

امانت بر وجه یکشنبه ۱۰:۴۵ الی ۱۲ یکشنبه
چهارشنبه ۱۲:۰۰ الی ۲:۰۰ یکشنبه رمضان

مطالعه (مضامین) : حدود ترویجی

مراجع :

1. Neurocomputing, Robert Hecht-Nielsen, ۱۹۹۰
2. Fundamentals of Neural Networks, Laurene Fausett, ۱۹۹۴
3. Neural Networks, A Comprehensive foundation, Simon Haykin, ۱۹۹۴ (این سه بحث)

ارزانی :

- درجهان بیان ترم
- برورده آ
- گزارش مطالعه
- جدول در بیان ترم
- جدول در بیان ترم
- پیشنهاد در موضوع از طرف دانشجو
- موضوع بعد اطلاق ترم انتخاب شود
- جستجو برای مقالات و انتخاب مقالات (داشته)
- (استاد)

بحث درسی :

- ۱- مقدمه : ترویج شبهه دی عصبی ، درجه و بحث از شبهه شبهه دی عصبی ، زمینه تاریخی ، کاربرد و تکنولوژی گنگی و ...
- ۲- ترویج در عقول انسان : با حقار و نودینها که ضمیمه در بر روی ایجا جمله شبهه دی عصبی طبعی
- ۳- مفاهیم : ترویج و روش دی شبهه شبهه دی عصبی ، ملاحظه در بر لاریش ، اقتضات و ملاحظه
- ۴- ملاحظه در بر لاریش در سبب و سبب سبب ، ملاحظه در سبب سبب ، ملاحظه در بر لاریش ، ملاحظه در سبب سبب

۵- تدریس الگوریتم شبکه های عصبی: شبکه های عصبی، شبکه های عصبی عمیق، شبکه های عصبی بازگشتی و قضیه کوهن ابراهامسون و شبکه های عصبی دو طرفه

۶- مدل های عصبی، یادگیری نظارت، یادگیری بی نظارت، یادگیری، ارزیابی

* ۷- شبکه های عصبی عمیق: یادگیری رقابتی، شبکه های عصبی عمیق، شبکه های عصبی عمیق و شبکه های عصبی عمیق

* ۸- شبکه های عصبی عمیق بر روی داده های تصویری و گفتاری: شبکه های عصبی عمیق و شبکه های عصبی عمیق

تعمیم و تعمیم، شبکه های عصبی عمیق، شبکه های عصبی عمیق و شبکه های عصبی عمیق

۹- شبکه های عصبی عمیق و شبکه های عصبی عمیق

۱۰- شبکه های عصبی عمیق (GMDH) Group Method of Data Handling

۱۱- شبکه های عصبی عمیق (روش لاشتم و قوت)

۱۵- / مورد

Neural Networks, Neural Nets

Artificial Neural Networks (ANN)

Parallel Distributed Processing (PDP)

Connectionist Models

Neuromorphic Systems

Neural Computing

Neuro Computing

شبکه های عصبی عمیق ✓

شبکه های عصبی عمیق چیستند؟ تعریف از شبکه های عصبی عمیق، تعریف از روش های مختلف

در این مقاله کاربردی شبکه های عصبی عمیق را انجام داده و از اطلاعات

ناقص، مشخصات نیز ادراک و استخراج برشده اند.

معلومات بیشتر در مورد سیستم‌های رایانش سنتی (traditional computing) در این بخش خصوصی
پس از گذر از کامپیوتر رایج مردمی در دهه ۱۹۵۰؟

- ← ساختار نرم افزار رایج در آن زمان به ندرت از یک برنامه‌کار در نظر می‌گرفت.
- ← به جای خواندن برنامه برای پردازش اطلاعات طبیعی مناسب تر است.

در این بخش پردازش اطلاعات طبیعی : اطلاعات محدودیت‌های مختلفی با اصطلاحات در نظر گرفته شده
اینها خود ساختار است ناقص و ناقص هم باشند.

سیستم ادراک از آن می‌تواند بدون تصمیم‌گیری از یک حالت مختلف به اوزن باشد و اینها تمام
محدودیت در ارضاء شوند. در این حالت تصمیم‌گیری از آن می‌شود تا برای برداشتن تصمیم
کامپیوتر را اجتناب به این چنین تکلیف‌هایی در این نظام.

مقایسه بین رایانش سنتی (traditional computing) و رایانش خصوصی

در سال اخیر	نشان داده که رایانش خصوصی
به دنبال یک الگوریتم می‌گردد	از الگوریتم مشخص نشده
الگوریتم پیدا شده	بسیار کم از آن به روش‌های مختلف
قابل بهره‌برداری باشد	از رایانش خصوصی رستنداری کنیم
نوشتن نرم افزار	

رایانش خصوصی : رایانش سنتی، توزیع شده، خصوصی است در دریا به یک محیط اطلاعات
قدرت پردازش اطلاعات آن محیط را بسیار کمتر

Subject :

Year . Month . Date . ()

دانش عمومی

روش های آموزش عمومی سنتی

عموماً دانش بصورت قطعه بکس می شود

حافظه را طیف های توزیع شده کامل نیست

حافظه متدرج نیست

صدها بر حافظه سیستم به از کارهای روزانه

سیستم یادگیری نمونه (خود قطعه بکس را می آید)

اطلاعات در سیستم بصورت گامی توزیع شده است

حافظه متدرج است (سیستم یادگیری روزی)

که تنها شاهد شبکه یادگیری ناقص است

نیز در یادگیری و پیچیدگی می دهد

خواه تشخیص بعضی قسمتها (ملاحظه در اتصال)

رفتار شبکه یادگیری می تغییر می کند

(Fault Tolerance)

Graceful Degradation

این ویژگی برای کارهای مهم است

شکلهای عمومی، فازی، شبکه در روزهای اخیر AI جدا می شود اصطلاح دیگری به نام

Computational Intelligence به معنی است

Neural Networks ←

Fuzzy Systems ←

Genetic Algorithms ←

AI همان روش های کلاسیک می باشد

بیا در این شبکه های عمومی

۱- شبیه سازی نرم افزار

۲- شبیه سازی دهنده های سخت افزار

۳- مدارهای مجتمع فشرده اختصاصی

۴- پردازش تصویر

موضوع

Neural Networks using MATLAB -

Mathematics -

Neural wave - Neural Networks -

موضوعات

موضوعات: Neural Networks, Mathematics, MATLAB, Neural wave

موضوعات: Neural Networks, Mathematics, MATLAB, Neural wave

موضوعات: Neural Networks, Mathematics, MATLAB, Neural wave

موضوعات: Neural Networks, Mathematics, MATLAB, Neural wave

(MIS) موضوعات

IC Design

(ENN) Electronic Neural Networks - ART

100,000 (for 20)

Neural Networks IC - 20 (for 20)

Neural Networks IC - 20 (for 20)

(on-chip learning)

موضوعات

موضوعات: Neural Networks, Mathematics, MATLAB, Neural wave

موضوعات: Neural Networks, Mathematics, MATLAB, Neural wave

موضوعات: Neural Networks, Mathematics, MATLAB, Neural wave

موضوعات: Neural Networks, Mathematics, MATLAB, Neural wave

موضوعات: Neural Networks, Mathematics, MATLAB, Neural wave

Subject:

Year. Month. Date. ()

کاربرد های شبکه های عصبی

موفق العتارده متعهد در من باشد:

۱- شناسایی الگو

در بیان مشکل دسته بندی شبکه های عصبی در موفق بوده از

۲- بردار نشان تصویر و بنیاد های کامپیوتری

۳- آموزش مصنفی

۴- بردار نشان سگینا

۵- گفتار سیما

۶- در بیان اقتصادی و ما

۷- تشخیص پزشکی

گفتار های مهم در زمینه شبکه های عصبی:

- IEEE International Conference on Neural Networks (ICNN)

- International joint conference ~ ~ ~ (IJCNN)

دو سازمان: IEEE, INNS → برگزار کننده

(International Neural Networks Society)

محمد علی

1. IEEE Transactions on Neural Networks

2. Neural Networks (INNS)

3. Neural Computation

4. Neuro Computing (Elsevier)

سابقه تا کنون :

۱- Jackson (1869, 1958) هرشل
متدبیر شد و در نظریات وی ۱۹ نوردهی در خصوص توزیع شدگی
تقدیر توزیع شدگی چند سطحی بهنج اولاد در سیستم دی اولاد طبیعی

۲- vi. McCulloch & vi. Pitts (1943)

شان دادند و شکر دی عصبی را در مطلقاً حالت محاسباتی ریسم (صند)

۳- Hebb (1949) رولانسن

مغز قانوج ب : برای تغییرات سیناپسی در سلولها

۴- Loshley (1950) هرشل

اصول بر روی توزیع شدگی در سیستمی عصبی

There are no special cells reserved for special memories.

۵- Minsky (1951)

اولین کامپیوتر عصبی با نام Snark ساخت این کامپیوتر می توانست اعداد را
وزن دیش را تنظیم کند

۶- Rosenblatt (1957) دانه کونیل

دانه کونیل در نظریات سیستم perceptron ساخت و دستوری که
الگوریتم یادگیری پرسپترون را ارائه کرد و همگونی آنرا نشان داد
بهشت مدینه فتنه شدیم بسیاری افراد به این رشته
بسیاری روز نسبت به در شبگردی عصبی می دانند

۷. فنکی و سوت (اواسط دهه ۷۰) از دانشگاه MIT کتاب درسی از پرسترون
NN

۸. ویدرو widrow (1959) Stanford
یک مقاله پرکارشگر به نام Adaline اولین مقاله در باره توانایی قدرت
Adaptive Linear Element

۹. پرسترون تنها مقاله در باره توانایی حل کردن روابط ساده ای همچون XOR با استفاده از یک شبکه
کلاسیک از روشی ساده
کار آن تا حدی نشان داده که توانایی از شبکه های مصنوعی به Classic AI سوق پیدا کرده

۹. از مینون ۱۹۷۷-۷۷ (BROWN Uni.)

۱۰. لاینر اسیوسیاتور Linear Associator متنی بر مبنای ذخیره سازی و شناسایی در حافظه

۱۰. ۷lexbos (1974)

روشن بلای انتی رخط از خروجی یک شبکه به جهت درودها ارائه شده

۱۱. کوپونن ۱۹۷۲-۱۹۸۲ دانشگاه صنعتی سهندی

در زمینه یادگیری مبتنی بر شبکه های مصنوعی (نیمه دهه ۷۰) شبکه های کوپونن (نوعی شبکه)

۱۲. گولدرک ۱۹۷۸ نوردرگورت ، ریاضیات (BOSTON)

تئوری ریاضی خاص شبکه های مصنوعی در مورد آنتی مپ

۱۳. ویش ویش ۱۹۸۱

تکامل ریاضی در زمینه ارائه توزیع شده

۱۴. ساتن ویدرو ۱۹۸۱

قاعده اصلاح وزن به نام دلتا Delta

Subject :

Year . Month . Date . ()

۱۵. کانپور (۱۹۸۲)

فصل Crossbar Associative Network - (۱) شبکه کانپور هم شناخته شده

به مقصد شبکه مجوز به شبکه ای متصل به شبکه

۱۶. بنگال (۱۹۸۵)

قاعده ای برای اثبات خط از جدول یک شبکه به ورودی ادا شده

۱۷. راهپایان و مگنر (۱۹۸۶) و دانش

قاعده ای برای خط عقب با اصلاح قواعد برای ادا شده (حوزه ای برای راهپایان)

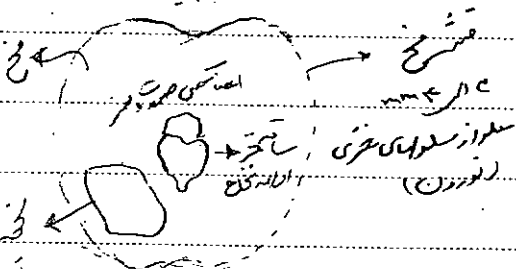
۱۸. ازنیک ۱۹۸۶ - تکنیک گسترش این رشته فوق العاده زیاده است

دانش ۳ مقدماتی در استخراج

مقر = بزرگترین ضلع دلاش

مقر بانی دست خاکبری، حدوداً همین حوزه ها که در نظر گرفته شده است ۱۵۰۰ رقم

دارای ۲ نیمه با تقارن آمیزگی



همین دوجوهری که شبیه تریا

در شکل که شبیه در بر موز در این شکل

سطح مقر مبنی بر این همین دوجوهری که شبیه تریا شده است

(Frontal lobe)
 Frontal lobe: responsible for planning, decision making, and problem solving.
 Temporal lobe: involved in hearing, memory, and language.
 Parietal lobe: processes sensory information from the body.
 Occipital lobe: responsible for vision.
 Cerebellum: coordinates movement and balance.
 Brainstem: controls basic life functions like breathing and heart rate.
 Spinal cord: carries messages between the brain and the rest of the body.

Subject :

Year . Month . Date . ()

مغز در زیر میکروسکوپ


بزرگنمایی با 30,000 برابر بزرگی در سطح داخل نورون

تشریح مغز است از سلولهای عصبی D به نام نورون (این باخته) نامیده ای که شده است می باشد.
 (10^{15} الی 10^{12} عدد) در مجموع این 10^7 الی 10^8 سلول برشته در 6 لایه لایه قرار دارند.
 شکل این نورون، برسی است و ستاره ای و لوزی و گردی
 قطر نورونها 10 الی 100 میکرون است. اتصالات بین نورونها تصادفی نیست در جهت ارتباطات
 بسیار دقیق و منظمی بین آنها وجود دارد. سلولهای دیگری نیز در تشریح وجود دارند به نام
 سلولهای گلیا (غذایی) از نورونها کوچکترند و تعداد آنها 10 برابر تعداد نورون می باشد.
 ماده سفید (Myelin) لایه نازک

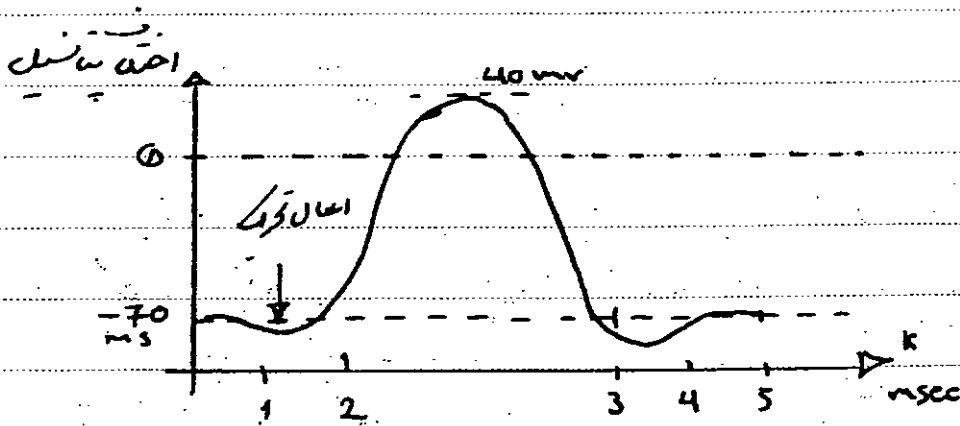
در مغزها یک نورون ممکن است بیش از 10^4 اتصال سیناپسی داشته باشد و این اتصال در
 مغز انسان 10^{14} الی 10^{16} اتصال وجود دارد.

ساختار الکتریکی مغز

بیشتر داخل سلول و سطح آن 7 الی 100 mV اختلاف پتانسیل برقرار است = پتانسیل استراحت
 در سطح و توزیع نامعادله یونی سدیم + پتاسیم در درون سلول می باشد و در سطح سلول کوکوی پرده شش وجود معنی در
 داخل سطح سلول ، توجه به اینکه اختلاف پتانسیل 10^{-6} است. (مقاله کویا در شیمی، الکتریسیته مغزی)



اگسوخ، حدود 1 ms پس از اعمال محرک. در این تصویر با نر درید




شکل و اندازه
 پتانسیل کاربند
 ثابت است و بستگی به اندازه
 محرک ندارد

اطلاعات: فرکانس در سال اینج سرجا انتقال دارد میشود

با حرکت پتانسیل فعالیت در اگسوخ، ششک شش و شش سلول بعدی چگونه مشخص میشود؟

۱- در اگسوخ پتانسیل کاربند سیناپس، که دی سزاد انتقال دهنده به حرکت ششک می رود در حلقه ششک پس حلقه را تخلیه میکنند تا به درون ششک نفوذ کند. انواع سزاد انتقال دهنده ممکن است خیلی زیاد باشد آن به نوسان به نظر می رسد تنها یک نوع دارد در رشته باشد



۲- با افزایش فرکانس ورود ضربه، نرخ دفعه ششک سزاد انتقال دهنده صورت میگیرد (کوانتومی اندازش می یابد)

۳- سولکولهای گیرنده در سلول پس سیناپس متغیر در وقت سزاد انتقال دهنده هستند و در وقت آنها در هم قدایی شوزر اختراع شد و در وضعیت نظی سلول پس سیناپس تغییر می کند

۴- اگر نوع ماده انتقال دهنده محرک و بلا لارزه (Excitatory) باشد، پتانسیل استتات سلول پس سیناپس به سمت صفر می رود (دپولاریزاسیون Depolarization) و اقله پتانسیل کم می شود. اگر اینج دپولاریزاسیون به بیان تر از یک استتات باشد، نوسان پس سیناپس ششک می کند

در دو مقدار کم ماده منتقل کننده سب ای دی و در دو مقدار زیاد سب ای دی پتانسیل ما در اندازه کوچک ای دی می کند

Excitatory Post Synaptic Potential (EPSP)

اگر در میان سیناپس و سیناپس ای محاور قبل از آنکه اثر EPSP او از بین برود یک EPSP دوم ای دی شده اثر آن با هم جمع می شود و اگر این حاصل جمع به یک حد آستانه ای برسد

سلول پیام شغلی می کند

ماده منتقل کننده نباید در نتیجه پس سیناپس جمع از زیر در این حالت سلول به یک حالت ثابت حد اکثر تحریک و دیپولرنا سب ای دی می آید سلول لایه ای آنتری می آید که ماده منتقل کننده را می شکنند و به محاور نیز فعال تری می کند

اگر ماده منتقل کننده در مقدار کم باشد و مقدار کم ماده ای که فرود می آید سیناپس عمل می کند اگر ماده ای که در مقدار کم باشد و مقدار کم ماده ای که فرود می آید سیناپس عمل می کند

مقدار کم ای دی از این جهت که در مقدار کم ماده ای که فرود می آید سیناپس عمل می کند

مقدار کم ای دی از این جهت که در مقدار کم ماده ای که فرود می آید سیناپس عمل می کند

سیناپس می تواند در سلول پس سیناپس ای ای می تحریک (وقتی ای دی در آنجا) اگر چه نحوه عمل یکسان است


این امر به جای دوک ای دی سب ای دی (Inhibitory) در آنجا سیناپس ای دی می کند

این امر به جای دوک ای دی سب ای دی (Inhibitory) در آنجا سیناپس ای دی می کند

فایده‌ای که سلول، به‌دانش بی‌سوی و گونج دارد کمی شگفتی‌انگیز است. مهم‌ترین مسئله در شگفتی‌بخش یک سلول، گوناگون بودن آن است. اگر سلول فقط یک است، در نهایت سلول درم حاد است. راجع به این مسئله، ایجاد کننده تقوله این مسئله است که عامل موثر آن، عامل دیگر فاصله بین آنها نیست، بلکه این مسئله است. (ظلم و عدالت) عامل دیگر محل زندگی بر روی زمین است.

← ۴ مفاهیم تعریف و اخذی شبکه‌های عصبی

یک شبکه عصبی، یک ساختار پردازشی توزیع شده، مسطری است. در فریم و گراف جهت‌دار است.



در این گراف برآمده، لان پردازشگر

(processing Element) - واحد پردازشگر

(processing Unit) - یونیت پردازشگر (Neuron)

نمونه‌ای شده

برای هر تعداد بر یک‌تعداد ورودی داشته و تنها یک خروجی دارد (احتمالی است که اینها یکی باشند)

خروجی هر گره می‌تواند بر یک‌تعداد بر یک‌تعداد گره‌ها وصل شده. سیم‌ها بین اتصالات یک گره و سایر سیم‌ها خروجی می‌باشد.

بر اتصالات گراف دارای جهت و وزن (weight) است. جهت نشانه و وزن نشانه گره می‌باشد.

گره مقصد اتصال مشخص می‌کند

گره (به لایه‌ها) (Layer) - (طبقات) قسمتی شده. لایه اول شبکه معمولا لایه ورودی

(Input Layer) - حلقه‌ای می‌شود. بر مبنای این لایه، هر یک سیم‌ها ورودی از خارج شبکه

دره‌فرت می‌کند و آن‌ها به لایه بعدی می‌رود و هیچ کار دیگری از این نمی‌کند. واحد دیگری این لایه، fanout units

نمونه‌ای شده

Subject:

Year: Month: Date: ()

- آؤخ لایہ شیکہ لایہ خوری، output لایہ میں شیکہ خورگی لایہ این لایہ خوری شیکہ لایہ شیکہ میں رہند۔

- لایہ دی بیچ لایہ دی ورودی و خوری، لایہ دی کھن (Hidden Layers) میں شیکہ میں شیکہ۔

- ہر واحد میں تیار بہ واحد دی لایہ خوری لایہ دی دیگر حاصل شیکہ۔

- واحد دی لایہ شیکہ میں شیکہ در نظر لایہ شیکہ۔

- مورد سیکہ میں در اتصال بصورت لایہ دی و لایہ تا خیر در نظر لایہ شیکہ۔

- عمل واحد میں تیار بصورت عمود یا بمقام (Synchronous & Episodic) ، غیر عمود (Asynchronous & Continuous) یا شیکہ در واحد دی عمود در زمانہ کی خاصی واحد دی ہر لایہ فعال میں شیکہ در نتیجہ ان، بہ استناد از ورودی، در وقت تباہی واحد، خوری دی جدید لایہ شیکہ میں شیکہ در شیکہ کی غیر عمود واحد لایہ شیکہ در حال کار ہونہ و بہ در وقت ورودی خوری دی جدید میں شیکہ۔

- حکمہ واحدی ہر شیکہ عمود یا عمود در نظر لایہ شیکہ غیر عمود۔

- در تباہی الاتصالات در یک فاز آموزش، ہر لایہ میں شیکہ (Training) ، (Learning) ، تباہی در تباہی لایہ شیکہ و نمونہ دی متعدد ورودی (Learning) میں شیکہ۔

Subject:

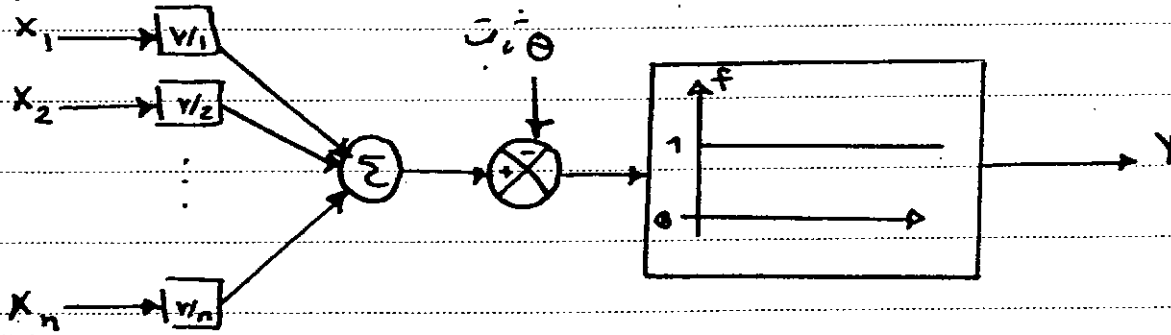
Year. Month. Date.

