی و ورودی‌ها و خروجی‌های آنها

در مرحله‌ی بعد به ساختار هریک از مدل‌ها می‌پردازیم. ساختار هر مدل شامل سه نوع لایه‌ی اصلی است: لایه‌ی ورودی^۱، لایه‌های مخفی^۲، و لایه‌ی خروجی^۳.

۱. لایه‌ی ورودی هر مدل مشخص می‌کند که ورودی‌های آن به چه ترتیب و به چه تعداد هستند.
۲. لایه‌های مخفی لایه‌های پردازش‌کننده هستند که با دریافت اطلاعات از لایه‌های پیشین خود، پس از انجام پردازشی بر روی آنها (معمولاً ضرب ماتریسی در وزن‌ها، جمع با گرایش‌ها، و اعمال تابع فعال‌ساز)، نتیجه را به لایه‌ی بعدی انتقال می‌دهند. لایه‌های مخفی می‌توانند تعداد دلخواه داشته باشند، که انتخاب این تعداد بسته به شرایط مسئله و پارامترهای موجود دارد. همچنین می‌توان هیچ لایه‌ی مخفی را در نظر نگرفت که در این صورت شبکه‌ی عصبی مصنوعی همانند یک رگرسیون خطی^۴ عمل خواهد کرد.
۳. لایه‌ی خروجی نوع و تعداد خروجی‌ها را مشخص می‌کند. به طور کلی دو نوع خروجی برای شبکه‌های عصبی مصنوعی وجود دارد:

۱. خروجی رگرسیون^۵: این نوع خروجی به صورت یک عدد حقیقی () است. در این حالت شبکه‌ی عصبی سعی در حدس زدن مقدار یک تابع حقیقی را دارد. در این تحقیق، حدس‌هایی که برای دما و میزان بارش توسط مدل ۱ و ۲ تولید می‌شوند از این نوع هستند. در این حالت تعداد خروجی‌ها برابر تعداد اعدادی است که سعی در حدس زدن آنها داریم. اگر تعداد O خروجی داشته باشیم، لایه‌ی خروجی به صورت زیر تعریف می‌شود:

Input Layer	۱
Hidden Layers	۲
Output Layer	۳
Linear Regression	۴
Regression	۵

۲. خروجی دسته‌بندی^۱: این نوع خروجی برای تشخیص دسته‌بندی‌ای برای ورودی است. برای مثال تشخیص زیست‌بوم یک نقطه، یک عمل دسته‌بندی است چرا که تعداد مشخصی دسته‌بندی گسسته وجود دارند. در این حالت معمولاً تعداد خروجی‌ها برابر با تعداد دسته‌بندی‌ها است و خروجی‌ها به صورت مقادیر صفر تا یک در نظر گرفته می‌شوند. خروجی‌ای که دارای بیشترین مقدار باشد، دسته‌بندی مورد نظر برای ورودی در نظر گرفته می‌شود.

۵.۲ محیط آزمایش‌ها

برای پیاده‌سازی شبکه‌های عصبی از فریم‌ورک Keras که بر پایه‌ی فریم‌ورک Tensorflow از شرکت گوگل است استفاده کردم که رابط آن زبان پایتون است. این فریم‌ورک اجازه‌ی پیاده‌سازی ساده‌ی مدل‌های شبکه‌ی عصبی را با استفاده از رابطی سطح بالا می‌دهد که زحمت پیاده‌سازی الگوریتم‌های متفاوت یادگیری ماشینی را از دوش محققان برمی‌دارد.

برای پیدا کردن ساختار مناسب برای مدل‌ها، لازم به انجام آزمایش بر روی ساختارهای مختلف و انتخاب بهترین ساختار بر اساس نتیجه است. برای این کار، محیط آزمایشی آماده کردم تا بتوان در آن به سادگی مدل‌های متفاوت را مقایسه کرد. برای این کار از ابزار Tune استفاده کردم که اجازه‌ی آموزش همزمان مدل‌های شبکه‌ی عصبی را با پارامترهای متفاوت که بر اساس الگوریتم Grid Search انتخاب می‌شوند را می‌دهد. با این کار توانستم آزمایش‌های متعددی روی مدل‌ها اجرا کنم و بهترین ساختارهای شبکه را پیدا کنم.

آزمایش‌ها عمدتاً بر روی تعداد لایه‌های پنهان، تعداد عصب‌های لایه‌های پنهان، ضریب یادگیری^۲ و اندازه دسته^۳ انجام گرفته‌اند. در برخی موارد الگوریتم‌های متفاوت یادگیری نیز مورد آزمایش قرار گرفتند اما در نهایت تمامی مدل‌ها از الگوریتم Adam استفاده می‌کنند.

۵.۳ پارامترهای مدل‌ها

آزمایش‌های متعددی برای هر مدل انجام شد و در نهایت پارامترها و ساختاری برای هر یک برگزیده شد. در این میان برخی پارامترها به صورت مشترک بین تمامی مدل‌ها هستند:

جدول ۵.۱: پارامترهای مشترک میان مدل‌ها

سایز دسته	۲۵۶
تعداد لایه‌های پنهان	۲
الگوریتم یادگیری	Adam
تابع فعال‌ساز لایه‌های پنهان	ELU


سایز دسته‌های متفاوتی اندازه‌گیری شدند، از سایزهای کوچک مثل ۸ و ۱۶ تا ۵۱۲ که همه توان‌هایی از عدد ۲ هستند چرا که کارت گرافیک می‌تواند با سرعت بهبودیافته‌ای بر روی این تعداد از ورودی‌ها عمل کند. در نهایت برای همه‌ی مدل‌ها سایز دسته‌ی ۲۵۶ بهترین خروجی را ارائه داد. سایز دسته مناسب می‌تواند در توانایی مدل برای تعمیم دادن رفتار خود به تمامی ورودی‌ها کمک کند؛ و طبق تحقیق‌های انجام شده توسط ... سایز دسته‌های بیشتر می‌توانند تأثیر مثبتی بر این امر داشته باشند.

