

چگونگی رشد ذرات هیدروکربن در داخل خوشه بندی چندبندی به روش شبکه عصبی گازی

میثم طغرای سمیرمی^۱، محمد اسمعیلی^۲، فرهاد راد^۳

^۱ دانشگاه آزاد اسلامی واحد علوم تحقیقات تهران، یاسوج، may.toghraee@gmail.com

^۲ دانشگاه آزاد اسلامی واحد علوم تحقیقات تهران، اردبیل، esmaeili.cse@gmail.com

^۳ دانشگاه آزاد اسلامی واحد علوم تحقیقات تهران، یاسوج، f_rad@hotmail.com

چکیده

شبکه عصبی گازی یا شبکه گاز عصبی یکی از انواع شبکه‌های عصبی رقابتی با الگوی یادگیری غیر نظارت شده است، که کاربرد اصلی آن در حل مسائل خوشه بندی و یادگیری توپولوژی است. این نوع از شبکه عصبی، از نظر طبقه بندی در رده الگوریتم‌های (Vector Quantization به اختصار VQ) قرار می‌گیرد و ارتباط بسیار نزدیکی با الگوریتم خوشه بندی k-Means، شبکه عصبی (SOM) نگاشت‌های خود سازمان ده) و شبکه عصبی LVQ دارد. شبکه گاز عصبی علاوه بر انجام خوشه بندی و قرار دادن مرکز خوشه‌ها در محل مناسب، ارتباط‌های همسایگی میان نوروں‌ها (مراکز خوشه‌ها) را به صورت پویا ایجاد می‌کند، که در نهایت این الگوریتم را، قادر به یادگیری توپولوژی می‌کند

واژه کلیدی : شبکه گازی عصبی، الگوریتم خوشه بندی k-Means، شبکه عصبی نگاشت خود سازمان ده(SOM)

شبکه عصبی گازی و کاربردهای آن

شبکه عصبی گازی یا شبکه گاز عصبی یکی از انواع شبکه‌های عصبی رقابتی با الگوی یادگیری غیر نظارت شده است، که کاربرد اصلی آن در حل مسائل خوشه بندی و یادگیری توپولوژی است. الگوریتم پایه شبکه عصبی گازی در سال ۱۹۹۱ و توسط توماس مارتینتز (Thomas Martinetz) و کلاوز شولتن (Klaus Schulten) ارائه شد.

این نوع از شبکه عصبی، از نظر طبقه بندی در رده الگوریتم‌های Vector Quantization به اختصار (VQ) قرار می‌گیرد و ارتباط بسیار نزدیکی با الگوریتم خوشه بندی k-Means، شبکه عصبی (SOM) نگاشت‌های خود سازمان ده) و شبکه عصبی LVQ دارد. شبکه گاز عصبی علاوه بر انجام خوشه بندی و قرار دادن مرکز خوشه‌ها در محل مناسب، ارتباط‌های همسایگی میان نوروں‌ها (مراکز خوشه‌ها) را به صورت پویا ایجاد می‌کند، که در نهایت این الگوریتم را، قادر به یادگیری توپولوژی می‌کند.

از مهم‌ترین زمینه‌های کاربردی شبکه‌های عصبی گازی، می‌توان به بخش بندی تصویر (Image Segmentation)، فشرده سازی (Compression)، تشخیص گفتار (Speech Recognition) و بازشناسی الگو (Pattern Recognition) اشاره کرد.

شبکه عصبی گازی رشد یابنده یا GNG


در سال ۱۹۹۵، یک الگوریتم توسعه یافته به نام شبکه عصبی رشد یابنده یا (GNG) Growing Neural Gas Network توسط برنرد فریتسکه (Bernd Fritzke) معرفی شد. در شبکه عصبی GNG، برخلاف شبکه گاز عصبی عادی، ساختار شبکه عصبی با تعداد دو نورون کار را شروع می‌کند و بر حسب نیاز، اندازه شبکه به صورت تطبیقی، کم یا زیاد می‌شود. الگوی یادگیری و به روز رسانی همسایگی در GNG تفاوت‌هایی را با الگوریتم پایه شبکه عصبی گازی دارد که این شبکه را قادر به حل سریع تر مسائل یادگیری غیر نظارت شده می‌کند. یک مدل شبکه افزایشی معرفی می‌شود که قادر به یادگیری است روابط مهم توپولوژیکی در مجموعه معینی از بردارهای ورودی توسط به معنای یک قانون ساده یادگیری شبیه به Hebb. برخلاف قبلی رویکردهایی مانند روش "گاز عصبی" مارتینتز و شولتن (۱۹۹۱ و ۱۹۹۴)، این مدل هیچ پارامتری ندارد که در طول زمان تغییر کند و قادر است به یادگیری، افزودن واحدها و ارتباطات، تا زمان ادامه معیار عملکرد برآورده شده است کاربردهای مدل شامل کمیابی بردار، خوشه بندی و درون یابی است.