واحدی پردازشگر

1943

McCulloch & Pitts. مدل سلول دکارتی. با توجه به اطلاعات موجود در مورد نحوه عملکرد سلولها در مغز انسان
یک مدل ریاضی برای یک نوع صورت زیورانه ارائه دادند.


دستوریت



- دارنده ۱ : $w_i > 0$ وزن دادن
- بازدارنده : $w_i < 0$ اثر فرودینگی
- عدم اتصال : $w_i = 0$

حجتهای وارد شده به سلول Σ

این حجتهای وارد شده از یک حده با تریسیت \otimes



$$F\left(\sum_{i=1}^n v_i x_i - \theta\right) = y$$

روی سگ فرض کنیم : $x_0 = 1, v_0 = -\theta$

$$\Rightarrow y = F\left(\sum_{i=0}^n v_i x_i\right)$$

سلولهای واقعی دارای کمترین سبب اشتراکی می باشند:

۱- پاسخ دادن سلولها به ورودیها بطور گسسته می باشد نه پیوسته

۲- سبب اشتراکی از سلولهای واقعی که هیچ کار خطی از روی ایشان راهبره استوار نیستند

مثلاً در صورت نندارتی سلولها عدولت فقط به سبب اشتراکی می شود

۳- خروجی نودون واقعی یک دنباله (پالس) است نه یک تابع ثابت

۴- سلولهای واقعی دارای تأخیرهای نامتناهی هستند

۵- پاسخ نودون انتقال دهنده از یک سبب اشتراکی به صورت غیر قابل پیش بینی تغییر میکند


- واحد های پردازشگر مصنوعی با تقسیم مدل سلول نودون به طرق مختلف، واحد های مستقری در پاسخ نودون

الف) تقسیم پاسخ نودون (Activation, Gain, Transfer, Squashing Function)

در مدل نودون مصنوعی f تابع پله ای بود

الف) تابع خطی $f(x) = \alpha x$ ($\alpha > 0$)

$$f(x) = \begin{cases} \beta & x \geq 0 \\ -\delta & x < 0 \end{cases}$$



ب) تابع پله ای

در پاسخ تابع آر $\delta = 1$, $\beta = 0$, $\theta = 0$


$$\text{sgn}(x) = f(x) = \begin{cases} 1 & x \geq 0 \\ -1 & x < 0 \end{cases} \quad (\text{Sign Function})$$

خروجی نودون (درایک β) مقدار مثبت غیر صفری

این ارزشها نشان دهنده سبب اشتراکی در یک مدل یادگیری می باشد. Reward & Punish

Subject:

Year. Month. Date.



(ج) تابع قطعه قطعه خطی


$$f(x) = \begin{cases} a & x \geq a \\ x & |x| < a \\ -a & x \leq -a \end{cases}$$

(Sigmoid Function) (د) تابع سگموئید

(Logistic function) ← تابع سگموئید لوجیستی (تابع لوجیستی)

→ - - - - -


$$f(x) = \frac{1}{1 + e^{-\alpha x}} \quad \alpha > 0 \quad \text{تابع لوجیستی}$$



مشتق زیر است

$$f'(x) = \alpha f(x) \cdot (1 - f(x))$$

$$f(x) = \frac{2}{1 + e^{-\alpha x}} - 1 \quad \text{و} \quad \frac{1 - e^{-\alpha x}}{1 + e^{-\alpha x}}$$



مشتق زیر است

$$f'(x) = \frac{\alpha}{2} (1 + f(x)) (1 - f(x))$$

Subject:


Year: Month: Date: ()

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad \text{تابع تانج هپربولیک}$$

تقریباً در فاصله $[-1, 1]$ (سیگموئید در قطبی، $\alpha = 2$)


$$f'(x) = (1 - f(x))(1 + f(x))$$

$$f(x) = \begin{cases} \frac{x^2}{1+x^2} & x > 0 \\ e & \text{سویچت} \end{cases}$$



تابع نسبت تانج

$$f(x) = e^{-\frac{x^2}{\sigma^2}} \quad \text{نور و دمای}$$



تابع گوسی

$$f'(x) = -\frac{2x}{\sigma^2} f(x)$$

تابع فعالی برای داده‌های مختلف به صورت انتخاب می‌شوند
 به این است که داده‌های بی‌نهایت با تابع یکسان در نظر گرفته شود و داده‌های سایر (های مختلف) را متفاوت

تقسیم دایره
 حل لایه‌های تانج

تقسیم هم: توانک و دود در (منبر خطی) در نظر گرفته شود

$$y = f(\sum w_i x_i) \rightarrow g = f(\sum w_i x_i + \sum_{k=1}^{n_i} \sum_{l=1}^{n_l} \omega_{kl} x_k x_l)$$

(Second order) درجه ۲

اینج گندم از گندم (درجه ۱) قوی تر می‌باشد

$$y = f\left(\sum_{i=1}^n (x_i - w_i)^2\right)$$

$$f(x) = e^{-\frac{x}{2}}$$

Handwritten notes in Persian, possibly describing the function or its properties.

$$y = f(x, w, v)$$



Handwritten notes in Persian, likely explaining the diagram or the weights.


Handwritten notes in Persian, possibly defining variables or terms.

Handwritten notes in Persian, continuing the explanation or derivation.

Handwritten notes in Persian, including a small diagram with an arrow pointing left.

Handwritten notes in Persian, possibly concluding the notes or providing a final definition.

تعمیر بنیم : لورون کی منطق



$$w_i = a_i + j b_i$$

$$y = \left| x_1(a_1 + j b_1) + x_2(a_2 + j b_2) + \dots + x_n(a_n + j b_n) \right|^2$$

$$= (a_1 x_1 + a_2 x_2 + \dots + a_n x_n)^2 + (b_1 x_1 + \dots + b_n x_n)^2$$

$$z = f(y) = \frac{1}{1 + e^{-x(y-\theta)}}$$

تعمیر بنیم : لورون کی منطق

$$y = \sum_k w_k \prod_{i \in I_k} x_i \quad I_k = \{1, 2, \dots, n\} \quad ?$$

Spiking Neurons

تعمیر بنیم : لورون کی منطق

؟

1) نسل اول : برادسلی لورون کی منطق


2) نسل دوم : برادسلی لورون کی منطق

Subject:

Year: Month: Date: ()


؟ نسل سوم ، بر روی نوزادان هزینه ای می باشد

در ساده ترین مدل هزینه ای فرض می شود از آنجا که پتانسیل P_v نوزاد v به
 یک حد آستانه ای θ_v می رسد شکل می کند پتانسیل P_v مجموع EPSP ها
 و IPSP اندودی به نوزاد است. شکل یک نوزاد پیش سیناپس u در
 زمان s در زمان t به پتانسیل P_v هزینه $w_{u,v}$ $\epsilon_{u,v}(t-s)$
 به نوزاد v اثر می گذارد.



برای s در $\epsilon_{u,v}$ ثابت در اطراف

نوزاد صلبی در روی پتانسیل استراحت -70mV است و پتانسیل شیب -50mV
 نوزاد پیش سیناپس پتانسیل نوزاد سیناپس را در زمان t شکل کرده و
 میان وقت ظهور تغییر در v نوزاد t شکل کرده برای
 مدت کوتاهی قادر به شیب نیست. این موضوع توسط یک تابع آستانه $\theta_v(t-t)$
 بصورت زیر مدل می شود:



رایج نوزاد اگر $F_v \in R^+$ مجموعه نوزادان شیب نوزاد u باشد پتانسیل
 نوزاد v در زمان t عبارت از

$$P_v(t) = \sum_u \sum_s w_{u,v} \epsilon_{u,v}(t-s)$$

$s \in F_u$ که واحدی باشد

Subject :

Year . Month . Date .

بسیج $P_V(t) - \Theta_V(t-t)$ نوری شکلی

رفتار دینامیکی واحد

برای اینکه نوری را بشود که اصولی رفتار کند با هر از جمله دیگر اینها نیز تحت

$$\frac{dy}{dt} = -g(y) + \sum_{j=0}^n w_j x_j = -g(y) + I$$

تأثیر ورودی $I \rightarrow$ تأثیر خروجی

$$\frac{dy}{dt} = 0 \quad \text{در حالت تعادل}$$

$$\Rightarrow -g(y) + I = 0 \Rightarrow y = g^{-1}(I) = g^{-1}\left(\sum_{j=0}^n w_j x_j\right) = f\left(\sum_{j=0}^n w_j x_j\right)$$

اینجمله معین رابطه ای است که برای خروجی نورون داشته بودیم

$$g(x) = \frac{-1}{2\beta} \ln \frac{1-x}{1+x}$$

$$x = f(x) = \tanh(\beta x)$$

شماره

انقلاب شبکه

جهت جریان اطلاعات به شغف منتهی
وزن معبر و تاثیر سکون

در این دوره یادگیری و آموزش شبکه عصبی می شود. مقادیر ثابت و تغییرات در شبکه انقلاب
دادارنده هستند و مقادیر متغیرشان در شبکه انقلاب باز دارند بسته به عدم انقلاب

وزن می تواند به نفع داده ای در شتاب بیشتر: اعداد مثبت، منفی، صفر و ...
 به تنظیم مشخص کنیم که هر اتصال از یک شیب می شود و در یک خانه می یابیم. اگر واحدی شبکه را
 از این به شماره گذاری کنیم می توانیم که ماتریس اتصال *Interconnection Matrix*
 به صورت زیر تشکیل داد:

$$M = [m_{ij}] \quad m_{ij} \begin{cases} 1 & \text{یک اتصال از واحد } i \text{ به واحد } j \\ 0 & \text{بدون اتصال} \end{cases}$$

برای ارائه اتصال و وزنی از این ماتریس وزنی شبکه تعریف شده است
 هر ماتریس در یک اتصال و یک لایه به لایه بعدی می دهد.

$$V_i = [v_{ij}] \quad v_{ij} : \text{ وزن داده لایه } i \text{ به لایه } j \text{ بعدی}$$

بعضی مراجع از برای فوق را برگردانی می نویسند یعنی v_{ji} برابری از رخ اتصال از واحد i به واحد j بعدی

ماتریس در یک تشکیل شده در این حالت *transpose* ماتریس حالت قبل می باشد.
 کتاب *Neuro Computing* از حالت D مستثنی می کند

حاله بعد:

$$W_{ij} \quad \text{رخ اتصال از واحد } i \text{ به واحد } j \text{ بعدی}$$

$$-W_{ij} \quad \text{ورودی به واحد } i \text{ لایه } j \text{ بعدی از واحد } i \text{ قبل}$$

اتصال کامل به صورت زیر باشد:

(۱) کامل (Full) از خود به تمام واحدی لایه بعدی وصل می شود

(Uniformly Random)

۱۲) آلف متغیرات
بر پایه n ورودی از n بردار n - صورت آنفرض ای با توزیع یکسان انتخاب
شده از دریافت n گانه

۱۳) یک به یک (One to One)

بر روی هر یک لایه یک اتصال از لایه قبلی دریافت می کند

معاری شبکه های عصبی

۱) شبکه های پیش خور feed forward

۲) شبکه های خور پس (بازگشتی) feedback, Recurrent

در شبکه های پیش خور از شبکه های سیر بسته ای ظاهر

نه " " " " دارای سیر بسته است

شبکه های پیش خور عمدتاً استاتیکی هستند آنها در دسته متغیر خوری دریا پیچیده ورودی ای (د)

بسیار اغلب از حالت مغز شبکه مستقیم است

شبکه های پس خور دینامیک هستند (وقتی که ورودی اعمال می شود خروجی از طریق سیر

بسته محدود به ورودی اعمال می شود و خارج از آن تغییر دهد)

شبکه های خور : شبکه های مستقیم یا حلال
شبکه های پس خور : شبکه های حافظه
شبکه های پیچیده یا غیر خطی : شبکه های (ART) تطبیق الگو

Classification

۲. محدودی بردار شکر در مسائل دسته بندی

در مسائل دسته بندی ، دسته بندی گفته می شود ، استفاده از نمونه ای شنخته شده یا در گذشته
چگونه اشتباه ، الگوریتم برای دسته بندی می تواند از دسته بندی گذشته
میسوزد در وقت هر ورودی جدیدی توسط تصمیم گیری ورودی به یک گروه دسته تعلق دارد
سازده ترین حالت دسته بندی : دو دسته

دسته اول : اشتباه تعلق به دسته ای خاص
~ ۳۵ : سبب اشتباه

این هم دسته بندی ه شبکه مصوبی : دسته دوم (۱) ۵
دسته اول ۱
یک بار خروجی

حالت m دسته بندی

$$\geq 0 \rightarrow y_1$$

$$\geq 0 \rightarrow y_2$$

⋮

$$\geq 0 \rightarrow y_m$$


هر کدام از خروجی ادنیان شده

می فهمیم که ورودی متعلق به کدام

دسته بوده است.

عمل دسته بندی در واقع معادل با جد بندی فضای ورودی توسط شبکه است.

مثال : تشخیص وزن بردار از وکتور بیت



دقیق و دقیق تر در متن

فاز آموزش : تعیین درجه هر یک از بیت های سیستم آموزشی

$$(x, y)$$

⋮

$$\underline{x} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

Subject:

Year: Month: Date: ()

طراحی شبکه

$$y = f(I) = f\left(\sum_{i=0}^2 \omega_i x_i\right)$$

$$\underline{x} = \begin{pmatrix} 1 \\ x_1 \\ x_2 \end{pmatrix}$$

$$\underline{w} = \begin{pmatrix} -\theta \\ w_1 \\ w_2 \end{pmatrix}$$


$$I = -\theta + w_1 x_1 + w_2 x_2$$

$$f(I) = \begin{cases} 1 & I \geq \phi \\ -1 & I < \phi \end{cases}$$

دو دسته از نمونه‌ها (دو گونه‌ها) در این شکل

معمولاً از (x_1, x_2) به I تبدیل می‌شود + می‌شود (در آن مقدار I به ϕ می‌رسد) - می‌شود
نقطه مرز $I = 0$ از این جهت

$$w_1 x_1 + w_2 x_2 - \theta = 0$$



دسته اول
دسته دوم

فاز استوار

اگر دسته دوم فقط یک نمونه داشته باشد و دسته اول دو نمونه داشته باشد و خط مرز از آن طوری انتخاب شود که هر دو دسته از آن جدا شوند

مطالعه‌ی پرواز شکر و تعاهداری

* (۱) مطالعه پرواز شکر (Hebb)

تأثیر حب سونان و قندی بر آن قاصد درگیری است که در سال ۱۹۴۹ توسط Donald Hebb انجام شد. دانشمند بعد از آن شد.

بگاه نونخ با ظهور یک نور و درام در آنش شخ نونخ فی ضایت کند میزان تأثیر این نونخ در آنش نونخ نونخ فی افزایش میزان تحقیقات بعدی نشان داد. نظریه حب به طوری صحیح است.

وقتی نونخ حب به دسته فلانخ، درگیری هم و قومی (Coincidence learning) اتفاق دارد.

در مطالعه‌ی سادو، نتایج مثبت در مقادیر (از قانخ حب بر روی یادگیری استفاده کند و بعد حب نونخ به دسته فلانخ).

بطریق قانخ حب حرکات در نونخ ظهور نمونان فعال باشند و رخ اتصال بین این سید افزایش یادگیری در سال ۱۹۸۸، مگر کلی نمونان در این قدرت این سید، بلاگسترش دارد. این ترتیب که از نونخ به ظهور نونخ خاموش نیز باشند، قدرت اتصال نمودها از آنست که در سال ۱۹۸۸.

الکوریتم حب با این صورت خلاصه می‌شود:

(۵) مقدار اولی در آن مشخص شود (شکل $N \times N$ ، $\varphi = 0$)

(۱) برای هر زوج نمونان ورودی (s, t) قدری φ را اعمال می‌کنیم (Source, target)

۱۶ - در مورد ورودی محدود نمونه نسبت داده شده

$$\begin{cases} X_i = S_i & i = 1 \dots N \\ y = t \end{cases}$$

۱۷ - رزق و عقله با بین از رابطه زیر اصلاح شده

$$\begin{cases} V_i^{NEW} = V_i^{OLD} + X_i \mu \\ \theta^{NEW} = \theta^{OLD} + \mu \end{cases}$$


نقاط اوج و کلا در کم (0,0) و (0,1) تغییر می کنند در حالتی از مقدار در نقطه داشته باشیم نتایج فوقی نشانه (استفاده از مقدار در نقطه با بحث عملکرد بهتر این قانون می باشد)

۱۸ - مطالعه بر روی شکر و پسته

برای شیرینی که ساخته شده است حرف لاتین از روی مقدر حرف مورد نظر بر روی یک اسلاید برسی
۲۰۲۰ در کشورهای حاصل می شود که در ۴۰۰۰ هکتار حاصل می شود که در ۱۰۰۰ هکتار

مطالعه شده
سیستم دارای ۵۱۳ تا سنسور که به صورتی انتر می کنند داده می شود. تقسیم آنرا به ۱۰۰۰
و دستگیره از این تا سنسور - برترود این می باشد. تعدادی واحد آنتن نیز برای ای کار خود می
در نظر گرفته شده و اینها در مقادیر مختلف قابل دسترسی ای می باشد از این جهت
شکر بر روی این صفر بسته می باشد. اطلاعات بین لایه دی اول و دوم شکر به طول افتاد و در زمان
۱-۱-۱۰ برقرار گردید و نتایج فعالیت مطالعه در ۱۰۰۰ هکتار صورت می گیرد به بعد

دسته بندی دلخواه ان ثابت در نظر گرفته شود. در زمانی واحد خود به دستاره اربابانونی بر نام مانوخ
 پرستیدم صبح گویان



واحد پرستیدم

مخ، این ظاهر خواهد بود دسته A و B
 از هم آیزده و زیر آیدی دسته بندی \underline{x}
 $\theta = \begin{cases} 0 & \text{دسته A} \\ 1 & \text{دسته B} \end{cases}$

اصول می شود و ۷۱ صبح مانوخ

دفعه آموزش بر طاری (x, t)

مقدار
 - \underline{x} مقدار بر روی

$$\underline{x} = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix}$$

$$\underline{v} = \begin{pmatrix} \omega_0 \\ \omega_1 \\ \vdots \\ \omega_n \end{pmatrix}$$

$$\underline{v}^{NEW} = \underline{v}^{OLD} + (t - y) \underline{x}$$

قانون پرستیدم

$$\Delta \underline{v} = (t - y) \underline{x}$$

دسته A احتمالاً در طبقه ۱ است
 دسته B احتمالاً در طبقه ۰ است
 دسته صفر احتمالاً در طبقه ۱ است

Subject:


Year: _____ Month: _____ Date: _____

(در این زمینه)


روزگفت ثابت گوید در مدارت به صورت خط حقیقی زیر باشد از این نوع به همکار در روزگار
اگر سیستم پرستشوخ دیگر تقویت کننده در مدار است باید خط حقیقی که [حدای الگوریتم]

نمایند: به صورت خط حقیقی زیر یونگ راسته

x_1	x_2	y
0	0	0
0	1	1
1	0	1
1	1	0



مثل: یاد داری که XOR یا پرستشوخ



درست است: 00
11

خوبی = 0

درست است: 01
10

خوبی = 1

در اینجا دیگر از قانون یاد داری پرستشوخ مطرح شد

$$\Delta v_i = \alpha (t - y) x$$


$$\alpha = \frac{1}{\|x\|^2} \quad \bullet \quad \alpha = \frac{|x \cdot v_i|}{\|x\|^2}$$

Adaptive Linear Element

تأخذ پردازشگر آداپتیو

وینبرگ 1959 در دسترس بود

در مدار با این لوید فرسوخ (آداپتیو) استاده شده



الذریعہ LMS، Δw کا طریقہ

$$x = \begin{pmatrix} 1 \\ x_1 \\ \vdots \\ x_n \end{pmatrix} \quad w = \begin{pmatrix} w_0 \\ w_1 \\ \vdots \\ w_n \end{pmatrix}$$

$$I = \sum_{i=0}^n w_i x_i = \underline{w} \cdot \underline{x} = w^T x = x^T w$$

$$y = \text{sgn}(I)$$

Least Mean Square

Least Mean Square of Error

قانون لیسکی LMS
= LMSE

یہ سچ بہت سے ایسی صورتوں میں درست ہے (متوسط مربع خطا درجہ اول) (توضیح: رجسٹر بنیادی شرح)