تابع فعال‌ساز لایه‌های پنهان: تابع RELU بارها توانایی خود را برای بهبود آموزش مدل‌های شبکه‌ی عصبی اثبات کرده است اما این تابع می‌تواند دچار مشکل «عصب‌های مرده» شود که در این مشکل، برخی از عصب‌ها به صورت مداوم سیگنال صفر می‌دهند و از این رو، در فرایند پس‌انتشار، خطای آنها نیز صفر تلقی شده و در نتیجه این عصب‌ها تا ابد در این حالت می‌مانند. برای رفع این مشکل تابع ELU طراحی شده که این مشکل را تا حد خوبی حل می‌کند.

Classification	۱
Learning Rate	۲
Batch Size	۳

۵.۳.۱ مدل زیست‌بومها

برای مدل زیست‌بومها آزمایش‌های متعددی بر روی تعداد عصب‌ها انجام شد و در نهایت تعداد ۵۱۲ عصب در دو لایه‌ی پنهان به عنوان بهترین ساختار با بهترین خروجی انتخاب شد. طبق آزمایش‌های انجام شده تعداد عصب‌ها بیشتر باعث کندی بیش از حد شبکه شده و در نهایت اجازه‌ی بهبود شبکه به اندازه‌ی کافی و در زمان مناسب را نمی‌دادند. همچنین تعداد عصب‌های کمتر به نظر توانایی گنجایش تابع مورد نظر ما برای حدس زیست‌بوم از روی یازده ورودی را ندارند، و از این رو نمیتوانستند به نقطه‌ی مورد نظر همگرا شوند.




تصویر ۵.۲: ساختار کلی شبکه‌ی عصبی مصنوعی زیست‌بومها.

جدول ۵.۲: پارامترهای شبکه‌ی عصبی مدل زیست‌بوم‌ها

۵۱۲	تعداد عصب‌های هر لایه‌ی پنهان
۱۱	تعداد ورودی
۱۳	تعداد خروجی
1e-4	ضریب یادگیری
Categorical Cross-Entropy	تابع خطا
Softmax	تابع فعال‌ساز لایه‌ی خروجی

۵.۳.۲ مدل‌های دما و میزان بارش

این دو مدل دارای ساختار و پارامترهای یکسانی با یکدیگر هستند چرا که مسئله‌ی مورد نظر هر دو مدل بسیار مشابه است و در مراحل کاملاً یکسان. تفاوت این مدل با مدل زیست‌بوم‌ها در این است که این مدل‌ها در پی حل مسئله‌ی رگرسیون هستند و باید چهار خروجی حقیقی تولید کنند. در این شبکه‌ها اندازه‌گیری خطا و تعداد عصب‌ها متفاوت از زیست‌بوم است. همچنین نکته‌ی دیگر این مدل این است که به دلیل سعی در تولید یک عدد حقیقی، تابع فعال‌سازی برای لایه‌ی آخر در نظر گرفته نشده است و حاصل نهایی مدل، تنها از طریق ضرب وزن‌ها و جمع گرایش‌ها بدست می‌آید، چرا که تابع‌های فعال‌ساز مقدار ورودیشان را دچار دگرگونی می‌کنند و این می‌تواند برای رگرسیون ناخوشایند باشد.



Input Layer $\in \mathbb{R}^4$

Hidden Layer $\in \mathbb{R}_{64}$

Hidden Layer $\in \mathbb{R}_{64}$

Output Layer $\in \mathbb{R}^4$

تصویر ۵.۳: ساختار کلی شبکه‌های عصبی دما و میزان بارش

جدول ۵.۳: پارامترهای شبکه‌ی عصبی مدل‌های دما و میزان بارش

۶۴	تعداد عصب‌های هر لایه‌ی پنهان
۴	تعداد ورودی
۴	تعداد خروجی
3e-4	ضریب یادگیری
Mean Squared Error	تابع خطا
n/a	تابع فعال‌ساز لایه‌ی خروجی

۵.۴ نتایج آزمایش‌ها


در طول آزمایش دو معیار اصلی اندازه‌گیری می‌شوند:

- خطا: این معیار نشان دهنده‌ی فاصله‌ی پاسخ نهایی مدل از پاسخ مورد نظر، در قالب عددی حقیقی محاسبه شده توسط فرمولی مشخص. در آزمایش‌های ما این تابع خطا برای هر مدل متفاوت است و در جدول‌های ۵.۲ و ۵.۳ می‌توانید تابع خطا را بخوانید.
- دقت: این معیار صرفاً برای مدل‌های دسته‌بندی استفاده می‌شود که نشان می‌دهد دقت مدل برای تشخیص پاسخ درست چند درصد است. در واقع این معیار پاسخ این سوال است: در چند درصد از موارد، مدل می‌تواند پاسخ درست را دهد؟ این دو معیار در دو حالت اندازه‌گیری می‌شوند:
- آموزش: این سنجش بر روی داده‌هایی انجام می‌شود که مدل در طول آموزش خود از قبل با آنها برخورد داشته است. یعنی اگر مدل در حال آموزش بر روی مجموعه داده‌های A باشد، معیارها نیز با استفاده از همین مجموعه داده انجام می‌شوند.
- اعتبارسنجی: این سنجش بر روی داده‌هایی که مدل تا به حال با آنها برخورد نداشته است انجام می‌شود، و این معیارها مشخص‌کننده‌ی دقت و خطای نهایی مدل هستند چرا که مدل‌ها توانایی به حافظه سپردن اطلاعات را نیز دارند و ممکن است در معیارهای آموزش، صرفاً در حال پاسخ از روی حافظه‌ی خود باشند و نه از روی استنتاج، که به این اتفاق را «بیش‌برازش» می‌نامند.


۵.۴.۱ مدل زیست‌بوم‌ها

مدل زیست‌بوم با پارامترهای انتخاب شده پس از چند دوره آزمایش، برای ۲۰۰۰ دوره آموزش دید و در نهایت به دقت نزدیک به ۹۷٪ رسید. در تصویر ۵.۴ و ۵.۵ تغییرات دقت و خطای مدل در طول فرایند آموزش مدل را مشاهده می‌کنید.