در تنظیمات یادگیری بدون نظارت فقط داده‌های ورودی در دسترس است اما هیچ اطلاعاتی وجود ندارد روی خروجی مورد نظر در این شرایط هدف از یادگیری چه می‌تواند باشد؟ یکی از اهداف احتمالی کاهش ابعاد است: یافتن یک زیرفضا با ابعاد کم از فضای بردار ورودی که شامل بیشتر یا همه داده‌های ورودی است. خطی زیر فضاهای دارای این ویژگی را می‌توان مستقیماً با تجزیه و تحلیل مولفه‌های اصلی یا به طور مکرر با تعدادی از مدل‌های شبکه محاسبه کرد (سانگر، ۱۹۸۹؛ اوجا، ۱۹۸۲). این نقشه ویژگی کوهونن (کوهونن، ۱۹۸۲) و "ساختارهای سلولی در حال رشد" (فریتسکه، ۱۹۹۴b) اجازه می‌دهد تا بر روی فضاهای فرعی غیر خطی و نمونه‌ای از ابعاد کم به طور پیشینی انتخاب می‌شوند، طرح ریزی شود. بسته به رابطه بین ابعاد ذاتی و ابعاد فضای هدف، برخی اطلاعات در مورد آرایش توپولوژیکی داده‌های ورودی ممکن است در این فرایند از بین برود. ۶۲۶ برنرد فریتسکه از آنجا که نقشه برداری برگشت پذیر از داده‌های با ابعاد بالا به فضاهای (یا ساختارها) با ابعاد پایین به طور کلی وجود ندارد. پرسیدن اینکه ساختارها چگونه باید به نظر برسند تا نقشه برداری برگشت پذیر به طور مستقیم منجر شود هدف احتمالی دیگر یادگیری بدون نظارت که می‌توان آن را به عنوان یادگیری توپولوژی توصیف کرد: با توجه به توزیع داده‌های با ابعاد بالا $p(\epsilon)$ ، یک توپولوژیک پیدا کنید ساختاری که منعکس کننده توپولوژی توزیع داده‌ها است. یک ظریف روش ساخت چنین ساختارهایی "یادگیری رقابتی هیجان" (CHL) است (مارتینتز، ۱۹۹۳). CHL مستلزم استفاده از برخی روشهای کمی سازی بردار است. مارتینتز و شولتن روش "گاز عصبی" (NG) را برای این منظور پیشنهاد می‌کنند (مارتینتز و شولتن، ۱۹۹۱). ما به طور مختصر رویکرد مارتینتز و شولتن را معرفی و بحث خواهیم کرد. سپس ما یک مدل شبکه جدید پیشنهاد می‌کنیم که از CHL نیز استفاده می‌کند. در مقابل ترکیب CHL/NG فوق‌الذکر، این مدل افزایشی است و دارای فقط پارامترهای ثابت این منجر به مزایای متعددی نسبت به قبلی می‌شود.