Performance Learning: از حد کم قوت

فرض کریں کہ x و t کے درمیان کوئی بھی تعلق نہیں ہے۔ صرف آئٹمز کے بارے میں آئیے دیکھیں کہ آئیے زیر طاعت لیتے ہیں۔

$$F(w) = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n (t_k - I_k)^2 = E \{ (t_k - I_k)^2 \}$$

$$F(w) = E \{ (t_k - w^T x_k)^2 \}$$

$$= E \{ t_k^2 - 2t_k w^T x_k + w^T x_k x_k^T w \}$$

$$= \underbrace{E \{ t_k^2 \}}_P - 2w^T \underbrace{E \{ t_k x_k \}}_q + w^T \underbrace{E \{ x_k x_k^T \}}_R w$$

$P = \sigma^2$

q

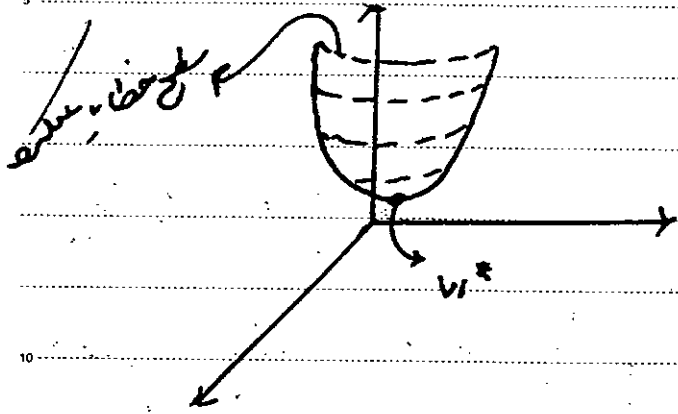
$R_{n \times n}$

تاریخ مشق

$$F(\underline{w}) = P - 2\underline{w}^T \underline{q} + \underline{w}^T \underline{R} \underline{w}$$

تابع درجه 2 از \underline{w}

داشته F - \underline{w} بصورت درجه 2 مرتبه و تنها در حالت فوق R و سطح بیته
 از $F(\underline{w})$ یک سطح بیته گوییم که از این وجهه طریقه کار می کند نقطه حقیقی که در آن
 $F(\underline{w})$ حقیقی شده (\underline{w}^*)



$$\nabla_{\underline{w}} F(\underline{w}) = \nabla_{\underline{w}} (P - 2\underline{w}^T \underline{q} + \underline{w}^T \underline{R} \underline{w})$$

$$= -2\underline{q} + 2\underline{R} \underline{w} = \underline{0} \quad \text{از \underline{w}^* = $\underline{R}^{-1} \underline{q}$ }$$

$$\Rightarrow \underline{w}^* = \underline{R}^{-1} \underline{q}$$

Generalized Inverse

R^+ : معکوس تعمیم یافته


Pseudo-Inverse

$$R^+ = R^{-1}$$

در R معکوس از R^+ (non-singular)

در \underline{w}^* یعنی $\underline{w}^* = \underline{R}^{-1} \underline{q}$ سطح بیته $F(\underline{w})$ حقیقی شده

در ۲ عددی در مشتق (Singular) v_1^* نزدیکترین منیم به بزرگترین خلاصه
 سطح عکس نظری و نظریات خلاصه v_1^* در نقطه v_1^* بزرگترین منیم به بزرگترین خلاصه



بزرگترین منیم به بزرگترین خلاصه

در ۱۰ عدد و حد در ۱۹۵۹ شش کوز در v_1^* با v_1^* نزدیکترین منیم به بزرگترین خلاصه (W_0)
 در v_1^* نزدیکترین منیم به بزرگترین خلاصه (W_0) در v_1^* نزدیکترین منیم به بزرگترین خلاصه (W_0)
 در v_1^* نزدیکترین منیم به بزرگترین خلاصه (W_0) در v_1^* نزدیکترین منیم به بزرگترین خلاصه (W_0)
 در v_1^* نزدیکترین منیم به بزرگترین خلاصه (W_0) در v_1^* نزدیکترین منیم به بزرگترین خلاصه (W_0)

$$\nabla_w f(v_1) = \nabla_w \left[\lim_{N \rightarrow \infty} \frac{1}{N} \sum (t_k - I_k)^2 \right]$$

$$= \lim_{N \rightarrow \infty} \frac{1}{N} \nabla_w \left[\sum (t_k - I_k)^2 \right]$$

$$= \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N 2(t_k - I_k) \nabla_w (-I_k)$$

σ_k $I_k = w^T x_k$
 $-x_k$

$$\Rightarrow = - \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N 2 \delta_k x_k = -2 E[\delta_k x_k]$$

$\delta_k = t_k - I_k$

Subject :

Year . Month . Date . ()

در هر دو با تصمیم گرفته می شود که به بیش از یک مقدار نزدیک
دستند و می کنند آنرا نشان دادند که قانون زیر با شیب از هر نقطه ای $v_{k+1} = v_k + \alpha \delta_k x_k$ به v_k^* همگرا می شود

(14-15)

$$v_{k+1} = v_k + \alpha \delta_k x_k \quad 0 < \alpha < \frac{2}{R}$$

قانون دیگری در اینجا LMS است

چون باید که مقدار R مشخص است α را محدود می کنند و سعی در حفظ مشخص
مقادیر می کنند آن در حد $0.01 \leq \alpha \leq 10$ و اینترال در ابتدا $\alpha > 0.1$ شروع می کنند
و α خیلی کم باشد تا کم کم به مقدار α مشخص می شود و در نهایت به مقدار α مشخص می رسد

در سال 1988 در این زمینه پیشنهاد شد $\frac{0.1}{n} \leq \alpha \leq \frac{1}{n}$ در نظر گرفته شد

دو نسخه مختلف تاریخ دارد

Adaptive

1) نسخه Batching :

v_k پس از تعداد زیادی x_k به v_k^* همگرا می شود و در هر دو نسخه
برای به دست آوردن $\delta_k x_k$ باید به v_k دسترسی داشته باشیم و این است که در نسخه دیگر
گرفته می شود

2) نسخه Momentum :

$$v_{k+1} = v_k + \alpha(1-\mu)\delta_k x_k + \mu(v_k - v_{k-1})$$

$$\Delta v_{k+1} = \alpha(1-\mu)\delta_k x_k + \mu \Delta v_k$$


$\mu > \alpha$ $\mu = 0.9$ (مقدار در بردار تغییرات)

حریک از این روش در معادله اثر علی و در معادله خیر است. معادله این شرایط متفاوت
 بهم نیست.

بر تقسیم نری از این نیز یک خط است $(I = v_1^T X)$ و در نتیجه پیشتر منتهی که بر خط حفظ
 حاصل از این نباشند قابل حل نیست.

Polynomial
 Preprocessor

در سمت غیر خطی از این درجه 2 است.



$$I = v_0 + v_1 X_1 + v_2 X_2 + v_{11} X_1^2 + v_{12} X_1 X_2 + v_{22} X_2^2$$

یک نیز بعضی شکل داریم.

این روشی حاصل می‌شود و معادله در این روش به این شکل است
 نیز زیادتر شد.


Subject :

Year . Month . Date . ()

Listar

فلاجه لار شتر انستاده

آرسا رابره موزن شده



دفعه v_i مقدار متوسط دودی $u(t)$ در وقت فعلی x_i ضرب به x_i فرض بر اینست که فرض بر آنست که اوقات x_i همواره همزمانه وقتی در فعلی باشد مقدار ثابت قابل توجهی تمیله میکنند

$$v_i = \overline{x_i u}$$

این قانون یادگیری گراوگن نامیده شده و چون قانون یادگیری فلتد است
Filter Learning

$$v_i^{NEW} = v_i^{OLD} + a (x_i u - v_i^{OLD}) \quad \begin{matrix} \uparrow & \uparrow \\ \text{تغییر} & \text{تغییر} \end{matrix}$$

اگر فرض کنیم محور زمان دودی داشته باشیم بعد از آن زمانی که مقدار فعلی x_i صرفاً باشد
 مقدار یادگیری به صورت زیر خواهد بود:

$$v_i^{NEW} = v_i^{OLD} + a (x_i u - v_i^{OLD})$$

می شود تا اینکه اگر استفاده از قانون فوق، فرض کنیم $w_i = x_i u$ را در خلاصه کنیم

در قانون فلتد، هر از صودی حاصل سینگی باشد و در آن صورت در عمل فلتد در سینگی
 زودتر اعمال شده باشد، به فرض اختصاص دادن و شش

Handwritten signature and text at the bottom of the page.

Handwritten text: $\varphi(x) = \varphi(x)$

Handwritten text: $\varphi(x) = \varphi(x)$

Handwritten text: $\varphi(x) = \varphi(x)$

Handwritten text: $\varphi(x) = \varphi(x)$

Handwritten text: $\varphi(x) = \varphi(x)$

Handwritten text: $\varphi(x) = \varphi(x)$

Handwritten text: $\varphi(x) = \varphi(x)$

Handwritten text: $\varphi(x) = \varphi(x)$

Handwritten text: $\varphi(x) = \varphi(x)$

Handwritten text: $\varphi(x) = \varphi(x)$

Handwritten text: $\varphi(x) = \varphi(x)$

Subject: _____

Year: _____ Month: _____ Date: _____ ()

انواع شکردهای متداولی

۱) شکردهای همبسته (بند خور)

۱۵

در شکردهای همبسته اطلاعات تنها از روی - خصوصیات در میان می آید - اعمال روی X نیز به این درجتهای متناظر آن درجتهای می شود

در شکردهای همبسته اطلاعات از خصوصیات هم - روی هر یک می آید - (اعمال روی X حلقه ای به زشتی و فقط در شکردهای همبسته می آید)

دسته بندی دیگر

Auto Associative

۱) شکردهای متداولی

Hetero Associative

۲) غیر متداولی

در شکردهای همبسته $m=n$ و $y_i = x_i$
در غیر همبسته $y_i \neq x_i$

دسته بندی سوم:

(Assertive)

۱) شکردهای همبسته

(Interpolative)

۲) درجتهای



$$\psi(x_i + \epsilon) = y_i$$

در این حالت خطای

$$\psi(x_i + \epsilon) = y_i + \delta$$

$$|\epsilon| \rightarrow 0 \Rightarrow \delta \rightarrow 0$$

(خطای خردی نسبت به خطای روی)



$$\underline{X} = [x_1 \dots x_n]^T \quad n \times 1$$

$$\underline{Y} = [y_1 \dots y_m]^T \quad m \times 1$$

$$\underline{T} = [t_1 \dots t_m]^T \quad m \times 1$$

$$\underline{v}_i = [w_{i1} \ w_{i2} \ \dots \ w_{in}]^T \quad n \times m$$

$$\underline{Y} = \underline{V} \underline{T}^T \underline{X} \quad \underline{V} = (\underline{v}_1 \ \underline{v}_2 \ \dots \ \underline{v}_m)$$

$n \times m \quad m \times n \quad n \times 1$

$$\underline{W} = (\underline{T} \underline{X}^T)^T = \underline{X} \underline{T}^T$$

عکس به نظر آید

اگر \underline{S}_k از بزرگ‌ترین (S_i, I_i) برای آموزش باشد به کار گرفته شود پس از آموزش، در روزی

$i = 1, \dots, k$

$$\underline{X} = \underline{S}_k \quad \text{به اشتباه اعمال که خروجی به یادگار \underline{T}_k است}$$

$$\underline{X} = \underline{S}_k + \underline{\epsilon} \quad \text{اگر $\underline{\epsilon}$ به اشتباه باشد خروجی به یادگار $\underline{T}_k + \underline{\delta}$ یعنی مقدار (دوین) از خروجی آن خواهد بود}$$

آموزش شبکه

$$w_{ij}^{NEW} = w_{ij}^{OLD} + S_{ki} t_{kj} \quad \text{برای کلاس k و روزی i آموزش}$$

(از استقده از قانون ضرب)

$$\underline{S}_k = (S_{k1} \ \dots \ S_{kn})^T$$

$$\underline{T}_k = [t_{k1} \ \dots \ t_{kn}]^T$$

$$\underline{V}^{NEW} = \underline{V}^{OLD} + \underline{S}_k \underline{T}_k \quad \text{(به عنوان قانون به جهت برابری)}$$

Subject: _____

Year _____ Month _____ Date _____

برای V_I ^{NEW} به مقدار V_I ^{OLD} فرض کنیم. فرض ما: $V_I = \underline{0}$

برای L نمونه آموختن
$$V_I = \underline{S}_1 \underline{T}_1^T + \underline{S}_2 \underline{T}_2^T + \dots + \underline{S}_L \underline{T}_L^T = \sum_{i=1}^L \underline{S}_i \underline{T}_i^T$$

آیا با انتخاب \underline{V}_I مناسب، می‌توانیم مقدار \underline{S}_k را از خروجی \underline{V}_I خلاصه‌نامه بگیریم؟

فرض کنیم $\underline{V}_I = \underline{S}_k$ به شکل $\underline{x}_k = \underline{S}_k$ در این حال داریم:

$$\begin{aligned} \underline{y} = \underline{V}_I^T \underline{x} &= \underline{V}_I^T \underline{S}_k \\ &= (\underline{T}_1 \underline{S}_1^T + \underline{T}_2 \underline{S}_2^T + \dots + \underline{T}_L \underline{S}_L^T) \underline{S}_k \\ &= \underline{T}_1 \underline{S}_1^T \underline{S}_k + \dots + \underline{T}_k \underline{S}_k^T \underline{S}_k + \dots + \underline{T}_L \underline{S}_L^T \underline{S}_k \end{aligned}$$

اگر \underline{S}_i بردارهای عمودی \underline{S}_i متعامد باشند:

$$\underline{S}_i^T \underline{S}_j = \delta_{ij} = \begin{cases} 1 & i=j \\ 0 & i \neq j \end{cases}$$

$$\underline{y} = \underline{T}_k \underline{S}_k^T \underline{S}_k = \underline{T}_k$$

اما شرط فوق، شرط بسیار محدودکننده‌ای است. حداقل تعداد بردارهای متعامدی که در فضای n بعدی قرار دارند n است. لذا هرگز نتوانیم بردارهای n تایی را در فضای n بعدی خلاصه‌نامه بگیریم. علاوه بر این، بردارهای n تایی که در فضای n بعدی قرار دارند، باید متعامد باشند. اما این کار، به شکل متعامد شدن بردارهای n تایی، به سبب این است که اگر بردارهای متعامد n تایی داشته باشیم، آن‌ها را نمی‌توانیم خلاصه‌نامه بگیریم.

$$\underline{y} = \underline{T}_k + \sum_{j \neq k} \underline{T}_j \underline{S}_j^T \underline{S}_k = \underline{T}_k + \dots$$

خطای بازتاب

Next
 Next
 Next
 $y = W^T S$

For $i \neq j$, $F(W) = 0$ or $W^T S_j \neq 1$

For $i = j$, $F(W) = 0$ or $W^T S_j = 1$

$$\sum_{i=1}^n W^T S_i = \sum_{i=1}^n \alpha_i \cdot 1$$

Minimize $\|S - W^T S\|$ subject to $S^T S = I$

$$I - \frac{W^T S S^T W}{\|S\|^2}$$

Minimize

$$F(W) = \frac{1}{2} \|T - W^T S\|_2^2$$

SUBJECT

$$W = (TS)^T$$

$$T = [T_1 \dots T_n]$$


$$S = [S_1 \dots S_n]$$

$$F(W) = \frac{1}{2} \sum_{k=1}^n |T_k - W^T S_k|_2^2$$

LHS

Subject :

Year . Month . Date . ()



تجزیه مقدار منفرد Singular Value Decomposition

ماتریس $S: n \times L$ را می توان به صورت زیر تجزیه نمود:

$$S = \sum_{i=1}^r \sqrt{\lambda_i} P_i Q_i^T$$

که $\{P_i\}$ و $\{Q_i\}$ ماتریس های یکتا و متعامد برداری ویژه مقادیر λ_i در ماتریس $S^T S$ و $S S^T$ هستند. در اینجا مقادیر ویژه از بزرگترین به کوچکترین مرتب شده اند. λ_i ها شده نشان داده اند.

$$S^+ = \sum_{i=1}^r \frac{1}{\sqrt{\lambda_i}} Q_i P_i^T$$

رتبه ماتریس S را $rank(S)$ می گویند.

= تعداد سطوح مستقل S

= " " مقدار ویژه غیر صفر $S^T S$

(چون مقدار ویژه λ_i مثبت است پس تجزیه مقدار منفرد یکتا است)

- روش 1: شیب های عمود بر یکدیگر (در مسطح دستمال نری B دستمال کی)
- روش 2: " " " " (" " " ")

لاسط کاور و اجزای تغییر یافته ها اینها از بردارهای
 کوانتوم کوانتومها: جمله اول از زمان ای از کوانتومی آنها
 ذخیره کوانتومها
 نشان دادن قدم به قدم مراحل آموزش

مسئله شبکه متداصل خطی برای ردیابی نویزی

در خلاصه مسمی خطی از شبکه متداصل خطی با بترخ دقت با پنج بیک ورودی دارای نویز را
 در این حال شبکه بردار $Z_i = S_i + n_i$ را به برداری حوضه تردیدیک در بردار T نوشتگو

نظری: نیز دارای سینگلیس σ مولفهای غیر وابسته را بخلاف معادله در مقدار دیگر در مقدار دیگر می باشد

در تداصل نشان داده که با این $V_i = (TS^+)^T$ خط عبارت خواهد بود از:

$$F(w) = \underbrace{\sum_{i=1}^L |Tq_i|^2}_{\text{رابطه وابستگی خطی}} + \underbrace{\sum_{i=1}^L \frac{L\sigma^2}{\lambda_i} |Tq_i|^2}_{\text{رابطه وجه نویز}}$$

برای حداقل کردن $F(w)$ راه مختلف معادله بردار w را به صورت S تغییر دهم به این دلیل

$$V_i = (T \tilde{S}^+)^T$$

$$\tilde{S}^+ = \sum_{i=1}^L \frac{1}{\sqrt{\lambda_i}} q_i p_i^T \quad (S \text{ مقدار بزرگتر معادله بردار و نه داشته باشد})$$

$$S \leq L, \quad S \text{ طوری انتخاب می شود که } \frac{L\sigma^2}{\lambda_S} \leq 1 \leq \frac{L\sigma^2}{\lambda_{S+1}}$$

لاستیکه $F(w)$ را به این معادله از S درم رابطه F به S اول مشتق می شود را بکار

$$F(w) \text{ را به مشتق می شود}$$

پس، حذف مجدد از گزینه مقدار منفی S^+ در معادله شکر در مقابل نوزاد پس می آید

ارشد خفیه است $\gamma_1 = (SS^+)^T$ و $F(W) = L\sigma^2 \gamma$
در برای $\gamma_1 = (SS^+)^T$

$F(W) = L\sigma^2 s + \sum_{i=S+1}^n \gamma_i$

بارگیری γ_1 با تابع ویدو

نمی از تابع ویدو برای $\gamma_1 = (TS^+)^T$ صورت بارگیری این کاره
استند از تقیه Greille میراث

$$\gamma_1^{NEW} = \gamma_1^{OLD} + \alpha S_k (T_k - (W^{OLD})^T S_k)^T$$

$$\gamma_{1i}^{NEW} = W_{1i}^{OLD} + \alpha (t_{ki} - (W_{1i}^{OLD})^T S_k) S_k$$

این تابع برای آموزش سیستم یادگیری درون خطی در یک شبکه عصبی است
معمولاً در بارگیری
در یک نقطه $\theta \neq 0$ معادله پس می آید

رفتار دین میکی شکر دی و لایه شکر

$$\frac{dy_i}{dt} = -g(y_i) + I_i$$

$$I_i = \sum_{j=0}^{n_i} w_{ij} x_j \quad i = 1, 2, \dots, m$$

این فرآیند به گونه‌ای طراحی شده است که...

در این فرآیند، داده‌ها به صورت...

این فرآیند به گونه‌ای طراحی شده است که...

این فرآیند به گونه‌ای طراحی شده است که...

این فرآیند به گونه‌ای طراحی شده است که...

این فرآیند به گونه‌ای طراحی شده است که...

این فرآیند به گونه‌ای طراحی شده است که...

Recurrent Associative Networks

این فرآیند به گونه‌ای طراحی شده است که...

$$I_i = \sum_{k=1}^{K_i} \sum_{k=1}^{K_2} w_{ik} X_k$$

این فرآیند به گونه‌ای طراحی شده است که...

$$g(R_i) = I_i \quad R_i = \theta^{-1}(I_i) = f(I_i)$$


این فرآیند به گونه‌ای طراحی شده است که...

Subject:


Year: Month: Date: ()

عقل و شکر و تسلیم به اراده و استقامت و پایداری و استمرار و تداوم و استمرار در آن بر عقده
که فریبگنده (حالات ناایمن) در هر نقطه دگرگانه از فضای آن بعدی قرار داده شده اند. نیروی
جاذبه هر کوه تنها به بقای آن در دایره آن کوه از سایر کوه در تدریج هستند

کارشما در این ترتیب شمع می شود که حجم از فضای در آن فضای متوالی شده. حجم حرکت در آمده
بزرگترین که جاذبه خواهد بود



جغرافیای شکر و تسلیم به اراده و استقامت و پایداری و استمرار و تداوم و استمرار در آن بر عقده



$f(x) = x$

تدریس و تفکر و استقامت

پایداری و تداوم و استمرار

بعضی تحقیقات اتصالات خود ارادگی را حذف کرده اند


(یعنی حرکتی از دست داده و بی برکت)

* پاسخ این شکر در روی (به خصوص در روی) که در دست آموزش به فعالیت به کار گرفته شده اند
مکلف است به یاد بزرگ شده از نیروی پاسخ شکر بر کوهی که در کوه

شکر (BSB) Brain-State-in-a-Box

سال ۱۹۷۷ توسط جیمز ازمنش نوشته

بر روی یک صفحه
یک ترمون



نتیج فعالیت و تعداد آنها متغیر
در داخل یک ارجح که محدود را اختیار می کنند

اگر n بردار $y = (y_1, y_2, \dots, y_n)^T \in \mathbb{R}^n$ را در نظر بگیریم، آنگاه $\|y\|_1 = \sum_{i=1}^n |y_i|$ را می‌توانیم به صورت زیر تعریف کنیم:

اصولاً در این روش n متغیر داریم:

حالت ۱: اگر y_i مثبت باشد، آنگاه $|y_i| = y_i$ و در این صورت $\|y\|_1 = \sum_{i=1}^n y_i$ خواهد بود. این حالت معمولاً در مدل‌های خطی استفاده می‌شود. حالت ۲: اگر y_i منفی باشد، آنگاه $|y_i| = -y_i$ و در این صورت $\|y\|_1 = \sum_{i=1}^n -y_i$ خواهد بود. این حالت معمولاً در مدل‌های لاسو استفاده می‌شود.