Loss	۱
Accuracy	۲
Overfitting	۳




تصویر ۵.۴: خطای آموزش و اعتبارسنجی مدل زیست‌بوم در طول آموزش ۲۰۰۰ دوره‌ای




تصویر ۵.۵: دقت آموزش و اعتبارسنجی مدل زیست‌بوم در طول آموزش ۲۰۰۰ دوره‌ای

۵.۴.۲ مدل‌های دما و میزان بارش

این مدل‌ها دارای معیار دقت نمیباشند و صرفاً با استفاده از میزان خطا سنجیده می‌شوند مدل دما برای ۷۰ دوره و مدل بارش برای نزدیک به ۸۰۰۰ دوره اجرا شدند. در تصاویر ۵.۶ و ۵.۷ می‌توانید میزان خطای هر دو مدل را در طول آموزش مشاهده کنید.



تصویر ۵.۶: میزان خطای مدل دما در طول آموزش

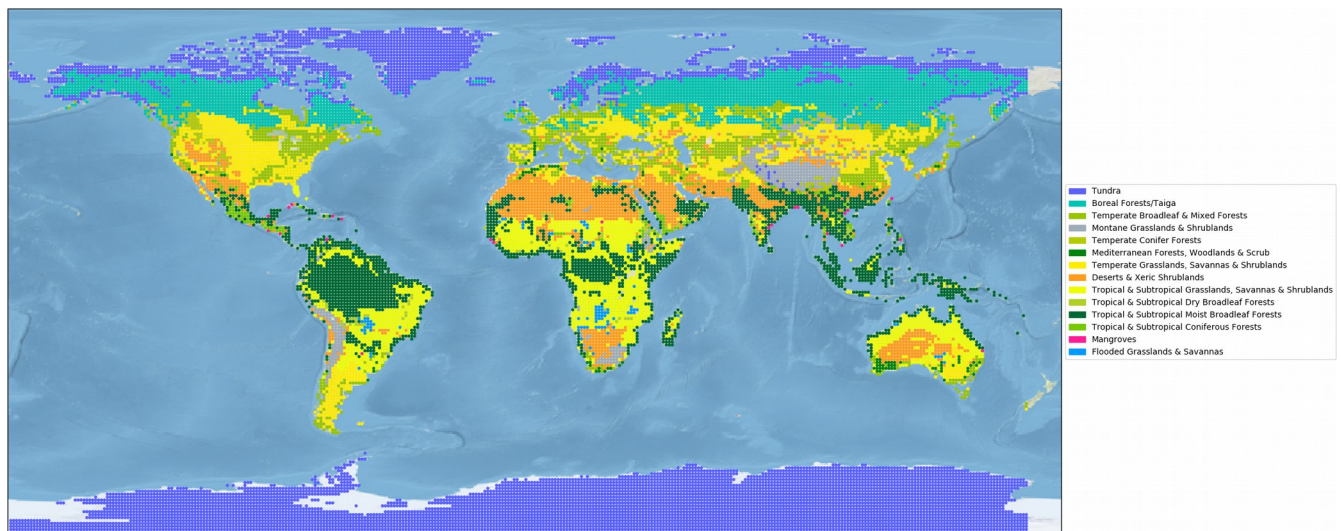
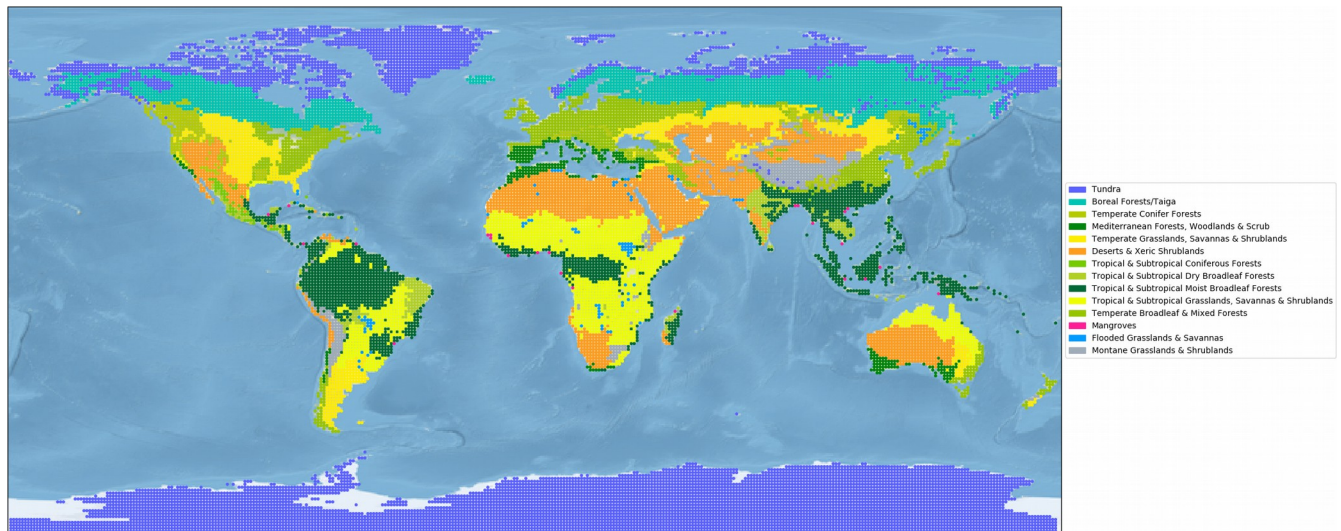


تصویر ۵.۷: میزان خطای مدل بارش در طول آموزش

۵.۵ تولید خروجی

پس از طراحی و آموزش مدل‌های هوش مصنوعی، نوبت آن می‌رسد که خروجی این مدل‌ها به صورت ظاهری تولید شده و از نگاه انسانی نیز قابل اندازه‌گیری باشد. برای این کار، نقشه‌ی کره‌ی زمین را به صورت نقطه به نقطه با اطلاعات اولیه همچون ارتفاع نقطه، عرض جغرافیایی و فاصله از دریا به مدل‌ها داده و در نهایت زیست‌بوم هر نقطه را طبق پیش‌بینی مدل بر روی نقشه علامت می‌زنیم.