آموزش رقابتی شبکه عصبی گاز طبیعی

(مارتینز، ۱۹۹۳) تعدادی از مراکز را در R^n و پی در پی در نظر می‌گیرد ارتباطات توپولوژیکی بین آنها با ارزیابی سیگنال‌های ورودی برگرفته از داده‌ها توزیع $p(\epsilon)$. اصل این روش عبارت است از: برای هر سیگنال ورودی X دو نزدیکترین مرکز (اندازه‌گیری شده) را وصل کنید با فاصله اقلیدسی) توسط یک لبه. نمودار به دست آمده زیرگرافی از مثلث بندی دلونی (شکل ۱ الف) مربوط به مجموعه مراکز است. این زیرگراف (شکل ۱ ب)، که "القایی" نامیده می‌شود مثلث بندی "Delaunay"، محدود به مناطقی از فضای ورودی R^n است که در آن قرار دارد $p(\epsilon)$. مثلث بندی ناشی از دلونی "به طور مطلوب نشان داده شده است توپولوژی را در یک مفهوم کلی حفظ کنید (مارتینز، ۱۹۹۳). فقط مراکزی که در زیر چند برابر داده‌های ورودی یا در مجاورت آن قرار دارند واقعاً توسعه می‌یابند هر لبه ای بقیه برای یادگیری توپولوژی بی‌فایده هستند و اغلب واحدهای مرده نامیده می‌شود. برای استفاده از همه مراکز، آنها باید در آن مناطق مستقر شوند از R^n که $p(\epsilon)$ با صفر متفاوت است. این را می‌توان با هرگونه کمی بردار انجام داد رویه (VQ) مارتینز و شولتن نوع خاصی از VQ را پیشنهاد کرده اند روش NG ذکر شده (مارتینز و شولتن، ۱۹۹۱). اصلی اصل NG به شرح زیر است: برای هر سیگنال ورودی X نزدیکترین مراکز k در آن است را وفق دهید از مقدار اولیه بزرگ به مقدار نهایی کوچک کاهش می‌یابد. مقدار اولیه بزرگ k باعث سازگاری می‌شود (حرکت به سمت سیگنال ورودی)

بخش بزرگی از مراکز سپس k (محدوده سازگاری) کاهش می‌یابد تا در نهایت فقط نزدیکترین مرکز برای هر سیگنال ورودی اقتباس شده است. اقتباس قدرت زیربنای یک برنامه پوسیدگی مشابه است. برای درک پارامترهای پوسیدگی فرد تعیین تعداد کل مراحل سازگاری به روش NG انجام گیرد.



شکل ۱: مثلث بندی دلانی (خطوط ضخیم)




شکل ۲: مثلث بندی دلانی اصلی با توزیع داده $P(\sim)$ (سایه دار)

شکل ۱: دو روش برای تعیین نزدیکی بین مجموعه ای از نقاط. الف) مثلث بندی دلانی (خطوط ضخیم) نقاطی را که دارای چند ضلعی های ورونوی همسایه هستند (خطوط نازک) به هم متصل می‌کند. اساساً این به نقاط دارای فاصله اقلیدسی کوچک کاهش می‌یابد. W.T.

مجموعه نقاط داده شده ب) مثلث بندی دلانی (خطوط ضخیم) با پوشاندن مثلث بندی اصلی با توزیع داده $P(\sim)$ (سایه دار) به دست می‌آید. دو مرکز تنها در صورت اتصال مرز مشترک به یکدیگر متصل می‌شوند چند ضلعی های ورونوی حداقل تا حدی در منطقه ای قرار دارد که $P(\sim)$ (از نزدیک تطبیق داده شده است از مارتینز و شولتن، ۱۹۹۴) برای توزیع داده های داده شده می‌توان ابتدا الگوریتم NG را برای توزیع تعداد معینی از مراکز اجرا کرد و سپس از CHL برای ایجاد توپولوژی استفاده کرد. با این حال، امکان استفاده همزمان از هر دو تکنیک نیز وجود دارد (مارتینز و شولتن، ۱۹۹۱). در این مورد، روش حذف لبه های منسوخ مورد نیاز است حرکت مراکز ممکن است لبه هایی را که قبلاً ایجاد شده اند نامعتبر کند. مارتینز و شولتن برای این منظور از طرح پیری لبه استفاده می‌کنند. یکی باید توجه داشته باشید که الگوریتم CHL بر نتیجه روش NG در تأثیر نمی‌گذارد به هر روشی که سازگاری در NG فقط بر اساس فاصله در فضای ورودی و در توپولوژی شبکه نیست از سوی دیگر، NG توپولوژی را تحت تأثیر قرار می‌دهد از آنجا که مراکز را در اطراف حرکت می‌دهد توسط CHL ایجاد می‌شود. ترکیب NG و CHL که در بالا توضیح داده شد یک روش م for اثر برای یادگیری توپولوژی است. با این حال، ممکن

است مشکلی در کاربردهای عملی تعیین شود پیشاپیش تعداد مناسبی از مراکز. بسته به پیچیدگی داده‌ها تعدادی از مراکز ممکن است از توزیعی که فرد می‌خواهد مدل‌سازی کند، استفاده کنند مناسب. ماهیت الگوریتم NG مستلزم تصمیم‌گیری از قبل و اگر نتیجه رضایت بخش نباشد، باید یک یا چند شبیه‌سازی جدید انجام شود از ابتدا در ادامه ما روشی را پیشنهاد می‌کنیم که بر این مشکل غلبه کرده و تعدادی مزایای دیگر را از طریق یک طرح انعطاف‌پذیر برای مرکز ارائه می‌دهد.