الگوریتم L_1 (Lasso)

برای درازنای مقدار α بسیار کوچک اختیار می‌کنیم. برای نزدیکی به $\alpha = 0$ در ستادری اختیار می‌کنیم.

۱- برای α بسیار کوچک، S تقریباً ۲ الی ۳ متغیر می‌گردد.

- ۲- مقدار α را به قدری کوچک می‌کنیم که S در نظر می‌گیریم $y_i = S_i$
- ۳- تا زمانی که α را به قدری کوچک می‌کنیم که S را در نظر می‌گیریم $y_i = S_i$
- ۴- α را به قدری کوچک می‌کنیم که S را در نظر می‌گیریم $y_i = S_i$

$$I_i = y_i + \alpha \sum_{j \neq i} w_{ij} y_j$$

$$y_i = \begin{cases} 1 & I_i > 1 \\ y_i & -1 \leq I_i \leq 1 \\ -1 & I_i < -1 \end{cases}$$

۶- در نظر گرفتن α در این روش

$$y_{i,j}^{NEW} = w_{ij} y_j^{OLD} + \beta y_i y_j$$

توضیح: در این روش، در هر دوره، هر شرکت به نوبت در بازار عرضه می‌گردد و قیمت‌ها را تعیین می‌کند.

\underline{x} stable \underline{y} stable
 - \underline{x} stable \underline{y} stable
 - \underline{x} stable \underline{y} stable
 - \underline{x} stable \underline{y} stable

تجزیه و تحلیل روش SSBS در هر دوره، هر شرکت به نوبت در بازار عرضه می‌گردد.


$w_{new} = w_{old} + \eta (y_{desired} - y_{actual})$

این روش، در هر دوره، هر شرکت به نوبت در بازار عرضه می‌گردد و قیمت‌ها را تعیین می‌کند.

۱۸/۵۰

شماره ردیف

روش عرضه نوبتی (SSBS) در هر دوره، هر شرکت به نوبت در بازار عرضه می‌گردد.



W
 روش عرضه نوبتی
 این روش، در هر دوره، هر شرکت به نوبت در بازار عرضه می‌گردد.
 $W_{ji} = W_{ij}$

پس از ارائه نمونه اولیه شبکه، نمونه‌ای معقد دیگری نیز معرفی شدند.
 در شبکه گسترده حافظه، حالات شبکه در حالات اولیه (مقداری هستند
 (مثلاً بیزی اده - ۵ - ۳۱ قطب ۱-۱ -)

در شبکه حافظه موسسه، تطبیق فعالیت واحدهای تولیدی و تقارن بزرگ در معادله حالت
 اده را اختیار کردند.

این سیستم در دو روش واحد معکوس است بطور همزمان (Synchronous) یا نهمزمان (Asynchronous) باشد.

در حالت نهمزمان واحد در صورت اتفاق در یک لحظه اتفاق می‌افتد.
 در این شبکه نیز انتقال بزرگشتی تنها یک ردیف از خروجی هر واحد و یک ردیف از ورودی است
 تا محکومی شبکه بضرورت نیاز به مدار اولیخ این سیستم سازی از این برون. معادله دست‌نزدکی
 واحد معکوس است ۵ یا غیر ۵ باشد.

از این برای مقایسه عمومی این سیستم سازی همزمان است تقارن حالات (مقطبی و معادله دست‌نزدکی ۵ برای واحد
 معمول تر و فاستر است.

$$y_i^{NEW} = \begin{cases} 1 \\ \text{OLD} \\ \delta_i \\ -1 \end{cases} \quad \begin{matrix} \sum_{j=1}^N v_{ij} y_j^{OLD} + x_i \\ \sim \\ \sim \end{matrix} \quad \begin{matrix} \theta_i \\ = \theta_i \\ < \theta_i \end{matrix}$$

۵ برای حالت بیزی

اگر واحد نایب در صفحه‌ای در زمان حالات بی خطا بود که با y_i مشخص خواهد شد.

اگر y_i در سمت مثبت از صفحه از طریق شده $y_i^{NEW} = 1$ و اگر در سمت منفی آن
 باشد $y_i^{NEW} = -1$ و اگر در وقت روی از صفحه باشد $y_i^{NEW} = y_i^{OLD}$ خطا بود در از صفحه
 از این در حالات با هم مقایسه می‌شود که در

Subject: _____

Year: _____ Month: _____ Date: _____

برای جلوگیری از این حالت می توان فرسخ γ را در صورت جزئی تغییر داد
در این حالت تابع تبدیل به صورت زیر خلاصه می شود:

$$y_i^{NEW} = \text{sgn} \left(\sum_j v_{ij} z_j^{OLD} - \theta_i + x_i \right)$$

$$y_i^{NEW} = U \left(\sim \right)$$

برای حالت مابینگی

Step

انرژی اثری Energy Landscape

همینکه در سال ۱۹۸۹ در نظر گرفتن تابع انرژی و تابع یاد پرور به صورت زیر است که
شماره به شرح اندک شده است. به حالت مابینگی می گویند
تابع یاد پرور تابعی است غیر افزایشی از حالات سیستم که از بین محدود است.

$$E = -\frac{1}{2} \sum_{i,j} \sum_{i \neq j} v_{ij} y_i y_j - \sum_i x_i y_i + \sum_i \theta_i y_i$$

وقتی شبکه تغییر حالت در دو (نقطه کیهانیت K) تغییر انرژی به صورت خلاصه می شود:

$$\Delta E = E_2 - E_1 = -\frac{1}{2} \sum_{i,j} \sum_{i \neq j} v_{ij} y_i^{NEW} y_j^{NEW} - \sum_i x_i y_i^{NEW} + \sum_i \theta_i y_i^{NEW} \\ + \frac{1}{2} \sum_{i,j} \sum_{i \neq j} v_{ij} y_i^{OLD} y_j^{OLD} + \sum_i x_i y_i^{OLD} - \sum_i \theta_i y_i^{OLD}$$

برای همه i ها $i \neq k$ داریم $y_i^{NEW} = y_i^{OLD}$

$$\Delta E = - \sum_{i \neq k} v_{kj} (y_k^{NEW} y_j^{NEW} - y_k^{OLD} y_j^{OLD}) - \sum_i x_i (y_i^{NEW} - y_i^{OLD}) \\ + \sum_i \theta_i (y_i^{NEW} - y_i^{OLD})$$

$$= \sum_{i=k} \varphi \neq 0 \quad i \neq k = \Delta y_k$$

Subject:

Year: _____ Month: _____ Date: _____

$$\Delta E = - \left[\sum_{j \neq k} w_{kj} y_j^{OLD} + x_k - \theta_k \right] \Delta y_k$$

(در حالت)

(1) اگر $y_k^{OLD} = 1$ و $y_k^{NEW} = -1$ و با توجه به اینکه تغییر در y_k داریم:

$$\sum_{j \neq k} w_{kj} y_j^{OLD} + x_k < \theta_k$$

و لذا در این [حالت] ΔE منفرجه است

$$\Delta y_k = -2 \quad \therefore \quad \Delta E < 0$$

(2) اگر $y_k^{OLD} = 1$ و $y_k^{NEW} = -1$ و $\Delta E < 0$ داریم:

(چون k در حالتی است که تغییر در y_k منفرجه است و در حالتی دیگر $\Delta E < 0$)

از طرفی چون $\Delta E < 0$ است، تغییر در y_k ارزش را کاهش می دهد تا حدی که $\Delta E = 0$ خواهد بود و لذا همیشه منفرجه است.

پس همیشه تغییرات E را کاهش می دهند. سوال: چگونه این اتفاق می افتد؟
 حدی دارد؟ یعنی این کاهش با خود جای می خورد؟

بر حالت s_k در شکر تنها طریق بسط کلی در تمام ارزش است شروع کار شکر از نقطه اولیه s_k به یک شکر در هر یک تعلق به تکرار محدود به یک حالت بالایی رسید اما حالت فکری الزاماً نزدیک به هیچ حالت به نقطه اولیه نیست

دو شرط: $v_i z_j = v_j z_i$ و $v_i z_i = \phi$ با هر دو در تعلق صحت شکر با هم برابری باشد.

اینجاست فرض از این شرط من تعلق به یک تکرار این شکر که

با دلیلی فرض

در زمانی شکر دفعه به هر ضریقی متمم شدن n اللودی D من خواهم در شکر دفعه شده حالات بالایی شکر که گذرد این تاریخ ارزشی جدیدی می شود $v_i z_j = v_j z_i$ $\sum_{i=1}^n$ جمله شکر برای ذخیره اللودی D قطعی است $S_k = [S_k(1), \dots, S_k(n), \dots]$ در زمانی $v_i z_i$ را صورت زیر اختیار می کنیم

$$v_i z_j = S_k(i) S_k(j)$$

با اینجاست ترتیب ارزشی حداقل می شود

چرخ در جهت پیدار $S_k(i) = S_k(j)$ و $S_k(i) = S_k(j)$ در S_k ها هم $v_i z_j = v_j z_i$ $\sum_{i=1}^n$ جمله شکر برابر $\sum_{i=1}^n$ جمله شکر

اگر به شکر i که اللودی S_k را ذخیره نموده اللودی جدیدی اعمال کنیم به کمتر از زمانی از شکر i که آن $v_i z_j$ منظر S_k متغیر باشد. شکر به حالت پیدار S_k خواهد رسید. اما اگر بیش از زلف بر گرفته $\sum_{i=1}^n$ متغیر باشد، شکر از اللودی جدید S_k به حالت S_k - برابر خواهد شد. حالت S_k - به حالت عکس (Reversal State) می گویند.

برای ذخیره چند الگوی در فضای (L الگو)

$$y_{ij} = \sum_{k=1}^L S_k(i) S_k(j) \quad y_{ij} = 0 \quad i \neq j$$

گاهی یک ضربه یا نیز در مثال مجموع تقارن دهند. این کار در شرایط یاداری را بهبود می بخشد. قانون یادگیری فوق قانون هب تقسیم شده نبوده شده است.

در الگو با بزرگی بزرگ قانون هب تقسیم شده است.

$$y_{ij} = \sum_{k=1}^L (2S_k(i) - 1)(2S_k(j) - 1) \quad i \neq j$$

S_k	Retrieval States	حالت یاداری
$-S_k$	Reversed States	حالت معکوس
S_i^{Mix}	Mixture States	حالت مخلوط

ترکیب خطی بر نقطه نقاط حالات یاداری همیشه

$$S_j^{Mix} = \text{sgn}(\pm S_k(i) \pm S_e(i) \pm S_m(i)) \quad (\text{در این ۴ تا})$$

Spin Glass حالت

بسیار حالت بیخ ارتباطی دارند

حالت معکوس مخلوط را حالت اصلی یا نیز می نامند. (Spurious States)
 میسک جاذبه بر همین دارند

اصلاح حالت معکوس: به ترتیب که توانند جواب دهند یا بیخ در ۱- در صورت ضرورت

Subject: _____

Year: _____ Month: _____ Date: _____ ()

روش درایگاه کش، حقوق حالت بدوی پیشنهاد شده است.

الگوریتم شبکه گسترده (پیدا)

۱: هزینه های شبکه را از قاعده $\sum_{i=1}^n x_i$ به دست می آوریم
۲: برای هر حلقه در جدول \times قوت های 2 تا $\frac{n}{2}$ را انجام می دهیم.

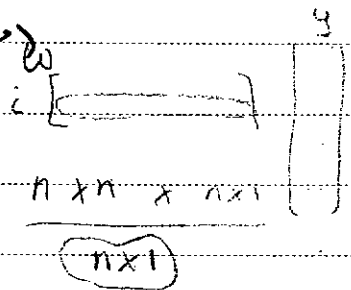
۳: مقدار در اولی حالت برابر از بدوی جدول \times قاعده $\sum_{i=1}^n x_i$ می دهیم
 $y_i = x_i$
 $i=1 \dots n$

۴: جدولی که $\frac{n}{2}$ تا $\frac{n}{2}$ به حالت شبکه می آید از جدولی 4 از 8 را انجام می دهیم:

۵: جدولی 5 از 7 را به هر واحد انجام می دهیم.

(طرح در صورت آشنایی استی بسازید)

۶: خروجی هر واحد به جدولی $\sum_{j=1}^n y_j$ می دهیم
 $I_i = X_i + \sum_{j=1}^n y_j$



۷: $I_i > \theta_i$?
 $I_i = \theta_i$
 $I_i < \theta_i$
NEW $y_i = \begin{cases} 1 & I_i > \theta_i \\ y_i^{OLD} & I_i = \theta_i \\ -1 & I_i < \theta_i \end{cases}$

۸: جدولی جدید $\sum_{j=1}^n y_j$ را به هر واحد به جدولی ارسال می کنیم

۹: از جدولی جدید

ظرفیت شبکه اینه کسسته :

با روش دی منتف سعی در تخمین ظرفیت این شبکه شده است.

ظرفیت شبکه اینه کسسته خطای قابل قبول به مقدار 0.01 و تعداد الگوریتم که می توانیم ذخیره کنیم (L) وابسته است. افزایش L احتمال خطای بزرگ را افزایش می دهد. اگر بخواهیم برای

خطای کمتر قابل قبول شبکه اینه کسسته می توانیم حد اکثر به مقدار 0.01 الگوریتم که می توانیم ذخیره کنیم را مشخص کنیم. خطای کمتر قابل قبول به مقدار 0.01 به مقدار 0.01 الگوریتم که می توانیم ذخیره کنیم را مشخص کنیم. خطای کمتر قابل قبول به مقدار 0.01 به مقدار 0.01 الگوریتم که می توانیم ذخیره کنیم را مشخص کنیم.

برای خطای کمتر از 0.01 $L \leq 0.15 n$
 " " " " 0.5 " " " $L \leq 0.37 n$
 " " " " 10 " " " $L \leq 0.61 n$

در حالتی که برای شبکه اینه کسسته n بیت را به دست آوریم از بهر صورت صحیح بزرگتر می کنیم. یعنی داشته باشیم $L \leq \frac{n}{2 \log e^n}$

در برای اینه کسسته الگوریتم بطور کامل بزرگتر شود $L \leq \frac{n}{4 \log e^n}$

$n = 100$	$L \leq 0.15 n$	$\rightarrow 15$
	$\frac{n}{2 \log e^n}$	$\rightarrow 11$
	$\frac{n}{4 \log e^n}$	$\rightarrow 5$

پاره 4 شبکه قدرتمندتر می شود

پاره 4 شبکه ها فیلتر کنند از الگوریتم قدرتمندتر است تا دهند که هر یک از آن در بسته

Subject:

Year: Month: Date: ()

تقدیر کو کھن گرا سرت

اگر n شے ہوں تو n حصوں پر تقسیم کر کے y_i کے ساتھ a_i کے ساتھ

$$a_i(y_i) \left[b_i(y_i) - \sum_{j=1}^n w_{ij} f_j(y_j) \right] = \frac{dy_i}{dt} \neq 0$$

دقیقہ طور پر

1- اگر $w_{ij} = w_{ji}$ اور $w_{ij} \geq 0$

2- $a_i(u)$ اگر $u > 0$ پرستہ باشد اور $u < 0$ پرستہ

3- $b_i(u)$ اگر $u > 0$ پرستہ باشد اور $u < 0$ پرستہ

4- $f_j(u)$ مشتق پرستہ اور $u > 0$ پرستہ $f_j(u) > 0$

5- اگر $b_i(u) - w_{ij} f_j(u) < 0$ پرستہ

6- $b_i(u) \rightarrow \infty$ اور $u \rightarrow 0^+$ پرستہ

(اگر $u \rightarrow 0^+$ پرستہ $\int_0^u \frac{ds}{q_i(s)} \rightarrow \infty$)

۱۰- اگر حالات n درجوں n درجوں پرستہ n درجوں پرستہ

۱۱- اگر حالات n درجوں n درجوں پرستہ n درجوں پرستہ

۱۲- اگر حالات n درجوں n درجوں پرستہ n درجوں پرستہ

Subject:

Year. Month. Date. ()

مدل کوهن گروسبرگ و اسپید عمومی برای شبکه‌های هورز در این مقاله بیان شده است.
توضیح زیر نیز دارای شرایط صحت فوق‌العاده است.

$$y_i = -A_i y_i + (B_i - C_i y_i) [I_i + f_i(y_i)] -$$


$$(D_i y_i + E_i) \left[J_i + \sum w_{ji} y_j \right]$$

$$y_i = G_i y_i (1 - \sum H_{ij} y_j)$$

شبکه‌های حافظه‌های دوطرفه (Bidirectional Associative Memory) (BAM)
حافظه‌های دوطرفه

در سال ۱۹۸۸ و ۱۹۹۲ توسط کوهن گروسبرگ و اسپید پیشنهاد شد. نسخه دیگری توسط

(چون این شبکه از این لحاظ بر حافظه‌ها است)



از شبکه حافظه‌های دوطرفه از هر دو جهت انتظار داریم که با داده‌ها
در این شبکه از هر دو جهت انتظار داریم که با داده‌ها

این شبکه حافظه‌های دوطرفه از هر دو جهت انتظار داریم که با داده‌ها

شماره پنج ستون است از طرف ورودی به هم از آن طرف خروجی داریم
 $(X \rightarrow Y)$
 $(Y \rightarrow X)$

ایم عمل به آنگ شمارم طرف نیز می نوشت

در حالی که X دبه ۶ ۷ ۶ و ۷ به ۱۱ باشد در حالی که Y دبه ۱۱ ۶ و ۷ باشد

نمودی با بیزی در فضای دیجیتال

Discrete BAM

منطق طرفی

بیزی در فضای دیجیتال

(S_i, T_i) $i = 1 \dots L$ آموزش ورودی آموزش

$$Y_{ij} = \sum_{k=1}^L S_k(i) T_k(j)$$

برای فضای

$$Y_{ij} = \sum_{k=1}^L (2S_k(i) - 1)(2T_k(j) - 1)$$

برای حالت بیزی

تولید حالت واحد

$$X_i^{NEW} = \begin{cases} 1 & I_i > \theta_i \\ X_i^{OLD} & I_i = \theta_i \\ -1 & I_i < \theta_i \end{cases}$$

$$Y_j^{NEW} = \begin{cases} 1 & \\ = & \\ -1 & < \end{cases}$$

در حالت بیزی $\theta = \text{خط صاف}$

مقدمه: در اینجا ما می‌خواهیم رابطه بین دو متغیر را بررسی کنیم.

الف) فرض کنید که X و Y دو متغیر تصادفی باشند.

ب) فرض کنید که X و Y دو متغیر تصادفی باشند.

ج) فرض کنید که X و Y دو متغیر تصادفی باشند.

د) فرض کنید که X و Y دو متغیر تصادفی باشند.

ه) فرض کنید که X و Y دو متغیر تصادفی باشند.

و) فرض کنید که X و Y دو متغیر تصادفی باشند.

ز) فرض کنید که X و Y دو متغیر تصادفی باشند.

ح) فرض کنید که X و Y دو متغیر تصادفی باشند. $I_j = \sum_{i=1}^n v_i x_j y_j$ $R_j = f(I_j)$ $X_j = f(I_j)$

ط) فرض کنید که X و Y دو متغیر تصادفی باشند. $I_j = \sum_{i=1}^n w_i y_j$ $X_j = f(I_j)$

ی) فرض کنید که X و Y دو متغیر تصادفی باشند.

ک) فرض کنید که X و Y دو متغیر تصادفی باشند.

ل) فرض کنید که X و Y دو متغیر تصادفی باشند.

م) فرض کنید که X و Y دو متغیر تصادفی باشند.

Continuous BAM

شبکه بستر R طبقه پیوسته

در این صورت پیوسته در تمام به خروجی (تبدیل در نامیده [1, 0]) ثابت می آید
 تمام واحدها در این شبکه از تابع سگونی و همبستگی استفاده کرده و دارای $0 < \theta < 1$ پیوسته

$$F(I_i) = \frac{1}{1 + e^{-I_i}}$$
 سگونی و همبستگی

نمودار دیدی زیر موضوع است

$$X_i = -a_i x_i + \sum_{j=1}^m v_{ji} f(y_j) + s_i \quad \begin{matrix} i=1 \dots N \\ a_i, s_i > 0 \end{matrix}$$

توان حکم بر جهت را این شبکه

$$y_j = -c_j y_j + \sum_{i=1}^n v_{ji} f(x_i) + t_j \quad \begin{matrix} j=1 \dots m \\ c_j, t_j > 0 \end{matrix}$$

۳۵

۱) ضربه کارنگ: شبیه ستادی فوق از هر جهت اولیه که شروع به کار کند به حالت پایداری همگرا می شود.