ابتدا نقشه‌ی کره‌ی زمین با زیست‌بوم‌های واقعی آن را تولید می‌کنیم تا به عنوان نقطه‌ای برای مقایسه از آن استفاده کنیم (تصویر ۵.۸). در مرحله‌ی بعد با استفاده از داده‌های اولیه از پیش‌بینی‌های مدل استفاده می‌کنیم و دوباره نقشه را با پاسخ‌های مدل می‌کشیم (تصویر ۵.۹).



تصویر ۵.۹: نقشه‌ی زمین همراه با زیست‌بوم‌های پیش‌بینی شده توسط سه مدل دما، بارش و زیست‌بوم

۶ تولید نقشه‌های جدید

از دیگر اهداف این تحقیق، استفاده از مدل‌های پیش‌بینی زیست‌بوم بر روی نقشه‌های غیر از کره‌ی زمین است. در جهت این هدف، ابزاری جهت تولید نقشه‌های جدید طراحی و پیاده‌سازی خواهیم کرد تا بتوانیم عملکرد مدل‌ها را بر روی نقشه‌هایی به جز کره‌ی زمین نیز بیازماییم.

برای طراحی این نقشه‌ساز، از روش «تولید رویه‌ای محتوای عامل‌گر^۱» استفاده می‌کنیم. در این روش، مجموعه‌ای از عامل‌ها با وظایف متفاوت بر روی یک نقشه اعمال تغییرات می‌کنند و در نهایت نتیجه‌ی نهایی نقشه‌ای است که با همکاری عوامل متفاوت تولید شده است. برای مثال، در ابتدا نقشه را محیطی از آب در نظر می‌گیریم، در مرحله‌ی بعد مجموعه عواملی وظیفه‌ی مشخص کردن مرزهای خشکی شده و به صورت تصادفی و یا بر اساس الگوریتم خاصی، قسمت‌هایی از نقشه را به خشکی تبدیل می‌کنند. در مرحله‌ی بعد عواملی وظیفه‌ی ایجاد پستی و بلندی‌هایی در خشکی می‌شوند: عوامل کوه ساز و عوامل دره ساز. به این ترتیب، در نهایت پس از اعمال تغییرات توسط عوامل متفاوت نقشه‌ای خواهیم داشت که می‌تواند مشابه نقشه‌ی زمین باشد.

در این بخش الگوریتم مورد استفاده برای تولید نقشه‌ی استفاده شده در این تحقیق را توصیف کرده و روندنمایی^۲ برای اعضای مختلف آن ارائه می‌دهم.

۶.۱ عوامل نقشه‌ساز

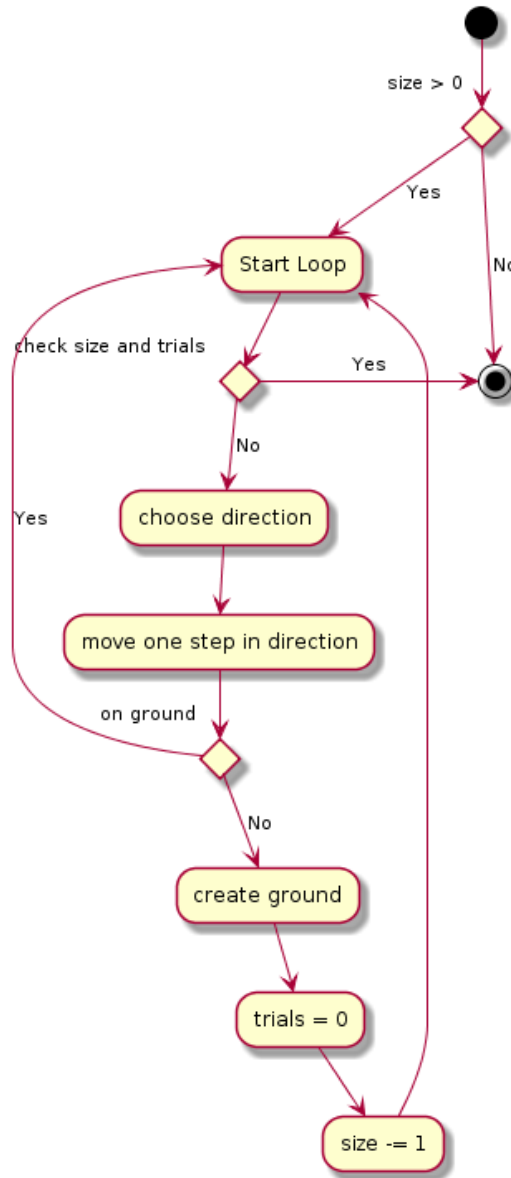
سه عامل اصلی اثرگذار در تولید نقشه‌های، عامل قاره‌ساز، عامل کوه‌ساز و عامل ارتفاع تصادفی هستند که در زیر به شرح آن‌ها می‌پردازیم.

۶.۱.۱ عامل قاره‌ساز

عامل قاره‌ساز وظیفه‌ی تفکیک خشکی و آب از یکدیگر است. این عامل بر روی محیطی که کاملاً پر از آب است شروع به عمل کرده و قسمت‌هایی را بر اساس الگوریتمی مشخص به خشکی تبدیل می‌کند. الگوریتم عملکرد این عامل به صورت زیر است:

- این عامل سه ورودی دریافت می‌کند: زمین، محل شروع و اندازه
- زمین: نقشه‌ی کلی که به صورت آرایه‌ی دو بعدی محورهای x و y را پوشش می‌دهد.
- محل شروع: مختصات نقطه‌ای در زمین که این عامل از آنجا کار خود را شروع می‌کند. یک جفت عدد (x, y) است.
- اندازه: پارامتر مشخص کننده‌ی اندازه‌ی قاره‌ی تولیدی توسط این عامل. عامل سعی می‌کند به اندازه‌ی این پارامتر نقطه‌ها را به خشکی تبدیل کند اما تضمینی برای این کار وجود ندارد چرا که ممکن است فضای خالی برای انجام این کار یافت نشود.
- الگوریتم وارد یک حلقه‌ی بی‌نهایت می‌شود که بعد، بر اساس شرط‌هایی از آن خارج می‌شود که در ادامه توضیح داده می‌شوند
- در هر اجرای حلقه دو شرط بررسی می‌شوند: آیا به اندازه‌ی مورد نظر رسیدیم؟ و آیا بیش از حد برای افزایش خشکی تلاش کردیم و به نتیجه نرسیدیم؟ شرط اول بسیار ساده و مقایسه‌ای بین تعداد نقاط تبدیل شده به خشکی در برابر اندازه‌ی ورودی است. شرط دوم در صورتی اتفاق می‌افتد که ما برای تعداد تکرارهای زیاد سعی در ایجاد خشکی کرده‌باشیم اما موفق به پیدا کردن نقطه‌ای برای اینجام این کار نشویم.
- در هر اجرای حلقه، یک جهت به صورت تصادفی انتخاب می‌شود که این جهت یکی از هشت جهت است (چهار جهت اصلی و جهت‌های اوریب)
- پس از انتخاب جهت، یک حرکت در این جهت انجام می‌شود

