


Subject:

Year. Month. Date. ()



سلام علیکم

safa@aut.ac.ir

* استاد:
دکتر رضا خانیان

* نویسنده:
دکتر شمس

* مراجع درس:

- Neurocomputing, R Hecht - Nielsen, Addison Wesley, 1990
نویسنده: روزمان محمدی
- Fundamentals of Neural Networks, L. Fausett, Prentice - Hall, 1994
آسان، گلابی
- Neural Networks, A comprehensive Foundation, S. Haykin, Macmillan College Pub., 1994
- Artificial Neural Networks, Theory and Applications, D.W. Peterson, Prentice - Hall, 1996
نویسنده: در حال حاضر، سایر نظریه‌های دیگر
- Introduction to the Theory of Neural Computation, Hertz, Krogh & Palmer, Addison Wesley, 1991
- Introduction to Artificial Neural Systems, J.M. Zurada, Info Access and Distribution, 1992
موضوعات محدودتر و در دسترس
- محمد باقر میرنج، ماساچیوستس، انتشارات دانشگاه صنعتی امیرکبیر، ۱۳۷۹

Subject:

Year:

Month:

Date: ()

* بهترین کتابهای مربوط

- Neural Computation , MIT Press
- IEEE Trans. on Neural Networks , IEEE
- Neural Networks , Elsevier
- Neural Processing Letters , Springer
- Neurocomputing , Elsevier

↑
دستیاری
اعتبار

* بهترین کنفرانسها

- IJCNN : Intl. Joint Conf on NN
- ICANN : Intl. Conf on ANN
- WCCI : IEEE World Congress on Computational Intelligence
- ESANN : European Symp. on ANN
- ICNC , Intl. Conf. on Neural Computation
- ISNN : Intl. Symp. on NN
- ICIC

* مباحث درس

• مقدمات : ماهیم ، تاریخچه ، کاربرد

• شبکه‌های عصبی طبیعی : ساختار فیزیکی ، عملکرد

• شبکه‌های عصبی مصنوعی : شبکه‌ها ، پردازشگر ، اتصالات

• مسأله دسته‌بندی : معرفی ، حل با واحدهای پردازشگر

• برداری الگو : شبکه‌های توابعی ساده : پیش‌خورد ، پس‌خورد ، اوپرنده

• یادگیری : با نظارت ، بی نظارت ، با ارزشیابی تقویتی

• شبکه‌های خود سازمان ده : رقابتی ، رقابتی دارای وزن ثابت ، گوانتیزاسیون برداری

• شبکه پرسپکتیونی محدود لایه و قانون انتشار خطا به عقب : مانند ، تقریب ، بهبود

• شبکه‌های توابع پایه شعاع : جبرانی پذیرای الگو ، آموزش شبکه

• شبکه‌های انجمنی : بهبود سازی ، شبیه سازی تابکاری ، ماشین بولتزمن

• شبکه تقریب تسخیر طبیعی : معرفی ART1

• شبکه‌های دیگر : Time Delay NN

Subject :

Year . Month . Date . ()

* ارزیاکی

٪ ۵۰

• امتحان پیل ترم

٪ ۱۰

• گزارش مطالعاتی

٪ ۱۰

• ارائه شفاهی

٪ ۱۵

• سباده سازی

٪ ۱۵

• پروژه ۴

© مودرن

* عارضه شبدهی عصبی

Neural Networks , Neural Nets

Artificial Neural Networks (ANN)

Connectionist Model

نظریه دانشی ←

Parallel Distributed Processing Model (PDP)

Neuromorphic Systems

Neurocomputing , Neural Computing

شبدهی عصبی ، شبدهی فودنها ، شبدهی سلولهای عصبی (عصبی)

* شبدهی عصبی چه هستند؟

تأثیرهای تولید از عملکرد مغز انسان

مغز انسان می تواند ادراک و استخراج بهوشمندی از اطلاعات ناشی ، مهم یا متناظر داشته باشد.

انسان نه از کامپیوتر سریعتر است و نه دقتتر

اما انسان بسیاری از کارها را بهتر از کامپیوتر انجام می دهد.

کامپیوتر دارای محدودیت در ارتباط بین آنها

نظم سریع و صحیح زبان

بزرگایی سریع اطلاعات مرتبط از حافظه

طرح ریزی برای انجام کاره : تعیین بدنه های لازم

انجام بهتر کاره با ابزار آن : کسب تجربه به

یاد گرفتن

* چرا انسان بهتر از کامپیوتر عمل می کند.