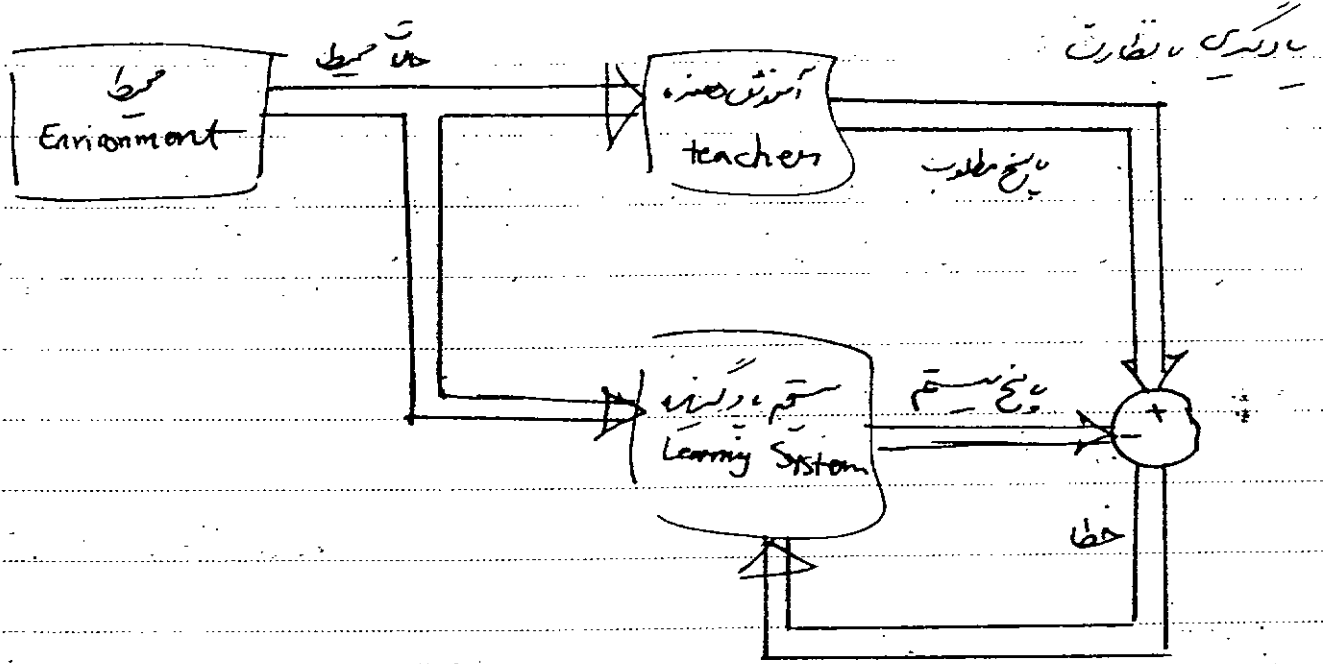
اثبات: به استفاد از قضیه کوخنج - گلاسرگ

۴- در هر یک از دیدی

1. دید دیدی با نظارت (Supervised Learning)
2. " " " " " " " " (Unsupervised Learning)
3. " " " " " " " " (Reinforcement Learning)
- Graded Learning

Subject:


Year. Month. Date. ()



نقد این مدل و اجزای آن است. اجزای عبارتند از: پاسخ مطلب، پاسخ نسقم، خطا، سیستم یادگیرنده، و محیط.

این آموزش می‌تواند با ارائه مجموعه‌ای از روش‌های یادگیری و پاسخ مطلب به سیستم انجام شود.

این نوع یادگیری را یادگیری با معلم (Learning with a teacher) می‌گویند.



یادگیری بی نظارت
برای نمونه گفته می‌شود که برای هر حالت خروجی جدید داشته
درد خروجی صحیح هستند، خطا

شبه فرگشتی، یادگیری، الگوریتم، و غیره. این روش‌ها در یادگیری عمیق و در شبکه‌های عصبی مصنوعی استفاده می‌شوند.

غیر از آنکه این روش‌ها در یادگیری عمیق استفاده می‌شوند.

۱- آشنایی: یک فرضی پوسته می تواند به نیت رده که الگوی ورودی چهار آشنایی باشد. یک الگوی نمونه
و توسط الگوهای دیگر، گنجشک شده که در آن است.

۲- تحلیل مؤلفه اصلی : Principal Component Analysis PCA

گسترش سرده اول - چند رده، منجر به این در یک مجموعه کوچک به چند مؤلفه اصلی می شود. در
انتقال آن مورد، شباهت به نمونه ای دیده شد، سنجیده می شود.

۳- خوشه بندی Clustering

از یک مجموعه از فرضی داشته باشیم که در عرض آن تنها یکی از آنها فعال باشد فرضی می تواند
مشخص کند. الگوی ورودی متعلق به کدام خوشه را دارد است.

۴- نمونه دهی Prototyping

شباهت بین نمونه ها مانند حالت قبل دست در می کشیم که رده ها در فرضی به جای ارائه شش خوشه الگوی
نمونه ای از خوشه را ارائه دهد. (شباهت الگوی نمونه ای)

۵- کدگذاری Encoding

فرضی ممکن است نمونه نگاشته، یکی از ورودی باشد که حتی الگوهای اطلاعات موجود در ورودی را
حفظ نموده، آن الگوها به یکدیگر است. عمل ممکن (کدگذاری) نیز میسر می باشد.

۶- نقشه بندی از ویژگی ها (Feature Mapping)

از واحدی فرضی یک نرم تر از نتایج خاصی داشته باشد در عرض آن تنها یک واحد فعال
باشد. شباهت الگوی ورودی را به یک نقطه خاص از فضای نگاشت می کند. در این حل مانده آن
است که الگوی نقشه بندی می کند.
الگوهای نقشه بندی می کند که پس از آن فعال می کند.



Subject:

Year. Month. Date. ()

PCA + Encoding
~ Clustering


کاربرد دیگر ترسیم نبرد است از مسئله فوق شکل شده شد

شماره دیگر در اینجا با این مدل بسیار در حدت (جمله کتبی)

یادگیری با ارزش

یادگیری با نظارت ، در این مسئله (برشماره انجام من شود) از تمام نمونه در این است. برای هر ورودی
یا خروجی را داریم ، یادگیری حداقل در کشتی بطور مناسب انجام خواهد شد.

یادگیری با ارزش در مسئله فوق قابل استفاده است



این نوع یادگیری ، یادگیری با ارزش نامند

Learning with a critic

نامیده شده است.

فرض کنید داده های ورودی ، آموزشی ، خروجی صحیح مشخص باشد ، به چگونگی آن بشماره این از هر حدت
برجسته یادگیری ، ارزشیابی شده ، به عملکرد آن است. زیرا فردا که داده من شود ، این نیز توسط
یک تابع (cost function) برآورد می شود.

شماره دیگر منتهی به این است ، یادگیری با ارزش را می توان به صورتی دیگر از شماره دیگر با نظارت مشاهده
اما کار به آنف در حدی که ارزش آن ، نظارت همه نیست بسیار کار است

۱. Self Organizing (feature) Topological Ordered Computational Maps (SOM)
 ۲. Self Organizing (feature) Topological Ordered Computational Maps (SOM)
 ۳. Self Organizing (feature) Topological Ordered Computational Maps (SOM)

۴. Self Organizing (feature) Topological Ordered Computational Maps (SOM)
 ۵. Self Organizing (feature) Topological Ordered Computational Maps (SOM)

۶. Self Organizing (feature) Topological Ordered Computational Maps (SOM)
 ۷. Self Organizing (feature) Topological Ordered Computational Maps (SOM)

۸. Self Organizing (feature) Topological Ordered Computational Maps (SOM)
 ۹. Self Organizing (feature) Topological Ordered Computational Maps (SOM)

۱۰. Self Organizing (feature) Topological Ordered Computational Maps (SOM)

Subject:

Year. Month. Date. ()

شبکه‌های رقابتی برای زنده ماندن

برای افزایش آنتروپی (یعنی کاهش دما) از این روش در شبکه‌ها استفاده می‌کنند.


حدود ۱۰

Hannet شبکه‌های رقابتی

در سال ۱۹۸۶ توسط لیپمن (Lippman) طراحی شد

می‌تواند به عنوان شبکه‌های رقابتی برای کارهای مختلف استفاده شود.

نزدیک به ۱۰۰



مقادیر

اصول عملی و مستعدی

در شبکه‌ها

تایم‌ها و دما - این عملیات

$$f(I_i) = \begin{cases} I_i & I_i > 0 \\ 0 & \text{otherwise} \end{cases}$$

لیپمن

تایم‌ها و دما

۰ < ε < ۱

Y_i(0) = X_i (مقادیر اولیه)

تایم‌ها و دما

$$v_{ij} = \begin{cases} 1 & i = j \\ -\epsilon & i \neq j \end{cases}$$

Subject:

Year. Month. Date ()

1- هزینه‌های شرکت خانگی برضای شده در مدت 2 از 4 سال گذشته

2- مقدار برضای در این سیستم در طی 4 سال

$$y_j^{NEW} = P \left[y_j^{OLD} - \epsilon \sum_{k=2}^4 y_k^{OLD} \right] \quad j = 1, 2, \dots, m$$

3- مقدار برضای در هر سال در این سیستم $y_j^{OLD} = y_j^{NEW}$

4- ارزش از یک واحد مقدار برضای غیر صفر دارد. ادوار به روش صورت خانگی


* برای نتایج در تعیین و پلا هاست. هر واحد می‌تواند وزن خودش (برای خود) داشته باشد
یعنی ضریب را تقویت می‌کند هر چه بیشتر ϵ - می‌تواند یعنی تعیین می‌کند

مثال (n): $m=4 \quad \lambda = [0.2 \quad 0.4 \quad 0.6 \quad 0.8]^T$
 $\epsilon = 0.2$

5- به تنگ الگوریتم، y را بر حسب λ حساب کنید.
 $y = (0.0 \quad 0.0 \quad 0.0 \quad 0.421)$

Mexican Hat Network


شبکه کلاه مکزیک



در سال 1989 توسط کوپمنس ارائه شد. برای ارزش‌های پایین در هر یک




محدود



در این شبکه هر واحد در زمانی
متوسط و طولی یک به یک می گذرد
و در هر یک از واحدهای این شبکه
می توان وقت رسیدن را تنظیم کرد

مثلاً y_{i-2} و y_{i-1}
و هر یک هم کار را واحد y_{i+3}
(در تمام R_1)



شعبه دیگری هم می تواند در تمام R_2
شعبه اتصال یعنی غیر از اینها دیگر
و واحد هر واحد متصل است (air feedback)

مثلاً اگر شعبه R_2 در تمام R_1 و R_2 در تمام R_1
و R_2 در تمام R_1 و R_2 در تمام R_1

اصولاً در شکل با تقوای هر واحد و ثابت واحد ثابت است
و بیشتر در هر یک از واحدهای این شبکه نسبت به سایر واحدهای این شبکه

در این اصوات طبقه بندی می شود و $R_1 < |K| < R_2$ و $R_1 < |K| < R_2$
مقررها باشد

نهایت هر واحد در این شبکه از لحاظ زمان در زمان t می رسد


$$y_i(t) = F \left[x_i(t) + \sum_{k=-R_2}^{R_2} y_{i+k}(t-1) \right]$$

Subject:

Year. Month. Date. ()

Why Mexican Hat?

there's a special function in Math which is called Mexican Hat. The characteristics of this network is to somehow like that function.



الگوی شبکه:
 1. مقدار ورودی با مقدار $R_1 - R_2 + \text{Max}$ و خروجی شبکه
 2. مقدار ورودی نقاط با مقدار R_1 و R_2 و خروجی شبکه
 3. مقدار خروجی بصورت زیر مشخص می شود:

$$V_{i+k,i} = \begin{cases} c_1 & |k| \leq R_1 & c_1 > 0 \\ c_2 & R_1 < |k| \leq R_2 & c_2 < 0 \end{cases}$$

این عملیات تبدیل خطی و مقیاس دهی در y^{OLD}

$$\underline{Y} = \underline{X} \quad y_i^{OLD} = X_i$$

مقدار $t = 0$


2- مقدار $t = \text{Max}$ و $t = 0$ و $t = 3$ از 7 لایه های شبکه

3- خروجی از یک خطی در لایه های شبکه

$$I_i = \sum_{k=R_1}^{R_2} V_{i+k,i} y_{i+k}^{OLD}$$

$$= \sum_{k=R_1}^{R_1} c_1 y_{i+k}^{OLD} + \sum_{k=R_1+1}^{R_2} c_2 y_{i+k}^{OLD} + \sum_{k=R_2}^{(R_2+1)} c_2 y_{i+k}^{OLD}$$

PAPCO



4- پنج نوبت زیر را اعمال می کنیم

$$y_i = \min \{ y_{Max}, \max(0, I_i) \}$$

$$y_i^{OLD} = y_i \quad i = 1 \dots N$$

5- جدول زیر را در نظر بگیرید

6- ارزش شمرده $t = t + 1$

7- آیا به شرط خاتمه: اگر $t < t_{Max}$ (لازمی در رسم) در غیر این صورت خاتمه

Hamming Network

شبکه همنگ

(d_j) فاصله همنگ: بین درگاه X و درگاه S_j در شبکه همنگ n درگاه β درگاه α به هم متناوب هستند

اگر X و S_j n همنگ باشند بین β درگاه $\alpha_j = n - d_j$ فاصله است

$$S_j \cdot X = \alpha_j - d_j \quad (1)$$


از رابطه بالا داریم: $d_j = n - \alpha_j$

$$\Rightarrow S_j \cdot X = 2\alpha_j - n \quad \alpha_j = \frac{1}{2} S_j \cdot X + \frac{1}{2} n$$

$$= \frac{1}{2} \sum_i S_{ij} X_i + \frac{1}{2} n$$


Subject:

Year. Month. Date. ()



نوعی از مدل بصورت زیر در نظر آید

اگر یکی که طرح می شده است. البته هم شبکه های دیگر در این زمینه هم در دسترس است. در دسترس می باشد.



بیشتر اینها هم در دسترس است. البته در دسترس است. در دسترس است. در دسترس است.

این نوعی از خروجی شبکه را در شبکه MaxNet متصل نموده، شبکه را در دسترس می گذاریم.

الگوریتم:

1- تعیین کردن n تعداد ورودی و m تعداد خروجی. در دسترس است. در دسترس است. در دسترس است.

$$(w_{ij} = \frac{1}{2} s_{ij})$$

1- برای هر ورودی x و خروجی a الگوریتم 4 را انجام می دهیم.

$$a_j = \frac{1}{2} + \sum w_{ij} x_i$$


2- خروجی خطی را می سنجیم.

3- مقادیر را در شبکه MaxNet می بینیم و مشخص می کنیم.

4- الگوریتم 4 را در MaxNet می بینیم. شبکه را در دسترس می گذاریم.

لازمه (شماره) در دسترس

رشته فایف در دسترس ۱۹۶۲ رتبه از آن. شبکه فایف در دسترس



Handwritten text in Persian script, likely a title or introductory sentence.

Handwritten text in Persian script, possibly a paragraph of text.

$$p \{ \text{...} \} = \frac{1}{m}$$

Handwritten text in Persian script, continuing the notes or explanation.

Handwritten text in Persian script, possibly a date or reference.

Handwritten text in Persian script, likely a conclusion or final note.

درون زاری بهر از مقدار فاصله هر فردی X تا فرضی I_i خود را می نویسد

$$I_i = D(X, Y_i)$$

فاصله

$$D(u, v) = |u - v| \quad \text{فاصله مطلق}$$


$$D(u, v) = 1 - \cos \theta \quad \theta = \angle u, v \quad D$$

- ۱. هر فرد برای نزدیک تر بودن به X و تا این که در گروه تعیین نزدیکترین I_i به X با خود صحبت می کند.
- ۲. هر فرد از سایر افراد I_j مربوط به این گروه تعیین کند و تصمیم بگیرد که در این گروه بماند یا به گروه دیگر برود.
- ۳. هر فرد ارتباط جدیدی با نظریه ریاضی پیدا می کند و نظریه جدید I_i را پیدا می کند.
- ۴. هر فرد به نزدیکترین نظریه I_j که فاصله آن با خود کمتر از I_i است نزدیک می شود.
- ۵. هر فرد به نزدیکترین نظریه I_j که فاصله آن با خود کمتر از I_i است نزدیک می شود.

این فرآیند به تدریج به تعادل می رسد و این فرآیند را می توان به صورت زیر نشان داد

$$Y_i^{NEW} = Y_i^{OLD} + \alpha (X - Y_i^{OLD}) \quad 0 < \alpha < 1$$

$$\begin{cases} Y_i^{NEW} = (1 - \alpha) Y_i^{OLD} + \alpha X & \text{در این گروه بماند} \\ Y_i^{NEW} = Y_i^{OLD} & \text{در این گروه نمی ماند} \end{cases}$$



(Radial Spreading) (Radial Spreading)
 P
 (Radial Spreading) (Radial Spreading)

...

...

...

...

...

...

...

...

...

...

...

...

...

...

...

...

Subject: _____
 Year. Month. Date. () _____

۱۳. اضافه کج نوز:

یک نوز دردی توزیع بی‌خطی در برهه‌های X اضافه می‌کنیم. تصور کنید در ابتدا در سید رومی باشد در برهه‌های X غالب بود. گذشت زمان از وقت نوز کاستن شده و آبروی از بین برده. این روشن نیز سیدر کند است.

۱۴. ی توفخ در یک کبک ایگر هر طور برده. همه برهه‌های در رخ سوجه با اصلاح کوه. بحدت دیگر آبروی جادونه برهه در سدی به درخش ای دسته‌ای از موهود D در یک ایگر موهود برده بسته آبروی کوه و آفت. ملاحظه می‌نمایید در ابتدا در کسوتش و شمع بکسیر نوز در بزرگ آفتی می‌کنیم تصور کنید هر موهود در یک ایگر موهود برده موهج شده و آبروت آبروتش شمع بکسیر راکه شش می‌صدم در بریدن آبروتش بکسیر آفتی شامک موهود برده باشد.

۱۵. روشن دستنو

برای شکر آیک و صلیخ در تقویم یکم. در این روش، بسته بده شخ و موهود مانده در رشته موهود می‌شود از λ رفته برده شده آنگاه یکی مدتی از صحنه نجات خارج می‌کنیم. این روش اگر اوقات بسیار خوب عمل می‌کند.

باید ساری کانتیم و صلیخ این از میان نجات و قیخ λ جا. نسبت زمان D ظاهر آبروی شعور صورت زیر می‌سب می‌شود.

$$f_i^{NEW} = f_i^{OLD} + \lambda (z_i - f_i^{OLD})$$

در مجموع جمله باین را در رابطه $p_i = \lambda (y_i - f_i^{NEW})$ و سب می‌کنیم که متوازن نوز

حال درخش ای موهود اصلاح می‌شود D در این کسوتین سوهود $p_i = \lambda (w_i x_i) D$ باشد.

Subject:

Year. Month. Date. ()

اللہ رب العالمین

۵. معادلات درجہ اولیٰ کے لیے Δ کا حساب لگائیں
یا درجہ اولیٰ کے لیے Δ کا حساب لگائیں
یا درجہ اولیٰ کے لیے Δ کا حساب لگائیں

۱. دو متوازی خطوط ایک دوسرے سے 2 میٹر کے فاصلے پر ہیں

2. ایک متوازی خطوط ایک دوسرے سے 3 میٹر کے فاصلے پر ہیں

3. ایک متوازی خطوط ایک دوسرے سے 4 میٹر کے فاصلے پر ہیں

$$D(x) = \sum (w_i x_i - x_i)^2$$

4. انڈین کے درجہ اولیٰ کے لیے $D(x)$ کا حساب لگائیں

$$w_{ij} = (1 - \alpha) w_{ij} + \alpha x_i$$

5. ایک متوازی خطوط ایک دوسرے سے $(1 - \alpha)$ کے فاصلے پر ہیں

6. ایک متوازی خطوط ایک دوسرے سے $(1 - \alpha)$ کے فاصلے پر ہیں

7. ایک متوازی خطوط ایک دوسرے سے $(1 - \alpha)$ کے فاصلے پر ہیں

8. ایک متوازی خطوط ایک دوسرے سے $(1 - \alpha)$ کے فاصلے پر ہیں

9. ایک متوازی خطوط ایک دوسرے سے $(1 - \alpha)$ کے فاصلے پر ہیں

Subject:

Year. Month. Date. ()

$$\sigma(n) = \sigma_0 e^{-\frac{n}{\tau}}$$

کاهش تدریجی اندازه سیالگی
شد iteration $n =$
در τ و σ_0 پارامترهای ثابت

$$\tau(n) = \tau_0 e^{-\frac{n}{\tau}}$$

تدریجاً در τ

$$W_j(n+1) = W_j(n) + \tau(n) \times h_{j,irreg}(n) \times (X - W_j(n))$$

این فرمول در سیستمی خطی از زمان به τ فاز تقسیم شده است.

(Ordering Phase) فاز خطی از موضعی به مرتبه تاریخ

در این فاز، در ابتدا مرتبه ها شروع می شود با درصد 1000. در هر مرحله الگوریتم با بیشتر لازم باشد.
انتی - پارامتر در این رابطه $\tau(n)$ را می توان به 0.1 شروع کرد و به 0.01 رسید.
همین 0.01 و 0.01 است. برای این کار $\tau_0 = 0.1$ ، $\tau = 1000$ است. انتخاب شده است.
اندازه کمترین در ابتدا بگونه ای انتخاب شود که همه واحدها در یک خط قرار گیرند و در یک
کاهش و بیشتر در میان فاز تاریخ و واحد از آن و در هر مرحله به 0.01 در یک تاریخ
بشود. لذا به 0.01 در 1000 تاریخ ما با $\frac{1000}{0.01}$ انتخاب کنیم.


فاز همگامی

این فاز برای تنظیم دقیق تر است. در هر مرحله الگوریتم در این فاز همگامی حدود 500 بار
تکرار و واحدی که در آن
در تمام طول فاز همگامی $\tau(n)$ را کوچک کنند و در 0.01 باشد.
همین در این فاز، تاریخ هر یک از واحدها به 0.01 در یک تاریخ
بشود. لذا به 0.01 در 1000 تاریخ ما با $\frac{1000}{0.01}$ انتخاب کنیم.

دېکارتی نظام میں دو متوازی خطوط کے درمیان سے گزرنے والے دو نقطوں کے درمیان کی فاصلے کی وضاحت کریں۔

دو متوازی خطوط کے درمیان سے گزرنے والے دو نقطوں کے درمیان کی فاصلے کی وضاحت کریں۔

دو متوازی خطوط کے درمیان سے گزرنے والے دو نقطوں کے درمیان کی فاصلے کی وضاحت کریں۔



دو متوازی خطوط کے درمیان سے گزرنے والے دو نقطوں کے درمیان کی فاصلے کی وضاحت کریں۔

دو متوازی خطوط کے درمیان سے گزرنے والے دو نقطوں کے درمیان کی فاصلے کی وضاحت کریں۔

دو متوازی خطوط کے درمیان سے گزرنے والے دو نقطوں کے درمیان کی فاصلے کی وضاحت کریں۔

Learning Vector Quantization Network (LVQ)

1	9/19	تعداد و مقدار س در سری
2	"	"
3	9/28	تعداد س در سری
4	"	"
5	"	تعداد س در سری
6	11/5	تعداد س در سری
7	"	"
8	"	"
9	"	"
10	11/10	تعداد س در سری

باز

تعداد س در سری $[s_1, \dots, s_n]$

- C_0 : دسته صحیح برای بردار S
- W_j : بردار وزنی واحد خصوصی Z_j
- C_j : دسته ارزش شده با واحد خصوصی Z_j

از $W_1 - W_5$: فاصله اندکی بین بردار S و بردار وزنی واحد خصوصی Z_j

5. بردار وزنی واحد در تشخیص کسب مقدار اولیه را در تشخیص کسب

1. در زمانیکه شرط خانه انتخاب است. قدرتی 2 از 6 را انجام می دهیم:

2- برای بردار درونی، حدش 5. قدرتی 3 از 4 را انجام می دهیم.