الگوریتم گازهای رو به رشد



در ادامه ما شبکه‌های متشکل از

• مجموعه ای از واحدها (یا گره‌ها). هر واحد $c \in A$ دارای یک مرجع مرتبط است بردار $w_c \in R^n$. بردارهای مرجع را می‌توان به عنوان موقعیت‌های ورودی در نظر گرفت فضای واحدهای مربوطه

• مجموعه ای از اتصالات (یا لبه‌ها) در بین جفت واحد.

این اتصالات وزن ندارند. تنها هدف آنها تعریف توپولوژی است ساختار علاوه بر این، تعداد (احتمالاً نامحدود) تعداد سیگنال‌های ورودی n بعدی وجود دارد که از تابع چگالی احتمال ناشناخته $p()$ تبعیت می‌کنند. ایده اصلی این روش اضافه کردن پی در پی واحدهای جدید به واحدهای اولیه کوچک است شبکه با ارزیابی اقدامات آماری محلی جمع‌آوری شده طی مراحل سازگاری قبلی. این همان رویکردی است که در مدل "ساختارهای سلولی در حال رشد" استفاده می‌شود. (فریتسکه، ۱۹۹۴) که با این حال دارای توپولوژی با ابعاد ثابت است (به عنوان مثال،

دو یا سه). در رویکردی که در اینجا توضیح داده شد، توپولوژی شبکه به صورت تدریجی تولید می‌شود توسط CHL و دارای ابعادی است که به داده‌های ورودی بستگی دارد و ممکن است متفاوت باشد به صورت محلی الگوریتم کامل مدل ما که ما آن را "گاز عصبی در حال رشد" می‌نامیم به شرح زیر ارائه می‌شود:

۰. با دو واحد a و b در موقعیت‌های تصادفی w_a و w_b در R^n شروع کنید.

۱. با توجه به یک سیگنال ورودی ϵ تولید کنید $p(\epsilon)$.

۲. نزدیکترین واحد s_1 و دومین واحد نزدیک s_2 را پیدا کنید.

۳. افزایش سن تمام لبه‌های ناشی از s_1 .

۴. فاصله مربعی بین سیگنال ورودی و نزدیکترین واحد را اضافه کنید فضای ورودی به یک متغیر شمارنده محلی:

$$\Delta error(s_1) = \|w_{s_1} - \epsilon\|^2$$

۵. همسایگان مستقیم توپولوژیکی آن را s_1 به سمت کسر حرکت دهید

به ترتیب ϵ_b و ϵ_n از کل فاصله:

$$\Delta w_{s_1} = \epsilon_b (-w_{s_1}), \Delta w_{s_1} = \epsilon_n (-w_{s_1})$$

برای همه همسایگان مستقیم n از s_1

۶. اگر s_1 و s_2 توسط یک لبه به هم متصل شده‌اند، سن این لبه را روی صفر قرار دهید. اگر چنین لبه‌ای وجود ندارد، آن را ایجاد

کنید

۷. لبه‌های با سن بیشتر از a_{max} را بردارید • اگر این منجر به داشتن نقاطی شد بدون لبه‌های ساطع‌کننده، آنها را نیز بردارید.

۸. اگر تعداد سیگنالهای ورودی تولید شده تا کنون یک عدد صحیح a باشد

پارامتر γ ، یک واحد جدید را به شرح زیر وارد کنید:

• واحد q را با حداکثر خطای انباشته تعیین کنید.

• یک واحد جدید r در نیمه راه بین q و همسایه آن f با بزرگترین متغیر خطا $w_r = 0.5(w_q - w_f)$ قرار می‌گیرد.

• لبه‌هایی را که واحد جدید r را با واحدهای q و f متصل می‌کند وارد کنید و حذف کنید لبه اصلی بین q و f

• متغیرهای خطای q و f را با ضرب در a کاهش دهید ثابت \cdot : متغیر خطای r را با مقدار جدید $\frac{1}{a}$ مقداردهی کنید متغیر خطای

۹.