۶. اگر نقطه‌ی فعلی که به آن حرکت کردیم از پیش زمین باشد، یک مقدار به تعداد «تلاش‌ها» برای ایجاد خشکی اضافه می‌کنیم و وارد تکرار بعدی می‌شویم
۷. اگر نقطه‌ی فعلی زمین نباشد، آن را به زمین تبدیل می‌کنیم، سایز پوشش داده شده را افزایش می‌دهیم و تعداد تلاش‌ها را به صفر برمیگردانیم.

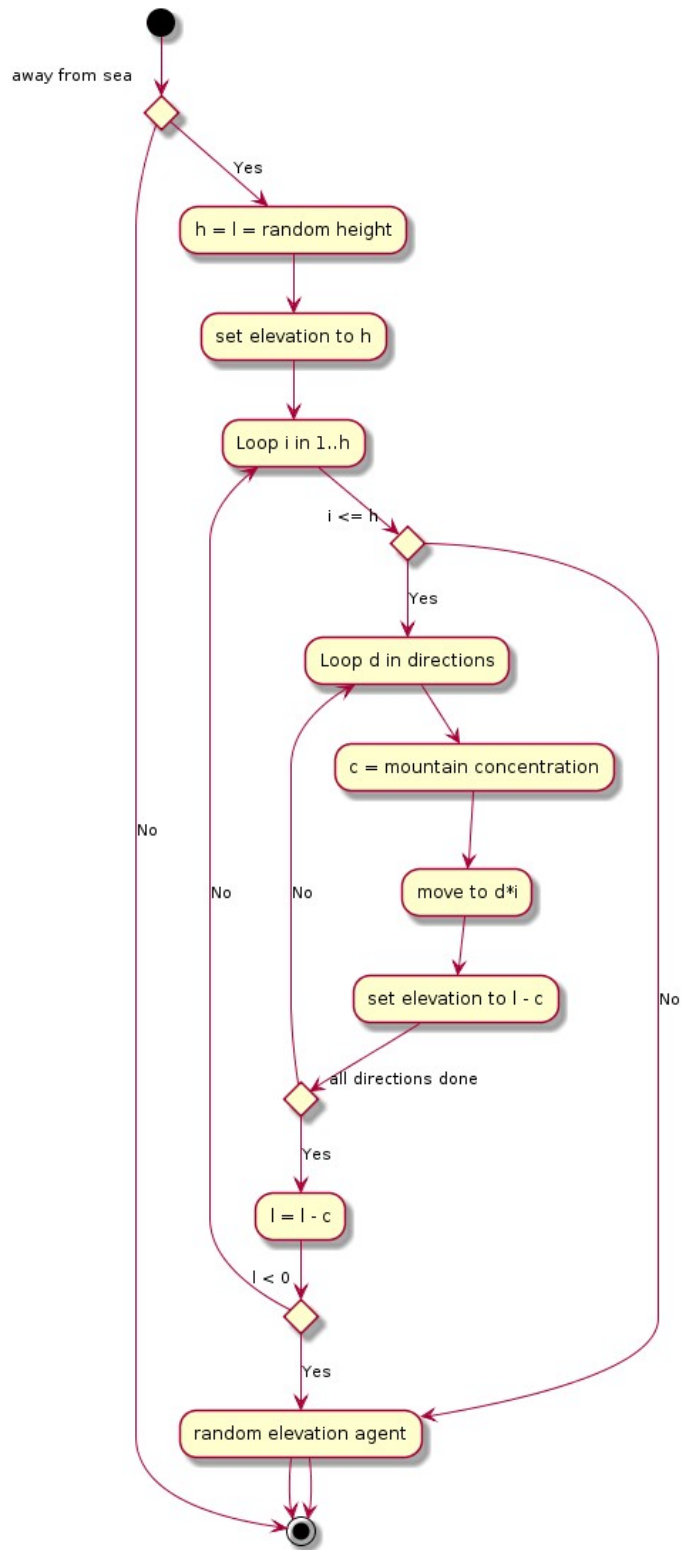


تصویر ۶.۱: روندنمای کار عامل قاره‌ساز

۶.۱.۲ عامل کوهساز

این عامل وظیفه‌ی ایجاد پستی و بلندی‌های بزرگ بر روی سطح نقشه را دارد. هدف اصلی این عامل ساخت کوه است، اما همانطور که خواهید دید، این عامل با اجرای عوامل ارتفاع تصادفی، باعث ایجاد انواع پستی و بلندی‌ها در نقشه می‌شود.