3- مقدار W_j را که برای آن $W_j - W_5$ حداقل است تشخیص می دهیم.

4- مقدار W_j را انجام می دهیم:

$$W_j^{NEW} = W_j^{OLD} + \alpha [s - W_j^{OLD}]$$

$$W_j^{NEW} = W_j^{OLD} - \alpha [s - W_j^{OLD}]$$

اگر $C_j = C_0$
 اگر $C_j \neq C_0$

- 5- تشخیص کسب را انجام می دهیم
- 6- شرط خانه انتخاب است

صحیح اویس و زلف اس قه قه تر سها و دردی بر تایی (شده) SOH ، و رش ای خوشه بندی مانه ارش
(K-Means) روش مانه در و با نتجا - m بر لار از به لار ای روش بر صورت تصادفی

نمودی دیگر الگوریتم LVQ

(۲. لار از روش بر و ردی)

نمرد LVQ2 : (صورت برداری شرایط بر ۳) به لار بر و با بر و اصلاح می گذرد

۱. بردار بر و به لار با بر و بر و در دسته کشف متعلق باشند

۲. لار در و در متعلق بر دسته به لار با بر و باشند

۳. فاصله بردار در و در و لار بر و در و لار با بر و تقریباً یکی باشند

این شرایط را می توان صورت زیر نیز بیان نمود:

اگر S به لار در و در و فعلی

w_c نزدیکین به لار در و S

w_r " " " " " " S - بعدی

d_c فاصله S تا w_c

d_r " " " " " " w_r

درشته باشیم $d_c < d_r$

$$\frac{d_c}{d_r} > 1 - \epsilon, \frac{d_r}{d_c} < 1 + \epsilon$$

نکته w_c و w_r اصلاح می گنند اگر شرایط فوق منطبق بر و در و باشند w_c و w_r و α با بر و در و در و متعلق

متعلق باشند S متعلق بر دسته w_r باشند اصلاح در و در و α صورت زیر خواهد بود:

$$\left. \begin{aligned} w_c(t+1) &= w_c(t) - \alpha(t) [S(t) - w_c(t)] \\ w_r(t+1) &= w_r(t) + \alpha(t) [S(t) - w_r(t)] \end{aligned} \right\}$$


حال نایز

نسخه 1 و 2 LVQ : تغییر شکل
 LVQ 3

گوانترادینج برداری سلسله مراتبی

عقد بر گوانترادینج برداری بواسطه نتیجه ای است که از تقویم اسامی و تاریخ شایخ حاصل شده است و آن اینست: D همیشه در تقویم با یک کوانج برداری به جای اسامی و تاریخ در آن قرار می گیرد.


اما گوانترادینج برداری، شکل حجم باری می باشد. بدور آن خصوصاً در جمله که کوانج D است برای هر بردار عضوی از آن که انتخاب شده و جمله دیگر خط حداقل باشد. سری کوانج نیز از آن می باشد. گوانترادینج برداری چند جمله ای پیشنهاد شده است که در آن با فید کوانج که جهت درست بطور قابل ملاحظه ای افزایش می یابد. از جمله ارزش های گوانترادینج برداری چند جمله ای، گوانترادینج برداری سلسله مراتبی می باشد. در این حالت مقدار برای گوانترادینج برداری $X = [\alpha_1, \alpha_2, \alpha_3, \alpha_4]^T$ در تقویم از آن گوانترادینج است. β در روی استفاده گو /



گوانترادینج برداری سلسله مراتبی

Multilayer Perception (MLP)

شبکه پرسپکتیو چند لایه



مختاری :

اتصالات کامل است.


قانون بک‌پراپگیشن (BP): انت از خط به عقب پس از انت از خط
 و قانون ردی تنظیم است.

قانون BP سه مرحله دارد.

- 1) اتصال درونی به شبکه را محاسبه خروجی و مقدار آن را برای آخر (انت از ورودی به سمت خروجی)
- 2) محاسبه خط در خروجی و خروجی دی لایه دی محلی (انت از خط به عقب)
- 3) بهنگام ردی و زنگ با استفاده از نتایج مرحله 2 تمام مقدار دلتا را محاسبه کنید (بهنگام ردی در لایه‌ها)

استخراج قانون BP

فرض کنید $\underline{S}_p = [s_{p1} \dots s_{pn}]^T$ که ورودی آموزش باشد و E_p تابع خطا برای این نمونه و $\underline{T}_p = [T_{p1} \dots T_{pn}]^T$ خروجی مطلوب برای ورودی \underline{S}_p باشد و $\underline{Y}_p^{(e)} = [Y_{p1}^{(e)} \dots Y_{pn}^{(e)}]^T$ خروجی شبکه باشد برای ورودی \underline{S}_p در لایه l باشد $\underline{W}_j^{(e)}$ وزن اتصال از لایه $l-1$ به لایه l در لایه l باشد.



$$E_p = \frac{1}{2} \sum_j (t_{pj} - o_{pj})^2$$

خطای شبکه برای ورودی \underline{S}_p

$$I_{pj}^{(e)} = \sum_k W_{kj}^{(e)} o_{pk}^{(e-1)}$$

مجموعه دلتا در لایه l

$$o_{pj}^{(e)} = F_j(I_{pj}^{(e)})$$

خروجی دلتا در لایه l

$$\frac{\partial E_p}{\partial W_{kj}^{(e)}} = \frac{\partial E_p}{\partial I_{pj}^{(e)}} \cdot \frac{\partial I_{pj}^{(e)}}{\partial W_{kj}^{(e)}}$$

$\frac{\partial E_p}{\partial I_{pj}^{(e)}} = -\delta_{pj}^{(e)}$

Subject: _____

Year: _____ Month: _____ Date: _____

$$\frac{\partial \Sigma_{pj}^{(e)}}{\partial w_{ij}^{(e)}} = \frac{\partial}{\partial w_{ij}^{(e)}} \left(\sum_k w_{kj}^{(e)} \mu_{pk}^{(e-1)} \right) = \sum_k \frac{\partial w_{kj}^{(e)}}{\partial w_{ij}^{(e)}} \mu_{pk}^{(e-1)}$$

$$= \delta_{pj}^{(e-1)}$$

$$\Rightarrow -\frac{\partial E_P}{\partial w_{ij}^{(e)}} = -\nabla_w E_P = \delta_{pj}^{(e)} \mu_{pi}^{(e-1)}$$

تغییر در BP نسبت به تغییر در وزن

$$w_{ij}^{New(e)} = w_{ij}^{Old(e)} + \eta \left(-\frac{\partial E_P}{\partial w_{ij}^{(e)}} \right)$$

$$= w_{ij}^{Old(e)} + \eta \left(\delta_{pj}^{(e)} \mu_{pi}^{(e-1)} \right) = BP \text{ تغییر}$$

$$\delta_{pj}^{(e)} = -\frac{\partial E_P}{\partial \Sigma_{pj}^{(e)}} = -\frac{\partial E_P}{\partial y_{pj}^{(e)}} \frac{\partial y_{pj}^{(e)}}{\partial \Sigma_{pj}^{(e)}} \rightarrow f'_j(\Sigma_{pj}^{(e)})$$

$$\frac{\partial E_P}{\partial y_{pj}^{(e)}} = -(t_{pj} - y_{pj}^{(e)})$$

$$\Rightarrow \delta_{pj}^{(e)} = (t_{pj} - y_{pj}^{(e)}) f'_j(\Sigma_{pj}^{(e)})$$

تغییر در BP نسبت به تغییر در خروجی

تغییر در BP نسبت به تغییر در ورودی

$$\frac{\partial E_P}{\partial y_{pj}^{(e)}} = \sum_k \frac{\partial E_P}{\partial \Sigma_{pk}^{(e+1)}} \frac{\partial \Sigma_{pk}^{(e+1)}}{\partial y_{pj}^{(e)}}$$

تغییر در BP نسبت به تغییر در ورودی

$$= \delta_{pk}^{(e+1)}$$

Subject :

Year. Month. Date. ()

$$= \sum (-\delta_{pk}^{(e+1)}) \frac{\partial}{\partial \theta_{pj}^{(e)}} \sum_c w_{ck}^{(e+1)} y_{pi}^{(e)}$$

$$= - \sum_k \delta_{pk}^{(e+1)} w_{jk}^{(e+1)}$$

$$\Rightarrow \delta_{pj}^{(e)} = F'(\sum_{pk} \theta_{pk}^{(e)}) \sum_k \delta_{pk}^{(e+1)} w_{jk}^{(e+1)}$$

برای لایه‌های مخفی

$$f(z) = \frac{1}{1 + e^{-kz}}$$

اگر f تابع سگمنت‌بندی باشد

$$f'(z) = k f(z) (1 - f(z))$$

$$f(z) = \frac{1}{1 + e^{-kz}} - 1$$

سگمنت‌بندی قطبی

$$f'(z) = \frac{k}{2} [1 + f(z)][1 - f(z)]$$

الگوریتم آموزش شبکه HPL

(مخفی)

1. مقدار اولیه وزن را برابر مقدار اولیه بایاس انتخاب می‌کنیم

2. شرط خاتمه خطا است. مقادیر 2 از 7 را انجام می‌دهیم

3. برای هر تابع برود آموزش (S_p, T_p) مقادیر 3 از 6 را انجام می‌دهیم

4. سه جعبه واحد از لایه مخفی اول تا لایه خروجی

$$\theta_{pj}^{(1)} = f_j \left(\sum_{i=0}^n w_{ij} \delta_{pi} \right)$$

$$\theta_{pj}^{(e)} = f_j \left(\sum_i w_{ij}^{(e)} \delta_{pi}^{(e-1)} \right)$$

4. هر δ_{pj} برای لایه مخفی

$$\delta_{pj} = (t_{pj} - \theta_{pj}) f'_j(\theta_{pj})$$

BPCCO

Subject:

Year: Month: Date: ()

5. برای بهسازی شبکه استفاده از $\delta_{pj}^{(e)}$ و $\delta_{pj}^{(e+1)}$ در $\delta_{pj}^{(e)}$ را به هم میزنیم

$$\delta_{pj}^{(e)} = \left(\sum_k \delta_{pk}^{(e+1)} w_{jk}^{(e+1)} \right) f_j'(I_{pj}^{(e)})$$

6. اصلاح درخت

$$y_{ij}^{NEW} = y_{ij}^{OLD} + \eta \delta_{pj}^{(e)} \theta_{pi}^{(e-1)}$$

7. آموزش شرط خاتمه

برای آموزش شبکه با این الگوریتم، مجموعه آموزش را به مقدار بیشتر اعمال کرده و اصلاح درخت صورت گیرد. برپایه اعمال مجموعه آموزش بیشتر تا آنکه در هر یک از epoch میمانند. آموزش این شبکه زبان بر است پس از آموزش شبکه برای استفاده از آن در دلال زیر استند می کنیم.

5. درخت مدار مقدار یادگرفته شد در آموزش تکامل داده شد.

1. مدار ورودی را اعمال و خروجی 2 و 3 را در می آوریم

2. ضرایب خروجی را به چگنی 1

$$\theta_i^{(1)} = f \left(\sum_{j=0}^n v_{ij}^{(1)} x_j \right)$$

3. می سبب خروجی را می سبب می آوریم

$$\theta_i^{(e)} = f \left(\sum_j v_{ij}^{(e)} \theta_j^{(e-1)} \right)$$

Subject: _____

Year _____ Month _____ Date _____

نی‌شبی از عملیات ششم
 شکرک، تاج خط، (از ترکی) می‌سازد و به هر ترکی از روش تری در وسطه کوه‌ساخت به دنبال
 حداقل کوه آتخ است. کوه تاج خط در فضایی در زمان سطح بر از سستی و ملبندی است
 (سطح خط به سطح از ترکی) اگر چه نیم پایداری در حد فعلی دی این سطح مملو می‌شود آن بسیاری
 از این حد فعلی در جمل رستند و با بعضی قسمت‌ها شکسته به دنبال آن است. شکرک، تاج خط
 در این از این کوه‌ها در تاج کوه می‌آید زیرا از هر طرف از جمله حد خط برتر می‌شود

جفت یک دسته بندی کننده:

۱۰۰ لغوی در هر لایه یک خط را می‌کشد. همچنین این نوعی از دسته بندی در فصلنامه می‌دهد ۱*

۱۰۱ لایه هر یک نامیه بندی را می‌دهد و می‌خواهد چنان بود ۱*

بر وجه یک در صنعت در وقت الگو در رسم می‌کنند با تریک جفتی در این ملاحظه در یک لایه بستی
 می‌توان فضای الگو را به طور سر در وقت تنظیم کرد. نقاطی می‌باشد در این حالت و نقاطی بودن
 خط هند بود. (تعداد دندان از تعداد اضلاع است در (ر صفحه ۷۱) از این بقعه ملاحظه در
 لایه اول بر لبه تواریش بقعه به دی نیز تشکیل شده می‌باشد. اگر چه لایه دیگر نیز از این نوع رسم
 ملاحظه می‌شود این لایه به نظر لایه قبل به نام تریک که در نقاطی بصورت تریکی می‌کشد
 لذا با داشتن حداقل ۶ لایه (۶ لایه حقیقی) می‌تواند صفحه را به هر شکل
 دایره یا جبهه بندی که (یعنی بر حسب اندازه سندی را می‌شود با آن حل کرد)

قدرت خط کج و قدرت تعمیم افق

قدرت خط کج: نقش شکرک در اینجا بصورت افق به عنوان یکی از روش‌ها

قدرت تعمیم افق: به عنوان یکی که در جفت است و این دو روش در افق یکی
 جدید

قدرت خط کج در مقابل قدرت تعمیم افق می‌باشد. سطوح است که این شکرک (یا با باشند
 ای در تقابل بین دو ویژگی در یک

Subject :

Year _____ Month _____ Date _____ ()

تویب خروج یا نجات ، بشکری جند لایه

تویب یک خروج ریاضی یا یک نجات - استفاده از لایه L (عمل نجات) یک لایه در خروجی مختلف (مندی) در مدار ساده میزبان . بشکری MLP بخوبی قادر به حل این مسائل می باشد در بشکری خصوصی نجاتی هدف پیاده سازی تویب یک نجات

$$F: A \subset \mathbb{R}^n \rightarrow \mathbb{R}^m$$

استفاده از لایه های نجات $(S_1, T_1), \dots, (S_2, T_2), \dots, (S_L, T_L)$ است که در آن $T_k = f(S_k)$ می باشد

صحت تویب یک یا یک لایه لایه در خروجی آموزش می بینیم
دستی که بر لایه آموزش x_k و بشکری اعمال شده میخونی خروجی لایه است

$$F_k(x_k, w) = |f(x_k) - y_k(x_k, w)|^2$$

برای N لایه لایه میخونی خط برد متوسط برابر است $F(w) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N F_k(x_k, w) \geq 0$

اینج عدد برای یک بشکری خاص ، آموزش از لایه لایه به مقدار خصوصی میگذرد
که لایه برای شخصی اینک از لایه میگذرد و آموزش میگذرد و بشکری آن است (در اینجا میخونی لایه لایه لایه)
لازم تر بشکری ، جایی که میخونی خط برد یک لایه لایه میگذرد

در اینجا نیز در آموزش بشکری خروجی $F(w)$ سطحی رفتاری در یک در نظر است (سطحی)
در آموزش بشکری بسبب اینکه سطحی $F(w)$ را می بینیم

Free

$$p | t(x)^2 dx$$
 (Handwritten notes and equations)

(Handwritten notes)

(Handwritten notes)

$$y_i = \sum_{j=1}^{2n+1} \theta_j(z_j)$$
 (Handwritten notes)

$$z_j = \sum_{k=1}^n \lambda^k \psi(x_j + k\pi) + \theta_j(z_j)$$
 (Handwritten notes)

۲- مقدماتی استیلا:

در این بخش به بررسی مقدماتی استیلا می‌پردازیم. استیلا به معنای تصرف غیرقانونی در ملک یا مال دیگران است. این تصرف می‌تواند به صورت فیزیکی یا حقوقی صورت گیرد. در حقوق ایران، استیلا به معنای تصرف غیرقانونی در ملک یا مال دیگران است. این تصرف می‌تواند به صورت فیزیکی یا حقوقی صورت گیرد.

۳- استیلا در حقوق:

استیلا در حقوق به معنای تصرف غیرقانونی در ملک یا مال دیگران است. این تصرف می‌تواند به صورت فیزیکی یا حقوقی صورت گیرد. در حقوق ایران، استیلا به معنای تصرف غیرقانونی در ملک یا مال دیگران است. این تصرف می‌تواند به صورت فیزیکی یا حقوقی صورت گیرد.

۴- نتیجه گیری:

در نتیجه، استیلا به معنای تصرف غیرقانونی در ملک یا مال دیگران است. این تصرف می‌تواند به صورت فیزیکی یا حقوقی صورت گیرد. در حقوق ایران، استیلا به معنای تصرف غیرقانونی در ملک یا مال دیگران است. این تصرف می‌تواند به صورت فیزیکی یا حقوقی صورت گیرد.

$$\begin{aligned}
 (1) \quad Y_{t+1} &= \beta \frac{Y_{t+1}}{Y_t} \\
 (2)
 \end{aligned}$$

Subject:

Year. Month. Date. ()

فرض کنه نقد دهن کی موجوده دشتیبا N_{tt} به شه
۵. خطای تابل تبول در دسته بندی الگودی آرنشیش

اگر شیکر طوی آرنشیش دانه شه D بملطاف نمونه دی آرنشیش بلای خطای E $\frac{1}{2}$ دشتیبا کی بکوه و بصله
نمونه دی آرنشیش بلای $L = \frac{N_{tt}}{E}$ باشد خطای دسته بندی الگودی آرنشیش از E کی ووز
شاه عدو کوه

شای: $N_{tt} = 80$ $6 = 10\%$ $4 =$ $L = 800$
شیکر بلای 800 نمونه آرنشیش دونه خطای نمونه دی آرنشیش بکوه 0.5 برابرا

آرنشیش کی دسته بندی کتده بکوهه آرنشیش

آرنشیش دسته بندی کتده \leftarrow بلای دی آرنشیش \leftarrow دونه خطا
 \leftarrow بلای دی عدو \leftarrow دونه خطا

۵- بکوهه دی آرنشیش - آرنشیش دونه آرنشیش

بکوهه دی لازم بری تریب تملیح بانفرد کی بکوهه دسته دی و در راه شکل می کتده

حداقل اندازه $?$ وقتی بکوهه بکوهه شعله تا تراسی ای کار بکوهه (debt way)

اگر دگر بری، دانه ا خفیر کم است، حل بر کتده بکوهه صدهی موفق کتده عدو!