۹. همه متغیرهای خطا را با ضرب در ثابت d کاهش دهید.

۱۰. اگر یک معیار متوقف‌کننده (به عنوان مثال، اندازه خالص یا برخی از معیارهای عملکرد) نیست هنوز کامل شده است به مرحله

۱ بروید روش توصیف شده چگونه کار می‌کند؟ مراحل سازگاری به سمت ورودی می‌رود سیگنال‌ها (۵). منجر به حرکت کلی همه واحدها

به سمت آن مناطق ورودی می‌شود فضایی که سیگنال‌ها از آن می‌آیند ($P > 0$). درج لبه‌ها (۶). بین نزدیکترین و دومین واحد نزدیک

به سیگنال ورودی a را تولید می‌کند اتصال واحد "مثلث بندی دلونی" (نگاه کنید به شکل ۱ ب) با احترام به موقعیت فعلی همه واحدها.

حذف لبه‌ها (۷). برای خلاص شدن از شر آن لبه‌هایی که دیگر وجود ندارند ضروری است بخشی از "مثلث بندی ناشی از دلونی"، زیرا نقاط

پایانی آنها دارای است منتقل شد این با پیر شدن لبه محلی (۳) در نزدیکترین واحد ترکیبی حاصل می‌شود با تنظیم مجدد سن آن لبه‌ها

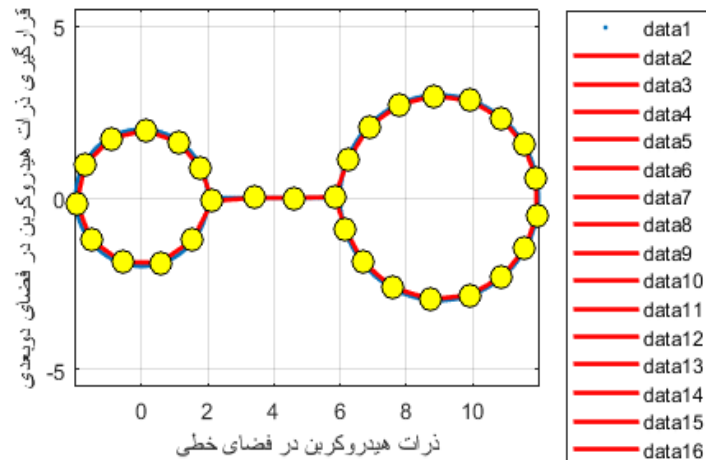
(۶) که قبلاً بین نزدیکترین و دومین واحد نزدیک با درج و حذف لبه‌ها، مدل سعی می‌کند بسازد و سپس ردیابی کند "مثلث بندی ناشی

از دلونی" که به دلیل این حرکت به آرامی در حال حرکت است اقتباس بردارهای مرجع تجمع فاصله‌های مربع (۴) در طول سازگاری به

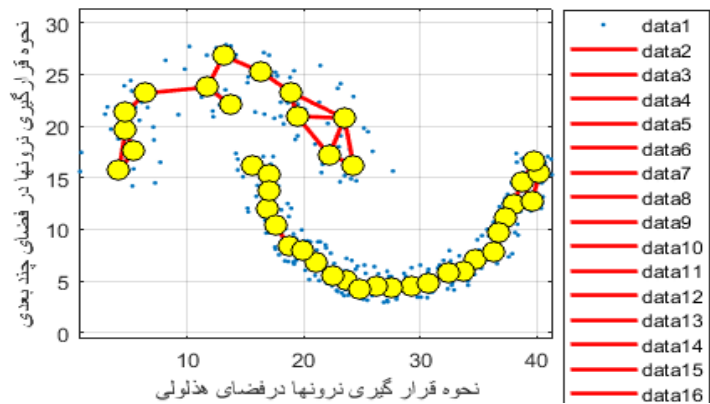
شناسایی کمک می‌کند واحدهای واقع در مناطقی از فضای ورودی که در آن نقشه برداری از سیگنال‌ها به واحدها قرار دارد خطای زیادی

ایجاد می‌کند برای کاهش این خطا، واحدهای جدیدی در چنین مناطقی وارد می‌شوند.