— ما سنبله نرم اطلاعاتی لازم را نداریم.

— معماری مغز با معماری ماشینهای ما متفاوت است.
معماری مغز سهولت پردازش اطلاعات طبیعی مناسبتر است.

* دیرینه پردازش اطلاعات طبیعی

— اطلاعات در محدودیتهای مختلفی باید به طره پردازش نظر گرفته شود.

— این اطلاعات در محدودیتهای هم ممکن است ناقص یا مبهم باشد.

۱۱ رفتن می خواهیم در حال نشسته جسم را از روی زمین برداریم و ایوان جایی در دست ما

طرح ویزی حرکات بدن
جایی نزدیک ، از روی صندلی پایین نیافتیم ، دستمان به لبه تیز میز برخورد
دزدن جسم در نحوه برداشتن مؤثر است.
حل نشی ، در وضعیت نشی ، اندازه و شکل دزدن مورد انتظار نشی
انسان را بر سر راه ما


۱۲ درک زبان

معنی روی دستور اشکی ندارد ، دستور روی معنی

{ I like the joke.
I like to joke.

I saw the Grad Canyon flying to NY.
I saw the sheep grazing the field.

تشخیص حروف و طرات



BED : انسان

B E D E I S H

جای تشخیص از دانش سطح بالای ما (زبان انطیس) استفاده می کند .
یعنی می کند امکانات مختلف دارد نظر بگیرد .

* سیستم ادراک انسان می تواند بدن تقسیم کردی نهایی امکانات مختلف را ارزیابی کند

تا آنکه همه محدودیت ها ارضا شود . در آنحال تقسیم نهایی اتخاذ می شود .

ما علاوه بر ایجاد چنین توانایی های در کامپیوتر هستیم .

* مثالیه رایانش (computing) سنتی و عصبی

رایانش عصبی

— سازی به الگوریتم نسبت

— از الگوریتم تشخیص نباید یا مشکل باشد

— دی پیاده سازی آن برچهرینه ، زمانبر

— ریاضی شکل باشد می توان از رایانش عصبی

— بهره صحبت

رایانش سنتی

— درش حل مسئله در ده سال گذشته

— در مثال یک الگوریتم می گوئیم

— الگوریتم باید پیاده شود

— باید قابل پیاده سازی باشد (سادگی)

— باید نرم افزار مناسب داشته شود

* رایانش عصبی

رایانش موازی توزیع شده و تقیسی که در پاسخ به یک محیط اطلاعاتی مدت پردازش اطلاعات را سادگی کند

* مقاله روشهای هوش مصنوعی سنتی و رایانش عصبی

روشهای هوش مصنوعی سنتی

رایانش عصبی

- دانش به شکل داده‌گیری شود.

- سیستم یادگیری نمونه‌های از مسئله مورد
تواضعی ایجاد می‌کند.

- حافظه و اطلاعات تیز به شکل کامل می‌ت

- اطلاعات در شبکه به صورت کاملاً تیز
مده است.

- حافظه تداعی گریست

- حافظه تداعی گریست : به دردهای
ناگهانی ، نویزی یا علائم شده
پاسخ مناسب می‌دهد.

- صدمه به حافظه سیستم را از کار می‌اندازد.

- با خراب شدن بعضی واحدهای اتصال
بدشکل ، رفتار شبکه تنها کمی تغییر
می‌کند . با تغییرات بیشتر رفتار بدتر می‌شود
... (Graceful Degradation)

این رفتار برای کاربردهای حساس بسیار
است.