اگر دانه دی موجوده زیار باشنه \leftarrow بکوهه آرنشیش بانفرد کتده دانه (1/2 دانه)

بکوهه آرنشیش: " " " " (1/3 دانه)

بکوهه آرنشیش 2 " " " " (2 دانه)

بکوهه آرنشیش 3 " " " " (3 دانه)


PAPCO

اگر داده‌های خطی زیرین باشد:
 ۱- نحوه آموزش را با بارهای مختلف در نمودار رسم کنید (با عنوان)
 جهت شباهت در آموزش دهیم؟

کوشش در ابتدا با بارهای سنگین در ابتدا به نفع است فرم عمیق‌تر است؛ با ادامه آموزش
 فرم عمیق‌تر می‌گردد و سعی در عمیق‌تر از داده‌های آغاز در ابتدا است
 و با بارهای در ابتدا کمتر خواهد شد؛ با عمل دیگر به نفع است، فرم عمیق‌تر
 بیشتر می‌گردد تا آنکه از داده‌های عمیق‌تر در ابتدا یکی به عمیق‌تر می‌گردد
 عمیق‌تر از نقطه و در ابتدا می‌باشد؛ آموزش با بارهای نقطه توقف شده است

بارهای Vs. تعلم

در سبک از سبک عمیق‌تر به صورت زیر است:



نتیجه اول: $\frac{1}{2}$: اگر آموزش دهیم ۵ خط دیگر با تلاش عمیق در آموزش، کاهش خطی داشته باشد

II. ۱. بارهای سنگین را با ۱-۵ نمونه آموزش دهیم. توقف آموزش در برابر توقف است که
 یعنی خطی که به نفع آموزش توجیه می‌شود.
 خط از یک نمونه ۵-۱۵ در آموزش با کاهش خطی، برابر با سبک می‌گردد.
 متوسط سطح خطی از ۱-۵ نمونه فقط با نفع می‌گردد.
 که خطی از سبک شباهت

۱-۵۰۰۰ leave One Out 1

Subject :

Year. Month. Date. ()

III. جدول داده از روی داده دی موجود

A. باای تغییرات تک در داده دی موجود

B. با از وضع توزیع داده دی موجود

(خروجی نتایج مات هم نشو مانند کلاس بر از آن جدول که ایم باشد هم از آن تغییر در هم)

نمودارهای مختلف الگو رسم

نقاط ضیق الگو رسم : ۱. انتخاب رسم الگو ای می
۲. یک به وضع یادگیری

رشد α برای رفع این مشکل پیشنهاد شده است که :

۱. رشد α مبتنی بر تغییر خود اصلاح در خط

الف) استناد از رسم
از α بزرگ باشد وزن شوری بیش می آید

از α بزرگ باشد α بزرگ خواهد بود

برای رفع مشکل به در خط از این می آید

$$\omega_{ij}^{(t+1)} = \omega_{ij}^{(t)} + \eta \sum p_j \sum p_i + \alpha [\sum \omega_{ij}^{(t)} - \sum \omega_{ij}^{(t-1)}]$$

یا ابرکار:

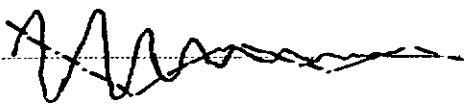
حرف با کلهوی بزرگی انجام می‌دهد و در همان پیوسته از روی چشم که خیلی زیاد می‌شود

بروت بزرگی از آنش می‌بارد

گلدنایخ نقطه‌مندی و نقطه‌فصلی است حرف با مشخصی کند حرکت در جهت گلدن

در نقطه‌فصلی است

لایحه و لایه‌های آموزشی حلقه‌ها با بقعه، علقه، و غیره در درازگی ایستاده



الگوریتم، بنفتم
 الگوریتم‌های

کلیت می‌سازد و نقطه‌مندی در حرکت	بسیاری از اینها در حرکت است
کلیت می‌سازد و نقطه‌مندی در حرکت	در آنجا چشم می‌بیند از درون
آنچه گفتند از آنش بر می‌آید و از حرکت	گفتی ز زبان زبانی است و از حرکت
طرح می‌دهد و از روی چشم در حرکت	طرح می‌دهد و از روی چشم در حرکت
در ظاهر خوب می‌نویسد و از حرکت	مکتوب می‌دهد و از سفاد بر می‌آید
در ظاهر خوب می‌نویسد و از حرکت	طرح می‌دهد و از روی چشم می‌آید
شیر خط و در چشم دست می‌آید و از حرکت	زینج می‌دهد است منفرود نم کرد
آنچه در آن و روی و غیره دست می‌آید و از حرکت	زینج خلق بر شکایت که از چشم در حرکت
حرف می‌سازد و از چشم در حرکت	گلدنایخ زینج از زینج که در حرکت
کلیت می‌سازد و از چشم در حرکت	در آنجا چشم می‌بیند از درون
کلیت می‌سازد و از چشم در حرکت	گلدنایخ زینج از زینج که در حرکت
آنچه گفتند از آنش بر می‌آید و از حرکت	گلدنایخ زینج از زینج که در حرکت
طرح می‌دهد و از روی چشم در حرکت	گلدنایخ زینج از زینج که در حرکت
زینج می‌سازد و از چشم در حرکت	زینج می‌سازد و از چشم در حرکت
زینج می‌سازد و از چشم در حرکت	زینج می‌سازد و از چشم در حرکت

نمودی مختلف الگو رسم 30

۱- ارزش دی بیتی بر چینه خود اصلاح درخت

از - استفاده از قسم

ب- اینم در اینم دستمک و زلف

ارزش } الگو الگو Pattern Made
 } دستار Batch Made

موتور و چنگلی ای در نه برای الگو ای در زور
دو طرفی به کار گرفته می شه

نسبت با آتری می ده $E_{ave} = \frac{1}{2L} \sum_{j=1}^L \sum_{i=1}^n e_{pj}^2$ (ژدلا - $e_{pj} = t_{pj}$)

ج- تعیین کتخ پیچ و درگی

ج-۱ درامدی و درگی ۱ بند انتخاب شده و درگی ۱ کاشی در هر طرفه در
توکل میگردان ۱ خنک و کله باشد. نسبت برای رده و در نه کتخ کم می شده

ج-۲ ارزش دتا و دتا ۱ بر وزخ پیچ پیچ و درگی مخصوص خود علامه ای نماد
با پیچ نیز تغییر کند

تا حد خوبی برای اصلاح ۱ در تغییرات وزخ چند قدم مثلا در کله کتخ باشد
تخ پیچ ای ارزش ۱ در دله ای بعضی شده
" کاشی ۱ در "

Handwritten text at the top of the page, possibly a title or subject name.

$$\left. \begin{aligned} \alpha_{JK}^{(t-1)} \\ \alpha_{JK}^{(t)} (1-x) \\ \alpha_{JK}^{(t-1)} + \lambda \end{aligned} \right\} = \alpha_{JK}^{(t)}$$

$\alpha_{JK}^{(t-1)}$
 $\alpha_{JK}^{(t-1)}$
 $\alpha_{JK}^{(t-1)}$

$$\Delta_{JK}^{(t)} = (1-\beta) \Delta_{JK}^{(t)} + \beta \Delta_{JK}^{(t-1)}$$

$$\Delta_{JK}^{(t)} = -s_{JK}^c = -s_{JK}^c \frac{\partial E}{\partial \Delta_{JK}^{(t)}}$$

$$\Delta_{JK}^{(t)} = -s_{JK}^c = -s_{JK}^c \frac{\partial E}{\partial \Delta_{JK}^{(t)}}$$

Handwritten text below the equations, possibly a derivation step or note.

$$w_{JK}^{(t)} = w_{JK}^{(t-1)} - \alpha \frac{\partial E}{\partial w_{JK}^{(t)}}$$

$$w_{JK}^{(t)} = w_{JK}^{(t-1)} + \alpha s_{JK}^{(t)}$$

Subject :

Year. Month. Date. ()

ج۔ روش دی جتنی ریختی ہے تاج فضا کی۔ ماحول

اگر تاج فضا کے متناظر ہوتے ہیں
یعنی $f(-x) = -f(x)$ (امتیاز)

تاج مختلف

تاج کی شکل کے مطابق - مکرر دیکھو [a, b]

$$f_1(x) = \frac{1}{1+e^{-ax}}$$

$$f_2(x) = (b-a) f_1(x) + a$$

$$f_2'(x) = \frac{a}{b-a} (f_2(x)-a)(b-f_2(x))$$

تاج کی شکل کے مطابق

تاج کی شکل کے مطابق α راہزن دیکھو فریڈن ہیکری ہاتھ دیکھو
تاج کی شکل کے مطابق
تاج کی شکل کے مطابق

$$f(x) = \frac{2}{\pi} \arctan x$$

تاج کی شکل کے مطابق

تاج کی شکل کے مطابق

تاج کی شکل کے مطابق

تاج کی شکل کے مطابق

۲- روش دی رینگر

این استفاده از الگوریتم دی رینگر
 مقادیر α و β ، الگوریتم BP در α بزرگ (در حدی که در هر حلقه ای
 از روش دی رینگر برای دی رینگر جدید استفاده شود.

با استفاده از عملیات ریاضی
 مقدار α و β و سپس α و β در هر حلقه ای مناسب برای در نظر گرفتن
 از تغییرات α و β در هر حلقه ای جدید ای دی رینگر شود.

در کارنامه این شکل
 - دی رینگر کلی است
 - تغییرات α و β در هر حلقه ای صورت می گیرد

۳- جری بندی الگو

تبدیل فضای برداری به فضای n بعدی با استفاده از قابلیت جری بندی الگو را افزایش دهد.
 فضای n بعدی X مجموعه X بردار x باشد n جمله X و X از آن

برای هر الگو $x \in X$ بردار جاری تبدیل جری به صورت زیر تعریف می کنیم. بردار



$$\varphi(x) = \begin{bmatrix} \varphi_1(x) \\ \vdots \\ \varphi_m(x) \end{bmatrix}$$

$\varphi(x)$ نقطه فضای n بعدی n بعدی n بعدی
 نگاشت می کند $\varphi(x)$ را به یک بردار n بعدی
 می نامند. دسته بندی $\{x^+, x^-\}$ از X را
 φ جدول زیر گرفته از الگو بردار n بعدی n


$$w^T \varphi(x) \geq 0 \quad x \in X^+ \quad \text{درجه داشته باشد علامت}$$

$$w^T \varphi(x) < 0 \quad x \in X^-$$

در این حال، اگر صفحه $\Phi = \gamma^T \Phi(x)$ به سطح جدا شده (جدایش) در فضای Φ خواهد بود.




$a \rightarrow \begin{pmatrix} a \\ 0 \end{pmatrix}$ $b \rightarrow \begin{pmatrix} b \\ 0 \end{pmatrix}$ $c \rightarrow \begin{pmatrix} c \\ 0 \end{pmatrix}$
 $d \rightarrow \begin{pmatrix} d \\ 2 \end{pmatrix}$ $e \rightarrow \begin{pmatrix} e \\ 2 \end{pmatrix}$ $f \rightarrow \begin{pmatrix} f \\ 2 \end{pmatrix}$



شکل دیگر: XOR

$\varphi_1(x) = e^{-\|x - c_1\|^2}$ $c_1 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$
 $\varphi_2(x) = e^{-\|x - c_2\|^2}$ $c_2 = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$

x	$\varphi_1(x)$	$\varphi_2(x)$
(1, 1)	1	0.135
(0, 0)	0.135	1
(0, 1)	0.368	0.368
(1, 0)	0.368	0.368




در این بعد، از آنجا که γ را تنظیم کنیم، این یک فضای جدا شده خواهد بود.
 حاصل کم

شبکه‌های توابع پایه شعاعی (RBF) (Radial Basis Function)

مختارگی:

شعاعی و درون محلی

تبدیل فضای ورودی به فضای لایه محلی، یک تبدیل غیر خطی است و در لایه خروجی تبدیل خطی می‌باشد.



در نقاط برجه از بیم مستقیم می‌باشد.

از آنجایی که لایه‌های محلی خروجی کارهای محلی انجام می‌دهند و فقط از این لایه‌ها لایه‌های RBF، رسوم به طرز جداگانه انجام شده‌اند.

آوردن شبکه: تعریف پلانهای توابع پایه شعاعی در وزنهای لایه خروجی

توابع پایه شعاعی را در سیستم‌های به صورت انفرادی در نقاطی که می‌خواهیم (در بسته) بزرگواران قرار می‌دهیم. نتایج این توابع به این صورت است:

$$G(\|x - c_i\|^2) = e^{-\frac{\eta}{D^2} \|x - c_i\|^2}$$

انتخاب خوب از داده‌ها

با کمترین خطا در شبکه، استفاده از توابع پایه شعاعی، استفاده از روش K نزدیکترین همسایه.

تعداد واحد درسی: ابتدا به تعداد واحد در نظر می‌گیریم و آنرا کاهش می‌دهیم
و ابتدا به یک واحد درسی می‌گیریم و سپس آنرا در واحد می‌دهیم

در این روش شکل تابع ϕ از طریق تابع ψ و از طریق انتگرال کردن و از طریق لایه خروجی ϕ است
روش عددی که در اینجا به کار می‌رود

و تقسیم از فرم تابع در درای تقاضای ψ به تابع ψ (Elliptically Sym)

به این معنی $(x_i - c_i)$ ، $\frac{x_i - c_i}{\beta_i}$ و تابع ψ را در هر یک از لایه‌های گشایی
در این کار، ما صدها نقطه در ψ داریم و ما صدها نقطه در ψ داریم و ما صدها نقطه در ψ داریم
تقریباً است!

در روش با نظارت

در این روش از نتایج یادگیری و یادگیری در شبکه‌های عصبی و نظارت
انتخاب می‌شود. برای این کار از روش تدریس در مقدار گزینش استفاده می‌شود.

$$e_j = d_j - F(x_j) = d_j - \sum_{i=1}^n w_i G(\|x_j - c_i\| D_i)$$

$$E = \frac{1}{2} \sum_{j=1}^L e_j^2$$

↓
حداقل کردن E
D

$$G(\|x_j - c_i\| D_i) = e^{-\frac{1}{2} (x_j - c_i)^T D_i^{-1} (x_j - c_i)}$$

$$= e^{-\frac{1}{2} (x_j - c_i)^T S_i^{-1} (x_j - c_i)}$$

$$(D_i^{-1} = \frac{1}{2} S_i^{-1})$$

Subject:

Year: Month: Date: ()

موضوع: w_i, c_i, s_i^{-1} ، اعدادی تعریف کنیم ϵ بسیار کوچک!

$$w_i(n+1) = w_i(n) - \eta_1 \frac{\partial \mathcal{E}(n)}{\partial w_i(n)} \quad i=1 \dots M$$

(۱) در فرمول η_1 بسیار کوچک

$$\frac{\partial \mathcal{E}(n)}{\partial w_i(n)} = \sum_{j=1}^L e_j(n) G(\|x_j - c_i(n)\|_{D_i})$$

RBF Δ ۱.۵

$$c_i(n+1) = c_i(n) - \eta_2 \frac{\partial \mathcal{E}(n)}{\partial c_i(n)}$$

$$\frac{\partial \mathcal{E}(n)}{\partial c_i(n)} = 2w_i(n) \sum_{j=1}^L e_j(n) G'(\|x_j - c_i(n)\|_{D_i}) s_{i,j}^{-1} (x_j - c_i(n))$$

(۲) تعریف

$$s_i^{-1}(n+1) = s_i^{-1}(n) - \eta_3 \frac{\partial \mathcal{E}(n)}{\partial s_i^{-1}(n)}$$

$$\frac{\partial \mathcal{E}(n)}{\partial s_i^{-1}(n)} = -w_i(n) \sum_{j=1}^L e_j(n) G'(\|x_j - c_i(n)\|_{D_i}) Q_{ji}(n)$$

where $Q_{ji}(n) = (x_j - c_i(n)) \cdot (x_j - c_i(n))^T$

موضوع: Δ تعریف

مجموعه داده ها

$$x_i \in \mathbb{R}^n \quad i=1, \dots, L$$

فضای ورودی n بعدی

$$d_i \in \mathbb{R} \quad i=1, \dots, L$$

d_i مقدار حقیقی

مقدار d_i در \mathbb{R}

$$F: \mathbb{R}^L \rightarrow \mathbb{R}^1$$

مجموعه خروجی

$$F(x_i) = d_i$$

روش RBF شامل انتخاب تابع F به صورت زیر است :

$$F(x_i) = \sum_{j=1}^L \omega_j \varphi(\|x_i - c_j\|) = \sum_{j=1}^L \omega_j \varphi_j$$

که نتایج $\left[\varphi(\|x_i - c_j\|) \right]_{j=1, \dots, L}$ به عنوان ماتریس Φ در نظر گرفته می شود. رابطه فوق را به صورت ماتریسی می توان نوشت :

$$\begin{bmatrix} \varphi_{11} & \varphi_{12} & \dots & \varphi_{1L} \\ \varphi_{21} & \varphi_{22} & \dots & \varphi_{2L} \\ \vdots & \vdots & \ddots & \vdots \\ \varphi_{L1} & \varphi_{L2} & \dots & \varphi_{LL} \end{bmatrix} \times \begin{bmatrix} \omega_1 \\ \omega_2 \\ \vdots \\ \omega_L \end{bmatrix} = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_L \end{bmatrix}$$

$\underline{\Phi} \quad \underline{\omega} \quad \underline{d}$

در صورت : $\underline{\Phi} \times \underline{\omega} = \underline{d}$

نتایج حاصل شده است که در صورت تعریف نقاط x_i و ω_i در Φ غیر متغیر و یکی دانسته می شود از تعریف Φ ماتریس ω_i به دست می آید. خواص این ماتریس از این تعریف :

$$\varphi(r) = \frac{1}{\sqrt{r^2 + c^2}} \quad c > 0 \quad r \geq 0$$


$$\varphi(r) = e^{-\frac{r^2}{2\sigma^2}} \quad \sigma > 0 \quad r \geq 0$$

در این حال، ضرایب ω_i از رابطه $\underline{\omega} = \underline{\Phi}^{-1} \underline{d}$ به دست می آید.


Group Method of Data Handling GMDH

در سال 1968 روی پیشگویی قیمت بعضی در درودرختان با کار رفت. آنرا با استفاده از روش (who the bell?) سترز شد. برای کاربرد در مدل های متعدد دیگر هم بسیار خوب کار کرده است.

این شبکه عموماً برای توابع نخطی یک یا چند مرحله استفاده می شود. این شبکه ها در واقع توابع چند جمله ای از درجه n را می سازند. $f: A \subset \mathbb{R}^n \rightarrow \mathbb{R}$



$$z_k^{(l)} = a_k^{(l)} \left(z_i^{(l-1)} \right)^2 + b_k^{(l)} \left(z_i^{(l-1)} z_j^{(l-1)} \right)$$



این شبکه ها در واقع توابع چند جمله ای از درجه n را می سازند.

$$+ c_k^{(l)} \left(z_j^{(l-1)} \right)^2 + d_k^{(l)} z_i^{(l-1)} z_j^{(l-1)} + e_k^{(l)} z_j^{(l-1)} + f_k^{(l)}$$

با افزایش به سطح در شبکه و چند چند جمله ای در شده. در 2 فرم می شود: لذا از در شبکه به جز این درودرختان، این شبکه ها در مدل های مختلف نیز استفاده شده است. این چند جمله ای، چند جمله ای براونر نامیده می شود.

چون این شبکه بدون صورت است که از نمودار، لایه به لایه شبکهاش فته می شه در هر لایه
اولین قدم آنست که برای هر تابع خروجی لایه قبل یک واحد قطار رسم در شبکه واحد
در لایه l لایه $l+1$ باشد. تعداد واحد در لایه $l+1$ را (n_{l+1}) خواهد بود.
برای هر لایه که از آن فته می شه به طور مستقیم تطبیق داده شده و ثابت می شه.

در این مرحله در هر لایه l سعی می کنه خروجی z_j را تولید کنه. تنظیم z_j پارامتر هر واحد
در شبکه از رابطه زیر بدست می آید که نمودار آن در شکل خروجی انجام می شه. اعمال هر واحد p خروجی z_j
($l-1$) z_j در لایه $(l-1)$ ای داشته و در لایه l وارد می شه. چرخه هر واحد می خواهد مقدار z_j
 t_p را از این بکنه z_j را با p در نظر می گیریم. لذا برای هر واحد در لایه l به گونه آموزش
(p, t_p) یک واحد z_j پارامتر ای در شبکه!

برای به دست آوردن یک مجموعه آموزشی جدید آموزش داده شده به صورت حاصل از آموزش یک واحد k
در سطح l را می توان به صورت زیر نوشت:

$$\begin{matrix}
 z_j^{(l-1)} \\
 z_j^{(l-1)} \\
 \vdots \\
 z_j^{(l-1)}
 \end{matrix}
 \begin{bmatrix}
 1 & z_j^{(l-1)} & z_j^{(l-1)2} & \dots & z_j^{(l-1)(l-1)} \\
 (z_j^{(l-1)})^2 & (z_j^{(l-1)})(z_j^{(l-1)}) & (z_j^{(l-1)})^3 & \dots & (z_j^{(l-1)})^{l-1} \\
 \vdots & \vdots & \vdots & \ddots & \vdots \\
 \vdots & \vdots & \vdots & \vdots & \vdots \\
 \vdots & \vdots & \vdots & \vdots & \vdots
 \end{bmatrix}$$

$$z_k^{(l-1)} \begin{bmatrix} a_k^{(l)} \\ b_k^{(l)} \\ c_k^{(l)} \\ d_k^{(l)} \\ e_k^{(l)} \\ f_k^{(l)} \end{bmatrix} = \begin{bmatrix} t_1 \\ t_2 \\ t_3 \\ \vdots \\ t_L \end{bmatrix} \Rightarrow z_k^{(l-1)} P_k^{(l)} = T$$

PAFCCO

مقدار فوق درای به پستی تریابی خواهد بود. درای حداقل گنج MSE عبارتت از:

$$P_k^{(e)} = \left(Z_k^{(e-1)} \right)^+ T$$

هرای آنکه برانیم بزرگتر از اندازه مجموعه آموختن است. باید که در این مجموعه (یا یک یا مجموعه) را برآورد حساب کرده و اندازه مجموعه را پیدا کرد. برای هر یک از برآورد را حساب نمود. اگر تفاوت برآورد زیاد نباشد، مجموعه اول کافی است.


به تعریف پارامترهای پروا، عملگر هر واحد در رسیدن به هدف حداقل گنج MSE یک مجموعه آموختن جدید از این مجموعه است. اگر تفاوت بین این مجموعه است.

مقدار $\| Z_k^{(e-1)} - P_k^{(e)} \|_2$ را می سنجیم. اگر این خطا برآورد را

از یک مقدار است. بزرگتر باشد واحد بزرگتر واحد می گنیم. با این روش، واحد

یک پس از دیگری در لایه ای می خواند تا جایی که به توقف ارضا شود.

اگر در لایه کوچکترین MSE را در نظر بگیریم، این مقدار با افزایش لایه ها تا جایی که بیش می رود پس از آن افزایش پیدا می کند. در آخرین حد قبل از افزایش، ای لایه جدید را متوقف می کنیم.



در لایه خوبی، غیر از آن واحدی که کوچکترین خطا را داشته باشد، واحد حذف می شود. حلال است این

واحد، مطلق است و هر دین در لایه قبل بودن، باشند که در اصل به واحد صریح نه زشته باشند
بدین ترتیب آن واحد نیز حذف می شود.

این شکر شفا دارد چه چیز کما ندارد؟ جان؟ بگو دلبه! خون فلان بگو!
شکر آن که ۲ درودک می خورد و حاله درجه پنجمی برای ناشکیلی می دهد.

پنجاه روزی

یک توجیه برینه تشکیلی می دسیم و به جرات گفتن آنج حل اینها را پیدا می کنیم.

روش دی سنتی اینها روشی: روش مخراب لا کلاثر، برینه روزی حفی، نیز حفی و فائده اینها

استفاده از شکر دی مصفی، در سوارک که روش ای سنتی خوب عمل نمی کند این روش در حقیقت
عمل می کند؛ مثلاً در جادوی که اینها را با ریختن در رویت دی قضا قضا
انجام شود.

شکر دی مصفی قطعی (Deterministic)

مشکل گرانده در وقت اینها

شکر دی مصفی آن (Stochastic)

مشکل فوقه و اولاد

Subject:

Year _____ Month _____ Date _____

کم دما کوکھ فزیت (Annealing)

1. حرارت دہلیج فزیت حالت زور زور سے ترک دوسکتی دی شدہ فزیت می شود
2. کوکھ فزیت صورت آرام و تدریجی

مجموعہ حالات α_i کے لیے

انرژی کی سطح E_{α_i} کے لیے

حرارت T

اگر $T > 500^\circ K$ (معتدل) ہے تو سیکم دراز کی فزیت حرارت خرابی سے بچے گی

انسانی از حالتی بہ حالت
دیگر انرژی را بطور جبرئتی
کم نہ لای گند

توازن حرارت: فزیت سیکم حول مقدار متوسط ثابتی است و از این مقدار دور نمی شود

احتمال شتخ سیکم بہ حالت α_i از حالت تعادل e : P_{α_i} نشان می دہند

$$P_{\alpha_i} = \frac{1}{Z} e^{-\frac{E_{\alpha_i}}{k_B T}}$$

* تابع احتمال بولتزمان

where $Z = \sum_i e^{-\frac{E_{\alpha_i}}{k_B T}}$

k_B بولتزمان ثابت ہے اور $k_B = 1.38 \times 10^{-23} \text{ J/K}$

نسبت احتمال β حالت α_i و α_j

$$\frac{P_{\alpha_i}}{P_{\alpha_j}} = e^{-\frac{(E_{\alpha_i} - E_{\alpha_j})}{T}}$$

اگر $T \gg 1$ $\Rightarrow \frac{P_{\alpha_i}}{P_{\alpha_j}} \rightarrow 1$

در ترکیب حالت β بلا احتمال وقوع فرسخ سیستم به یک حالت α انرژی بالاتر است و احتمال وقوع سیستم به یک حالت پایین تر است.