۱. این عامل دو ورودی دریافت می‌کند: زمین و محل شروع
۱. زمین: نقشه‌ی کلی که به صورت آرایه‌ی دو بعدی محورهای x و y را پوشش می‌دهد.
۲. محل شروع: مختصات نقطه‌ای در زمین که این عامل از آنجا کار خود را شروع می‌کند. یک جفت عدد (x, y) است.
۲. ابتدا نقطه‌ی شروع برای فاصله‌ی کافی از دریا سنجیده می‌شود. معمولاً سواحل دارای پستی و بلندی‌های کمتری هستند و کوه‌های روی خشکی در فاصله‌ای از دریا وجود دارند. هرچند در جزایر این مسئله همیشه مطابقت ندارد، اما در قاره‌ها این الگو به چشم می‌خورد.
۳. ارتفاعی به صورت تصادفی بین عدد یک تا حداکثر ارتفاع ممکن (از پارامترهای نقشه‌ساز) انتخاب می‌شود
۴. این ارتفاع را به نقطه‌ی شروع منسوب می‌کنیم و این ارتفاع را به عنوان «آخرین ارتفاع» ذخیره می‌کنیم (متغیر l)
۵. حلقه‌ای از عدد یک تا ارتفاع انتخاب شده اجرا می‌شود (متغیر حلقه: i)
۶. در هر هشت جهت عملیات زیر انجام می‌شود:
 ۱. عددی به صورت تصادفی بین یک تا پارامتر «تراکم کوه» انتخاب می‌شود (متغیر C)
 ۲. به اندازه i در جهت فعلی، از نقطه‌ی مرکز حرکت می‌کنیم
 ۳. ارتفاع این نقطه را برابر $l - C$ قرار می‌دهیم
 ۷. آخرین ارتفاع را برابر $l - C$ قرار می‌دهیم
 ۸. اگر ارتفاع به صفر رسیده است، خارج می‌شویم، در غیر این صورت حلقه ادامه پیدا می‌کند
 ۹. در انتها عامل پست‌وبلندی‌ساز تصادفی در نقطه‌ی شروع با پارامتر ارتفاع برابر ارتفاع تصادفی انتخاب شده اجرا می‌شود

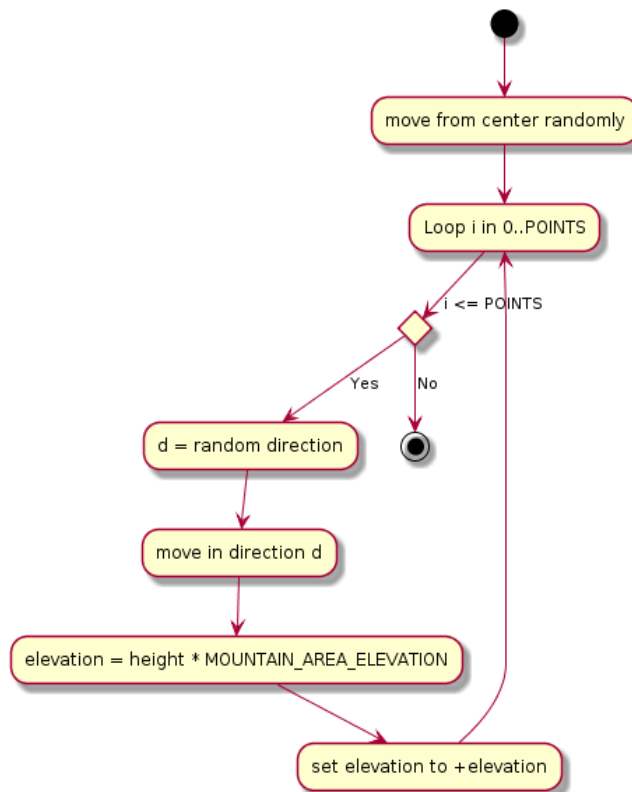


تصویر ۶.۲: روندنمای کار عامل کوهساز

۶.۱.۳ عامل ارتفاع تصادفی

این عامل برای ایجاد پستی و بلندها به صورت تصادفی در مجموعه‌ای از نقاط نزدیک یک نقطه‌ی مرکزی است. استفاده‌ی اصلی این عامل برای ایجاد ارتفاعات تصادفی در نزدیکی کوه‌هاست، چرا که مناطق اطراف کوه‌ها معمولا دارای ارتفاع میانگین بیشتری نسبت به دیگر مناطق هستند (دامنه‌ی کوه).

۱. این عامل سه ورودی دریافت می‌کند: زمین، محل شروع و ارتفاع
۱. زمین: نقشه‌ی کلی که به صورت آرایه‌ی دو بعدی محورهای x و y را پوشش می‌دهد.
۲. محل شروع: مختصات نقطه‌ای در زمین که این عامل از آنجا کار خود را شروع می‌کند. یک جفت عدد (x, y) است.
۳. ارتفاع: میزان ارتفاع پایه که ارتفاعات تصادفی به نسبت آن محاسبه می‌شوند.
۲. ابتدا نقطه‌ی شروع به صورت تصادفی در یکی از چهار جهت اصلی تغییر پیدا می‌کند. فاصله‌ی این تغییر از پارامترهای نقشه‌ساز است.
۳. سپس به اندازه‌ی پارامتر «نقاط ارتفاعات محل کوه» حلقه‌ای اجرا می‌شود
۴. یک جهت به صورت تصادفی از هشت جهت انتخاب می‌شود
۵. یک حرکت در جهت انتخاب شده انجام می‌شود
۶. ارتفاع این نقطه با ضرب ضریب «ارتفاع محل کوه» در ارتفاع ورودی (که معمولا ارتفاع قله‌ی کوه است) محاسبه می‌شود
۷. ارتفاع نقطه‌ی فعلی به میزان محاسبه شده افزایش پیدا می‌کند