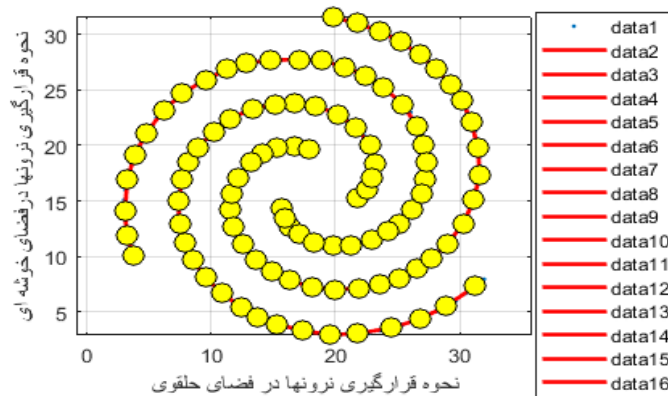
نتایج شبیه‌سازی



شکل ۱: نحوه قرارگیری نرونها در فضای خوشه ای ناهمگن



شکل ۲: نحوه قرارگیری نرونها در فضای نیمه خوشه ای در حال همگن



شکل ۳: نحوه قرارگیری نرونها در فضای تمام خوشه ای بصورت همگن

ما در حال حاضر برخی از نتایج شبیه سازی را برای نشان دادن رفتار کلی ما ارائه می دهیم مدل توزیع احتمال در:

شکل ۱. توسط مارتینز پیشنهاد شده است و شولتن (۱۹۹۱) برای نشان دادن مدل غیر افزایشی "گاز عصبی". میتونه باشه مشاهده شد که مدل ما به سرعت روابط مهم توپولوژیکی را در این زمینه می آموزد توزیع پیچیده با تشکیل ساختارهایی با ابعاد مختلف مثال دوم (شکل ۲) تفاوت بین مدل پیشنهادی را نشان می دهد و شبکه اصلی NG اگرچه توپولوژی نهایی برای هر دو مشابه است مدلها ، مراحل میانی کاملاً متفاوت است. هر دو مدل قادر به شناسایی هستند خوشه ها در توزیع داده شده اما فقط مدل "گاز عصبی در حال رشد"

شکل ۲: شبکه "گازهای عصبی در حال رشد" با توزیع سیگنال سازگار است دارای ابعاد مختلف در مناطق مختلف فضای ورودی است. نشان داده شده است شبکه اولیه متشکل از دو واحد تصادفی و شبکه های بعد از ۶۰۰ ، سیگنال های ورودی ۱۸۰۰ ، ۵۰۰۰ ، ۱۵۰۰۰ و ۲۰۰۰۰ اعمال شده است. آخرین شبکه نشان داده شده لزوماً "نهایی" نیست زیرا در اصل می توان روند رشد را به طور نامحدود ادامه داد. پارامترهای این شبیه سازی عبارت بودند از: $A=100$ ، $\epsilon_b=.02$ ، $\epsilon_n=.006$ ، $a=.5$ ، $a_{max}=50$ ، $d=.995$.

می تواند به رشد خود ادامه دهد و خوشه های کوچکتر را کشف کند (که در آنها وجود ندارد هر چند این مثال خاص) شبکه "گازهای عصبی در حال رشد" که در اینجا ارائه شده است قادر است روابط مهم توپولوژیکی را در سیگنال های ورودی مشخص کند. برتری در روش NG مارتینز و شولتن ، شخصیت افزایشی است مدلی که نیازی به تعیین اندازه شبکه ندارد. در عوض ، رشد این فرایند را می توان تا زمانی که معیار عملکرد یا اندازه شبکه تعریف شده توسط کاربر ادامه یابد برآورده می شود همه پارامترها در طول زمان برخلاف مدلها دیگر ثابت هستند به شدت به پارامترهای پوسیدگی (مانند روش NG یا ویژگی همگن) متکی هستیم نقشه) لازم به ذکر است که توپولوژی ایجاد شده توسط CHL یک ویژگی اختیاری نیست.

شکل ۳: شبکه NG/CHL مارتینز و شولتن (۱۹۹۱) و نویسنده مدل "گازهای عصبی در حال رشد" با توزیع احتمال خوشه ای سازگار است. نشان داده شده حالتهای اولیه مربوطه (ردیف بالا) و تعدادی از مراحل میانی هستند. هم تعداد واحدها در مدل NG و هم تعداد نهایی واحدها در مدل "در حال رشد گاز عصبی" ۱۰۰ است. ردیف پایین توزیع را نشان می دهد مراکز پس از ۱۰۰۰۰ مرحله سازگاری (لبه

ها مانند ردیف قبلی است اما نه نشان داده شده). توزیع مرکز برای هر دو مدل تقریباً مشابه است، اگرچه مراحل میانی به طور قابل توجهی متفاوت است.