بهینه سازی با روش تاپکی شبیه سازی شده (Simulated Annealing)

تایم میزبان بهینه سازی \rightarrow تایم انرژی قدر
مقیودگی ساده \rightarrow درجات قدر

قبول تنها احتمال 0.5 تایم میزبان را کاهش می دهد \rightarrow کاهش تایم در هر مرحله است
الله در سیستم های عملی \rightarrow روی در ترکیب سیستمی که است در فرسخ

اجازه به بالا فرسخ سیستم عملی \rightarrow اجازه انتقال به حالت α انرژی بالاتر

یک جنبه ای β به یادگیری افزوده شود P به یادگیری مانند آفتاب گسترش به شدت و اگر سیستم هم اجازه انتقال به حالت α انرژی بالاتر هم به حالت α انرژی پایین تر را بدهد.

در هر قدم در یک مقیور یک تغییر ایستادگی را در سیستم می دهد از حالت α_i به حالت α_j برود

$$\Delta E = E_{\alpha_j} - E_{\alpha_i}$$

تعداد افراد در هر گروه را N_i و N جمع کل افراد را N می‌نامند.

میانگین \bar{x} و \bar{y} را می‌توانیم به صورت زیر بنویسیم:

$$\bar{x} = \frac{\sum x_i N_i}{N}$$

$$\Delta E = f(x) - f(x')$$

$$x_i = \bar{x}$$

تعداد افراد در هر گروه را N_i و N جمع کل افراد را N می‌نامند.

میانگین \bar{x} و \bar{y} را می‌توانیم به صورت زیر بنویسیم:

$$\bar{x} = \frac{\sum x_i N_i}{N}$$

تعداد افراد در هر گروه را N_i و N جمع کل افراد را N می‌نامند.

$$\Delta E < 0 \Rightarrow \bar{x} < \bar{y}$$

آنچه گفته است، مقدار T را برابر α قرار دهم $T \leftarrow \alpha T$
 $0.8 < \alpha < 1$, $M \ll N$

7. اگر مقدار حداقل F را تا اندازه آخر بیشتر از ϵ کاهش ندهیم، الگوریتم را خاتمه می‌دهیم
 در غیر این صورت به قدم 2 برمی‌گردیم

نات شدن این که این الگوریتم همگرا می‌شود (در این استقراض) این در عمل میسر نیست اما،
 نتیجه آنداشن محدود نیز خواهد بود بسیار خوش آنرا می‌تواند در صورتی که ϵ را در حد مناسبی
 انتخاب کنیم و مقدار به طور تقریبی نزدیک کم است.

امثال روشن تا کارهای شبیه سازی شده بشود که در ادامه خواهد آمد

برای استناد از روش SR در شبیه دینید، تعاریف تبدیل و معادله به شکل زیر تغییر دهم.

$$y_i^{NEW} = \begin{cases} -y_i^{OLD} & (\Delta E < 0) \\ y_i^{OLD} & (\Delta E \geq 0, \sum \frac{\Delta E}{T} < \epsilon) \end{cases} \text{ otherwise}$$

در اینجا نیز در هر زمان تنها یک معادله را به سیستم درمی‌آوریم. این معادله به صورت افقی و عمودی است. این
 معادله در هر حالات نیز می‌تواند از تعادله‌های دیگر از تعادله‌های سیستم سازی. کاهش یافتن تعادله‌های
 این آورده می‌شود. به پنج شبیه‌سازی حتی اگر به همگرا می‌گردد، معادله‌های
 پنج این است. بعضی در این شبیه‌سازی (Hopfield + SA) را می‌تواند به بهترین
 نتیجه برسد.

Subject:

Year: Month: Date: ()

ماشین بولتزمن (Boltzman Machine)

در سال ۱۹۸۳ توسط جیمز جی هورنباک در این ماشین محدود دارای حالت بزرگ را انتقال حالات، انتقالی هستند و فقط دارای تعداد ثابت می باشند.

"Vanity, is definitely My Favourite Sin"

Al pacino in Devil's Advocate

هر دینگ x_i و x_j از میزان تطبیق فصل بفرخ بفرخ و واحدی می باشد برای استفاده در این نوع شبکه مورد استفاده می شود و محدودیت دارد و تنها در آن استفاده می شود.

ماشین بولتزمن از محدودی از واحدها و اتصالات در فرم تشکیل شده است. اگر واحدها و واحدهای هم وصل باشند $+0$ و $x_i = x_j$ و انتقال به وجه نیز به فرخ x_i و x_j خواهد داشت به شدت حذف حلاله که یک فرخ آرا را است بصورت زیر:

$$C = \sum_i \sum_{j \leq i} w_{ij} x_i \cdot x_j$$

تعداد واحدها

حلاله که یک فرخ آرا را است تعداد از روش SA (نیم می شده) برای ماشین بولتزمن از واحدها و واحدها تغییر حالت داده شده در این حال تغییر آرا را به شکل فرخ خواهد بود.

$$\Delta C(i) = [1 - 2x_i] [w_{ij} + \sum_{j \neq i} w_{ij} x_j]$$

فرخ آرا


$$A(i;T) = \frac{1}{1 + e^{-\frac{\Delta C(i)}{T}}}$$

این شبکه تغییر حالت فوق را با انتقال

در هر حالت T تری کاپاش می باشد. جاری شبکه را محدود می کنیم و تنها با توجه به کاپاش می شود.

یک گونگی:

مقدار بصورت یک آرایه β در یک $n \times n$ ماتریس A قرار می‌گیرد. این n مقدار در یک $n \times n$ ماتریس A قرار می‌گیرد. β در یک $n \times n$ ماتریس A قرار می‌گیرد.



در یک $n \times n$ ماتریس A قرار می‌گیرد.
 p : در یک $n \times n$ ماتریس A قرار می‌گیرد.
 b : در یک $n \times n$ ماتریس A قرار می‌گیرد.

اگر β را به صورت $\beta = (\beta_1, \beta_2, \beta_3)$ در نظر بگیریم

در یک $n \times n$ ماتریس A قرار می‌گیرد. $\beta = (\beta_1, \beta_2, \beta_3)$ در یک $n \times n$ ماتریس A قرار می‌گیرد.

$$b = (b_{12}, b_{21}, b_{23}, b_{32}) \quad \beta = (\beta_1, \beta_2, \beta_3) \quad \text{برای } i = 1, 2, 3 \quad \omega = (\omega_{12}, \omega_{21}, \omega_{23}, \omega_{32})$$

شکل بصورت $n \times n$

مقدار β در یک $n \times n$ ماتریس A قرار می‌گیرد. $\beta = (\beta_1, \beta_2, \beta_3)$ در یک $n \times n$ ماتریس A قرار می‌گیرد.

مقدار β در یک $n \times n$ ماتریس A قرار می‌گیرد. $\beta = (\beta_1, \beta_2, \beta_3)$ در یک $n \times n$ ماتریس A قرار می‌گیرد.

مقدار β در یک $n \times n$ ماتریس A قرار می‌گیرد. $\beta = (\beta_1, \beta_2, \beta_3)$ در یک $n \times n$ ماتریس A قرار می‌گیرد.

Subject:

Year: _____ Month: _____ Date: _____

۲- قسموں کی جی اے اور جی ۵ n^2 بار اپنی ہم میں دیکھیں (epoch 1 = n^2 بار)

3- تعداد صحیح I اور J راہ طوراً متاثر ہیں اور n اوقاب میں کھینچیں

4- تغیر درآمد یا سبب میں کھینچیں:

$$\Delta C = [1 - 2x_{IJ}] [\gamma_1 (I, J; J, J) + \sum_{I, J} \sum_{I, J} \gamma_1 (I, J; I, J) x_{IJ}]$$

$$A(I, J) = \frac{1}{1 + e^{-\frac{\Delta C}{T}}}$$

5- سبب احتمال تبدیل تغیر حالت

6- تصیم لہری درجہ تبدیل وارد تغیر حالت جی ایک متعلقہ اوقات میں 0, 1, 10 اوقاب میں کھینچیں اگر $A < 0.5$ جی تغیر حالت را تبدیل میں کھینچیں
و اگر $A > 0.5$ جی تغیر حالت تبدیل میں کھینچیں
 $x_{IJ} = 1 - x_{JI}$

$$T_e = 0.95 T_{e-1}$$

7- کوشش ہر قدر T

8- شرط خاتمہ را اٹھائیں میں کھینچیں

اگر ایک تعداد epoch سے تغیر حالتی سے ظاہر رہے آہر ایک متعلقہ حالات سے بہتر ہونے شروع ہو گئے ہیں تو فوراً اس وقت سے دوبارہ شروع کریں (متعلقہ اوقاب آہر درجہ کی بڑھ جائے)
ہر احتمال تبدیل حدود 0.5 شروع

کارہ در سالہ فزوشندی دورہ کو (TSP)

n : تعداد شروع (مثلاً 10)

ن: n زیرین دینه شتر (Isisn)


ز: n ترت سفر (nms)

ژ: n : طاصی کرفق کتر از شتر، دم در مرحله n ام از سفرمان شتران مدهد.

ژ: n : تعالی طاصی n یعنی } $1 = d_{1,n}$ فرض n صحیح است.
 $5 = d_{5,n}$

$d_{i,k}$: فصه بین شتر k و شتر i ($i \neq k$)
 d : همکاران فصه بین هر دو شتر

میری شتر



بروادم ژ: n که خود افعال با وزخ طاصی در شتران یک اتصال به هم داده شد طاصی در شتران n

خود افعال ژ: n مطلوبیت بعد از شتران در مرحله n ام است مدهد.

اتصال هر دو شتر به هم داده شد در این صورت که از شتر n ام به شتر n ام به هم داده شد.

بروادم ژ: n که خود افعال با وزخ n - اولی در شتران این صورت است n .

از n شترانی تا n شتران به هم داده شد.

طاصی n به طاصی $n+1$ برای $1 \leq k \leq n$ و $k \neq i$ به وزخ $d_{i,k}$ - دلیل است این اتصال

فصه بین شتر k و شتر $k+1$ در مرحله n ام.

Subject: _____

Year _____ Month _____ Date _____

واحد زینا سیرملاء U_1, U_2, \dots, U_n بریک k کے لئے $U_1 + U_2 + \dots + U_n = k$ اور $U_1 \geq 0, U_2 \geq 0, \dots, U_n \geq 0$ ۔ اصل ارت
 این اتصال، فصلی طر شدہ از شرک k در سرحله k ن تا شرک در سرحله k را
 ارترا میں دھت۔

۱۔ مرتبہ ترتیب کے لئے D کا انتخاب $a > p$ کے نتائج اور a کے لئے k کے لئے قابل قبول مقدار
 ترتیبی طور پر ایک کے لئے قابل قبول مقدار

۲۔ مرتبہ ترتیب کے لئے $a > p$ کے نتائج اور a کے لئے k کے لئے قابل قبول مقدار
 حاصل اور k کے لئے a کے لئے قابل قبول مقدار

مثال عددی حل :

$A = (0.4 \quad 0.4439) \quad B = (0.2439 \quad 0.1463)$

$C = (0.1707 \quad 0.2293) \quad D = (0.2293 \quad 0.7610)$

$E = (0.5171 \quad 0.9414) \quad F = (0.8732 \quad 0.6536)$

$G = (0.6879 \quad 0.5219) \quad H = (0.8488 \quad 0.3609)$

$I = (0.6683 \quad 0.2536) \quad J = (0.6195 \quad 0.2634)$

A B C D E F G H I J

A 0

B 0.3361

C 0.3141 0.1107

D 0.3801 0.6149 5049

E 0.5111 8407 7919 3397

F 0.5176 8083 8207 8207 4579

G 2982 5715 5941 5941 4529 2274

H 9564 6418 6908 6208 6682 2937 2277

I 3289 4318 4982 4982 7042 4494 2690 2100

J 2892 8934 4501 4501 6857 4654 2674 2492 0498

Subject :

Year . Month . Date . ()

دستیاب تعداد به ازای $T_j = 0.9 T_{j-1}$ ، $T_0 = 20$ ، $p = 70$ ، $b = 60$

100 حالت مختلف تولید ، محدود تصنیف و محدود در برابر آنتنای تکگوشه ای ، آنتنای تکگوشه ای در همه این حالات به ازای قابل قبول در کمتر از 20 اینک حاصل شد.

اینترین پاسخ به دست آمده :

GFDEACBJIA 3036 رت

DAIDGFHECB 3.713 جبهه بومی ->

به تعداد یکجمله برای p و b ($b=30$, $p=35$) آنتنای تکگوشه ای ، محدود تصنیف و محدود در برابر مختلف پاسخ راه حل ، به دست کوچکتر از راه حل بالا پیدا شد . در جواب همگام ، آنتنای تکگوشه ای (طولانی تر)

، محدود به همگامی برای p و b ($b=6$, $p=7$) آنتنای تکگوشه ای ، محدود تصنیف و محدود در برابر مختلف پاسخ به ازای قابل قبول پیدا شد .

نظریه تشدید تطبیقی (Adaptive Resonance Theory)

1987 در کتاب "کتاب" ، گسترش یافت . نمونه برجسته ART1 ، ART2 ، ART3 گویا .

- ART1 : یک خوشه بندی برداری پویا
- ART2 : ~ ~ ~ ~ ~ پرست
- ART3 : نظریه اصبغ شدهی ART2

Subject:

Year: Month: Date: (/ /)

استانده: دراز ← به دردی از نمونه دی جوبه
 Stability
 - plasticity
 Dilemma

2. استانه: چند لایه در لایه فرعی داشته باشیم!

توی باشد! اگر مقادیر از داده دی جوبه به هم میزنیم و از کجا معلوم داده دی جوبه به یک خوشه جوبه
 متعلق نباشد! صاف!


راه حل: مقادیر غیر فعال در مقادیر فرعی وجود داشته باشند که در صورت نیاز فقط فعال کنیم

شبکه ART1

در این شبکه، تفاوت در تغییر حالت بین دو حالت بیشتر در پایله

ت بیشتر پذیر، انجام یادگیری و تغییر پایله در شبکه
 پایله: این صده به یادگیری شبکه که دستگیری انجام می شود.

حجاری شبکه



فرمولها را بنویسید

چرا فعال است:

۱- تشخیص مواردی در سیستم: فریبی از تصادفات منبک مشخص می شود. $V_{ij} = 1$

$$V_{ij} = \frac{1}{1+n}$$

آستانه بر وقت (Yigilance threshold) $0 < \rho < 1$

و فعال در روی غیر صفر باشد ممکن است control-1 را نشانه دهد! می شود و در سیستم F1 را


در حالت در روی قاری در هر 4 اگر حرکت از داده های سیستم خود را فعال باشند اجابت control-1

در روی صفر می شود

با فعال در روی سیستم control-2 = 1 می شود و در داده های خود را فعال می کند در روی

؟ یک از برخی حالات یعنی control-2 = 0 می شود و در داده های خود را غیر فعال و

فردی های آن را صفر می کند



فرمولها را بنویسید

فرمولها در روی در روی سیستم فریبی دارد

مورد داده ها از روی در روی سیستم 2/3 اکثری می شود یعنی اگر در روی است در روی فقط

در روی داده ها از روی در روی سیستم ← خود را در 1 = 0

$$\phi = n$$

لایه F2 که لایه ارتباطی است. برادر ورودی به این لایه، الگوریتمی می‌شود. در درونهای واحدی
 لایه F2 تقسیم می‌شود. در این لایه تطبیق مشخص می‌شود.

این تطبیق، با سبب ضرب داخل اعداد حسابی بازنمایی و واحدی لایه F2 هر واحد دیگر
 واحدی که دارای توابعی است یا خارج می‌گردد.

با فعل شدن خروجی واحد برده و نهایی اعداد است. بهشتی به F1 وارد می‌شود.

c- بازتاب

یک خروجی لایه F2 فعال است - سینال control 1 صنوی می‌شود.

در هر واحدی که در 2/3 اعداد می‌شود که در حقیقت برادر ورودی خاصی در ورودی از خروجی لایه F2 را
 با هم AND می‌کنند. نتیجه این عمل در خروجی F1 ظاهر می‌شود.

این برادر و برادر ورودی به بخش Reset وارد می‌شود. در این بخش آستانه برابری می‌شود.

$$r = \frac{\sum v_j z_i x_i}{\sum x_i}$$

(تعداد اعداد شرکت در الگوریتمی ورودی) تعداد اعداد ورودی

r میزان است از 0 تا 1 برادر

اگر $r \geq p$ واحد فعلی لایه F2 خوشه درونی را نشان می‌دهد. خوشه‌های تمام شده
 در آنها اصلاح می‌شود.

اگر $r < p$ این الگوریتم نمونه برای این ورودی می‌باشد. واحد فعلی نیز فعال می‌شود.
 (سویچ القول) در این حالت جستجو می‌گردد.

تلفیق دو برادر ورودی و خروجی

۴- فرض کنید
واحد برنده میانی ← غیرفعال ← خرابی آن صنوبر می شود ← در تطبیق برای تعیین ترتیب می باشد
سختن 1-control صنوبر می شود.

در ردی به لایه دوم اعلان می شود در بهترین تطبیق دوباره مشخص می شود.
سپس شبکه دارد و فاز سفید می شود و تطبیق جدید برای ارضیه ۲ آزمون استاندارد برایت
نیت می شود. این فرآیند مکرراً تکرار می شود و در اصد های خرابی غیرفعال می شوند تا آنکه
واحدهای بیایا شده که در یکجوده قابل قبول برای حددار استاندارد برایت با در ردی تطبیق داشته باشند
اگر چنین مواردی پیدا شود شبکه فرود می جدید را به یک واحد جدید استفاده نشده در یک
حرفه جدید نیت می شود.

اگر سیستم

انتخاب حددار اولیه برای $V_{ij}(0) = 1$ $0 \leq j \leq m-1$
 $W_{ij}(0) = \frac{1}{1+n}$ $0 \leq i \leq n-1$

انتخاب حددار P (مورد ۰.۹)

۴- در ردی جدید به شبکه اعلان شده

۵- محاسبه میزان تطبیق با الگوریتم نمونه
$$\mu_j = \sum_{i=0}^{n-1} W_{ij}(t) X_i$$

$$j = 0 \dots m-1$$

۶- تعیین بهترین تطبیق
$$\mu_j = \text{Max}_j (\mu_j)$$

Subject: _____

Year _____ Month _____ Date _____ ()

$$R = \frac{\sum_{i=0}^{n-1} V_{ij}(t) X_i}{\sum_{i=0}^{n-1} X_i}$$

۵- از جدول برآید

اگر $r \geq P$ به قدم 7 می رویم
 وگرنه $r < P$ به قدم 6 می رویم

۶- واحد J را نیز فعال می کنیم. عقب و جلو را \oplus می کنیم و به قدم 3 می رویم.

۷- در نهایت بهترین تطبیق را اصلاح می کنیم.

$$V_{ij}(t+1) = V_{ij}(t) X_i$$

$$V_{ij}(t+1) = \frac{V_{ij}(t) X_i}{0.5 + \sum_{i=0}^{n-1} V_{ij}(t) X_i}$$

۸- اصلاح غیرفعال را فعال نموده به قدم 2 می رویم.

این شبکه در حوزین می تواند در حالت آموزش شده و ادماهای جدید را در آموزش داشته
 شبکه به کارگیرد

شبکه ART1 در طی آموزش نسبت به مقدار بسیار زیاد وزن جدیدی
 این هم این مقدار و وزن (بسیار کوچک است)

اگر مقدار m کوچک باشد (مثلاً 0.4) که کلاس بندی (جذب بندی) از روشن شدن
 این وضعیت به در آن کلاس می شود و در آن کلاس می شود.

اگر مقدار m (مثلاً 0.9) بزرگ باشد در نتیجه کلاس بندی از روشن شدن این خواهد شد

کہ دورانِ تعمیرات جن میں نئے نئے ایڈسٹمنٹس اور جدید سہولتیں لگائی گئیں۔

کہ تعمیرات میں جو کام ہو رہا ہے، اس میں تعمیرات میں نئے نئے ایڈسٹمنٹس اور جدید سہولتیں لگائی گئیں۔
اور ان کے لیے یہ بھی سہولتیں پیش کی گئی ہیں جو کہ صاف اور درمیانہ ہیں، تاکہ عوام کو مزید سہولت ملے۔
تعمیرات میں جو کام ہو رہا ہے، اس میں تعمیرات میں نئے نئے ایڈسٹمنٹس اور جدید سہولتیں لگائی گئیں۔
جنم اور یہ ایڈسٹمنٹس ہیں، ان کے لیے یہ سہولتیں پیش کی گئی ہیں، تاکہ عوام کو مزید سہولت ملے۔

گورنمنٹ

حرفی سہولتیں
تعمیرات میں پیش کی گئی ہیں

بہتر سہولتیں پیش کی گئی ہیں

پیش کی گئی ہیں، تاکہ عوام کو مزید سہولت ملے۔
تعمیرات میں جو کام ہو رہا ہے، اس میں تعمیرات میں نئے نئے ایڈسٹمنٹس اور جدید سہولتیں لگائی گئیں۔

رک

ان کے لیے یہ سہولتیں پیش کی گئی ہیں، تاکہ عوام کو مزید سہولت ملے۔
تعمیرات میں جو کام ہو رہا ہے، اس میں تعمیرات میں نئے نئے ایڈسٹمنٹس اور جدید سہولتیں لگائی گئیں۔

گورنمنٹ