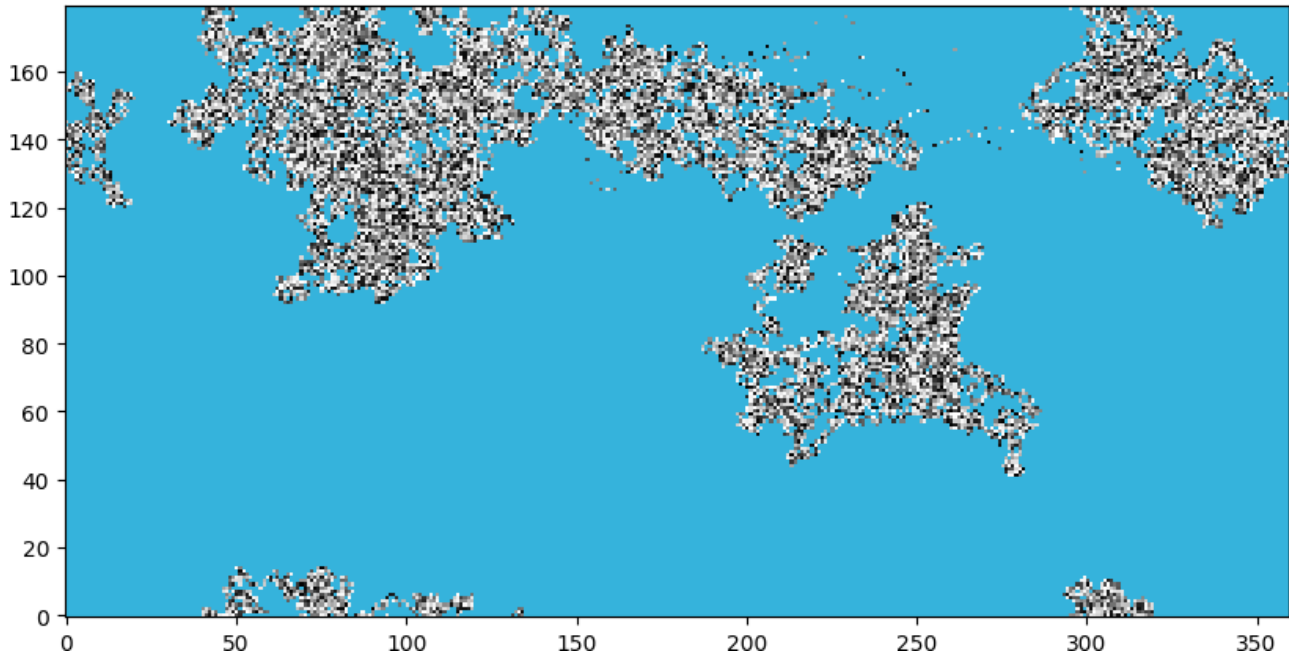


تصویر ۶.۳: روندنمای کار عامل ارتفاع تصادفی

۶.۲ الگوریتم کلی

پس از توصیف عامل‌های مختلف عملگر بر روی نقشه‌ها، الگوریتم کلی تولید نقشه که از این عوامل استفاده می‌کند و سپس با پردازش‌هایی پس از کار عوامل نیز اعمال می‌شوند تا نقشه‌ی نهایی تولید شود.

۱. در مرحله‌ی اول به تعداد قاره‌های مشخص شده در پارامترها عامل قاره‌ساز در فواصل مشخص شده‌ای توسط پارامتر فاصله‌ی قاره‌ها به صورت تصادفی اجرا می‌شوند. (تصویر ۶.۴)

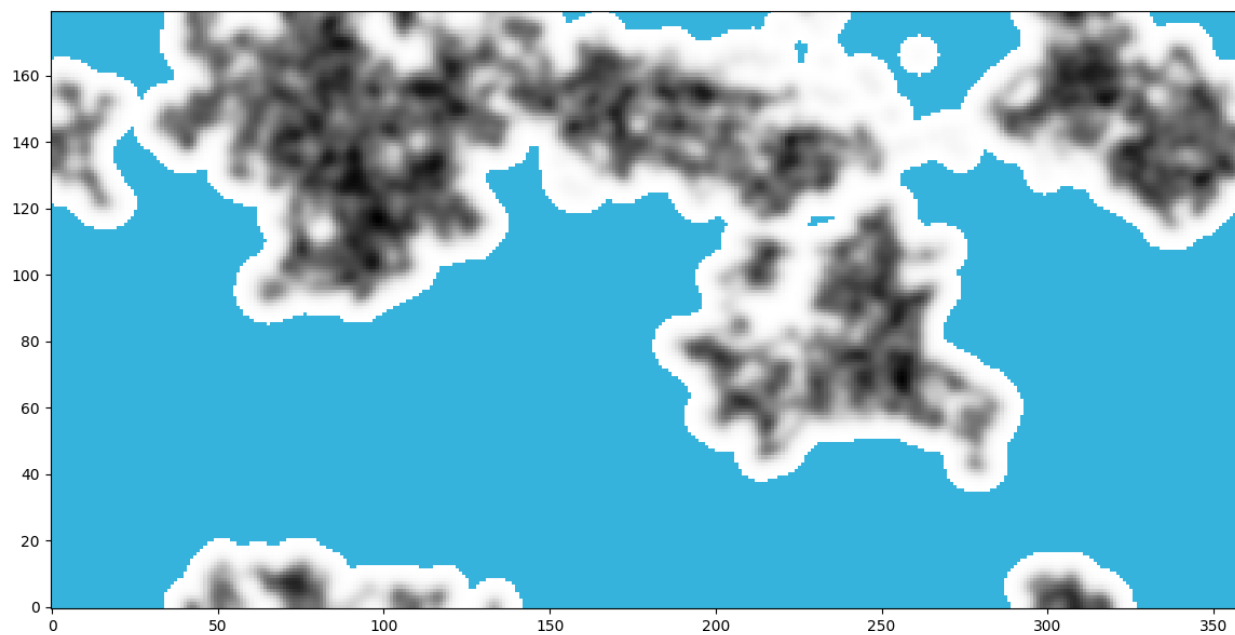


تصویر ۶.۴: اولین مرحله‌ی تولید نقشه: عامل قاره‌ساز، بدون فیلتر


۲. در مرحله‌ی بعد با اجرای یک فیلتر گاوسی^۱ با پارامتر زیگمای محاسبه شده بر حسب پارامتر «تیزی^۲» به صورت زیر را روی نقشه اجرا می‌کنیم. این فرمول به صورت تجربی به دست آمده است (تصویر ۶.۵).

$$\sigma = 20(1 - s)$$


Gaussian Filter ۱
Sharpness ۲



تصویر ۶.۵: مرحله‌ی دوم تولید نقشه: عامل قاره‌ساز و فیلتر گاوسی
 ۳. در مرحله‌ی بعد عوامل کوه‌ساز به اندازه پارامتر «نسبت کوه» بر روی نقشه اجرا می‌شوند (تصویر ۶.۶)




تصویر ۶.۶: مرحله سوم تولید نقشه: عامل کوه‌ساز بدون فیلتر
 ۴. سپس به دوباره یک فیلتر گاوسی با زیگمای ۱ را نیز اعمال می‌کنیم تا کوه‌ها با نقشه درآمیخته شوند. (تصویر ۶.۷)