کارهای آتی:

روش ما (همانطور که برای مدل NG است) اما یک جزء ضروری است برای هدایت سازگاری (کاملاً محلی) و همچنین درج مراکز استفاده می‌شود. این است احتمالاً راه اندازی مناسب واحدهای جدید با درون یابی واحدهای موجود که امکان داشتن فقط پارامترهای ثابت و سازگاری محلی را ممکن می‌سازد. کاربردهای احتمالی مدل ما عبارتند از خوشه بندی (همانطور که نشان داده شده است) و کوانتیزاسیون بردار.

شبکه باید به ویژه در شرایطی که همسایگی کار می‌کند عملکرد خوبی داشته باشد اطلاعات (در لبه‌ها) برای اجرای طرح‌های درون یابی بین آنها استفاده می‌شود واحدهای همسایه با استفاده از خطای رخ داده در مراحل اولیه می‌توان آن را تعیین کرد کجا می‌توانید واحدهای جدیدی را وارد کنید تا یک جدول توپولوژیکی با چگالی متفاوت ایجاد شود و ابعاد مختلف در مناطق خاصی از فضای داده ورودی.

یکی دیگر از جهت‌های امیدوار کننده تحقیق، ترکیب با یادگیری تحت نظارت است. این کار قبلاً با "ساختارهای سلولی در حال رشد" (فریتسکه، ۱۹۹۴c) و اخیراً همچنین با "گاز عصبی رو به رشد" توصیف شده در این مقاله (فریتسکه، ۱۹۹۴a). یک ویژگی مهم برای این نوع برنامه‌ها، امکان انتخاب دلخواه است معیار درج این ویژگی‌ها است که وجود ندارد، به عنوان مثال، در اصل "در حال رشد عصبی اولین نتایج این مدل شبکه تحت نظارت جدید، در حال حاضر شعاعی افزایشی شبکه عملکرد پایه، بسیار امیدوار کننده هستند و ما در حال بررسی بیشتر این موضوع هستیم.

مراجع

Fritzke, B. (1994c). *Supervised learning with growing cell structures*. In Cowan, J., Tesauro, G., and Alspector, J., editors, *Advances in Neural Information Processing Systems 6*, pages 255-262. Morgan Kaufmann Publishers, San Mateo, CA.

Martinetz, T. M. (1993). *Competitive Hebbian learning rule forms perfectly topology preserving maps*. In ICANN'93: International Conference on Artificial Neural Networks, pages 427-434, Amsterdam. Springer.

Martinetz, T. M. and Schulten, K J. (1991). *A "neural-gas" network learns topologies*. In Kohonen, T., Makisara, K, Simula, O., and Kangas, J., editors, *Artificial Neural Networks*, pages 397-402. North-Holland, Amsterdam.

Martinetz, T. M. and Schulten, K J. (1994). *Topology representing networks*. *Neural Networks*, 7(3):507-522.

Toghraee M, rad F, parvin H.,(2016). THE impact of feature selection on meta heuristic algorithm to data mining methods. International journal of modern education and computer science. Volum 8; issue 10., page(33).

Toghraee M, rad F, parvin H.,(2016). Evaluation of meta heuristic algorithm for stable feature selection. I.J.information technology and computer science (ijitcs),.volum8. issue:2074- 9015; pp: 22-29.

Toghraee M, rad F, parvin H.,(2016). Effect neural networks on selected feature by meta heuristic. i.j. mathematical science and computing (ijmcs).volum2.issue: 2310- 9033.pp:41-48.

Toghraee M, Esmaeili M , parvin H.,(2016).evaluation neural networks on selected feature by meta heuristic algorithms. Artificial intelligent system and machine learning.volum8.pp:108-115.

Toghraee M, rad F, parvin H.,(2017). Evaluation average total data set learning machine on the meta heuristic algorithm. International journal of emerging trend& technology in computer science .volum6.issue:2278- 6856.page(7).

Toghraee M, rad F, parvin H.,(2017). The Influence Select Feature on The Clustering Algorithm. Journal of Computer Science Engineering and Software Testing Volume 3 Issue 3.pp:1-10.