تصویر ۶.۷: مرحله چهارم تولید نقشه: عامل کوهساز و فیلتر گاوسی

۵. در مرحله‌ی آخر این نقشه به مدل‌های هوش مصنوعی طراحی شده داده شده زیست‌بوم‌ها بر روی نقشه جای می‌گیرند. (تصویر ۶.۸)

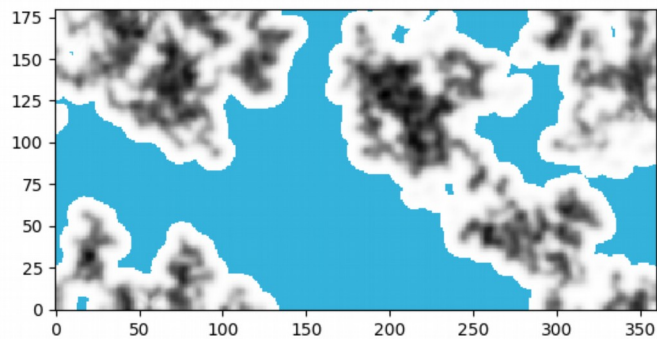


تصویر ۶.۸: مرحله‌ی پنجم تولید نقشه: مدل‌های هوش مصنوعی زیست‌بوم

۶.۳ محیط گرافیکی نقشه‌ساز

برای آسان کردن فرایند ساخت نقشه و تست آن، محیط گرافیکی تحت وب طراحی شده تا بتوان از طریق آن به سادگی پارامترهای مختلف نقشه را تغییر داده و نقشه‌ها را قبل از ارائه به مدل‌ها زیست‌بوم به صورت چشمی بررسی کرد.

این محیط با استفاده از زبان پایتون و فریم‌ورک Flask در قسمت بک‌اند و با تکنولوژی‌های معمول وب در سمت فرانت‌اند طراحی و پیاده‌سازی شده است. (تصویر ۶.۹)



World Map Generator

Width

360

Height

180

Mountain Ratio

0.02

Sharpness

0.9

Max Elevation

2000

Min Elevation

-400

Ground Noise

5000

Water Proportion

0.4

تصویر ۶.۹: محیط گرافیکی تحت وب برای ارتباط با نقشه‌ساز

۷ جمع‌بندی

حوزه‌ی تولید رویه‌ای محتوا همواره در تلاش برای خودکارسازی فعالیت‌های مرتبط با تولید محتوا که معمولاً هر ساله میلیون‌ها ساعت از زمان انسان‌ها را به خود اختصاص می‌دهند است؛ و در این مسیر از علوم و حوزه‌های دیگر نیز الهام گرفته و گاهی این الهام گرفتن باعث موفقیت و گاهی ناامید کننده بوده است.

در این تحقیق سعی در استفاده از فناوری‌های جدید یادگیری ماشینی در استخراج الگوهای از زیست‌بوم‌های کره‌ی زمین و اعمال این الگوها به نقشه‌های تولید شده توسط ابزارهای تولید رویه‌ای محتوا، شامل موتورهای بازی‌سازی داشتیم. مدل‌ها و روش‌های استفاده شده در این تحقیق دارای نقاط قوت و ضعفی هستند که تنها با طی تحقیق به صورت کامل به آنها پی برده شده است. در نتیجه می‌توان گفت مدل‌های طراحی شده کشتش زیادی به سمت کره‌ی زمین داشته و در صورت دریافت ورودی‌هایی متفاوت از کره‌ی زمین توانایی اعمال دانش کسب شده‌ی خود بر اساس داده‌های مشاهده شده را ندارند و در نتیجه، خروجی‌های تولیدی با درک ما از زیست‌بوم‌ها و جغرافیا هم‌خوانی ندارد.

دلیل این اتفاق را می‌توان در ناتوانی شبکه‌های عصبی مصنوعی در کلی‌سازی از روی نمونه‌های محدود دانست. شبکه‌های عصبی مصنوعی معمولاً تنها در صورت وجود داده‌های گسترده در دامنه‌های متفاوت می‌توانند به درکی کلی از موضوع مورد نظر دست پیدا کرده و آن را بر روی ورودی‌های از پیش دیده نشده اعمال کنند. در این تحقیق، داده‌های زیست‌بومی ما محدود به زمین، و محدود به مقیاسی بزرگ هستند و توانایی ما برای آموزش شبکه‌هایی با توانایی پیش‌بینی و الگوگیری از زمین برای نقشه‌های متفاوت را نمی‌دهند.

۸ کارهای آینده

پیشنهاد ما برای ادامه در این حوزه جمع‌آوری و یا تولید داده‌های مناسب برای پیش‌بینی زیست‌بوم‌های مختلف در محیط‌های مختلف است. برای این کار می‌توان تلاش در تولید داده‌هایی برای زیست‌بوم‌های نقشه‌های بازی‌های کامپیوتری بزرگ که دارای نقشه‌های وسیع و الهام گرفته از زمین هستند استفاده کرد. معمولاً این نقشه‌ها در فرمت‌های ساده‌ی تصویری در اختیار هستند و نیاز به تفکیک زیست‌بوم‌ها بر روی این نقشه‌ها به صورت دستی و یا خودکار دیده می‌شود.

از دیگر مسیرهای ممکن برای ادامه‌ی این تحقیق، ساده‌سازی ساختار مدل هوش مصنوعی ارائه شده است که در حال حاضر شامل سه مدل متفاوت است. می‌توان تلاش برای طراحی مدلی کرد که به صورت مستقیم اطلاعات اولیه را به خروجی زیست‌بوم‌ها تبدیل کرد.

در زمینه‌ی اطلاعات جغرافیایی و زیستی نیز می‌توان تحقیق‌های گسترده‌تری انجام داد تا به درک مناسبی نسبت به ارتباط بین عوامل محیطی و زیست‌بوم‌ها رسید. برای مثال میدانیم که وجود یک زیست‌بوم در یک منطقه خود تاثیر گزار در زیست‌بوم‌های اطراف آن است، از این رو رابطه‌ی بین زیست‌بوم‌ها رابطه‌ای ساده و خطی نیست و پیش‌بینی آنها می‌تواند کار پیچیده‌تری باشد و نیازمند مهندسی دقیق تر نرم‌افزاری بر پایه‌ی علوم دقیق جغرافیایی و زیستی باشد.