کاربردهای مناسب برای Graceful Degradation

تولیدات امنی ، پروانه ، مرسد ،
جایزنی برای سخت افزار مضاعف

* پیاده سازی شبکه های عصبی

- شبیه سازی نرم افزار
- مدارات مجتمع پرتابل
- کارتهای شناس دهنده بحث افزاری
- کامپیوترهای عصبی
- پیاده سازی فیزی

* شبیه سازی نرم افزار

- تعداد اول ترین ← طراحی و حل اولیه مسائل

- شبیه سازی صرف ← قابل ترکیب نیست (با نرم افزارهای دیگر)
- منبع سازی فرآیند آموزش و ساختار شبکه

SNNS, Emergent, Java NS, Neural Lab, Matlab

- توسط کامپیوترهای مغز و سیستمهای بزرگ مولاری

- محیطی توسعه ← تعداد
- Component-based ← توسعه انواع شبکه
- قابل ترکیب با نرم افزارهای دیگر

Synapse, NeuroSolutions, NeuroLaboratory

- عیب: کند

* مدارات مجتمع پرتراکم (VLSI)

• انجام سخت افزاری عمل جمع و ضرب براساسه است

• سرعت بسیار بالا ✓ بیشتر پردازشی

• کمالات ← سرعت تر

فشارده تر

کم تلفات تر

ارتباط مستقیم با مسند

دقت بیشتر

محاسبات به روز تر

• دیجیتال

• پارامتری هم ← حداقل تعداد نودون و اتصالات هم

دقت عددی ، خودجی ، دونه

دقت مدارات ضرب کننده

• چندلایه پیچور ، بازگشتی ، تابع ششای

• فازهای شبکه عصبی : ① آموزش : شبکه ایدین نمونه و تقابل ، محیط حل کردن

مسئله یادگیری گیرد (تغییر پارامتر)


② استفاده : پارامتر ثابت

• یادگیری در باره بسیاری سخت افزاری ← مورد استفاده شدن در شبکه مساحت (فاز ⑤)

یادگیری در آنها پس از مساحت → محدودتر و سریعتر

* کاربرد های شتاب دهنده سخت افزار

• افزودن شتاب دهنده های خاص سخت افزار برای افزایش کارایی



* کامپیوتر های عصبی (Neuro computers)

• شامل برداری Board در مجتمع سخت افزار این کامپیوتر

• معمولاً سخت افزار UNIX + محیط نرم افزار گسترده

* پیاده سازی نوری

• پیرفت با تکنولوژی لیزر

✓ ندره سازی اتصالات (x4)

✓ حل سگد داخل کانالی ارتباطی

✓ بهبود تلاقی اتصالات

• آرایه های لیزر در دسترس کمی ساده به طور مولدی

• دستوری پیاده سازی

Subject:

Year: Month: Date: ()

* تاریخچه

• آبان ۲۰۰۰

فعالیت های تجزیه‌ای ← بیولوژیکی ← زیست‌شناسی
 ← مدون احساس / روان‌شناسی
 شناخت ساختار و عملکرد ← مدل‌سازی

تئوری توزیع سنتی، چند سطحی بدن سیستم‌های پردازش طبیعی

• دسامبر ۲۰۰۰ : مدل ANN

مدل برای نورون ← یک لایک و بیشتر
 انجام عملیات منطقی و حساب

قانون سب (Hebb) ← زمانی برای تغییرات تأثیر نمدن بهبودی نورون
 دیده محل اتصال آنها

• دسامبر ۲۰۰۰ و ۲۰۰۱ : ربرادولیه ANN

توزیع سنتی حافظه ← شلی

There are no special cells reserved for special memories.

سازمان Snark ← شبکه الکترونیکی (مدور + پائیسوترا)
 منشی

نظیم ارتعاشی و دینامیک المات

پرسترون ← واحد پردازشگر (Perception + Electronics)
 ← الگوریتم یادگیری → اثبات همگامی
 ← روزنبلات ← پر شبکه های عصبی

آدالاین ← عنصر پردازشگر (Adaptive Linear Element)
 ← تانوین یادگیری تدریجی
 ترکیب آدالاین؟ (Madaline) ← ویدرو

آی بی علیه پرسترون ← پرسترون مسائل ساده غیر خطی را نمی تواند حل کرد.
 ← گامبش علانده به شبکه عصبی (۱۹۹۰)

۵ دینامیک ۷ : سالهای سلون ANN

شبکه های تداعیلر ← لوبون

شبکه های تداعیلر خطی ← به مناسبت دولای ذخیره ، پزایی دشمناسایی حافظه
 ← اندرسون

انتشار خطای عقب اندر خردی ← استفاده از شبکه ای از پرسترونها برای حل مشکل واحد آن
 ← ورتن ← بوی که زیار ویدی زدا

ساخت دولای محاسباتی عصبی ← با استفاده از داده های نورد لوزی
 ← کارهای ریاضی از شنید در تحلیل خواص شبکه عصبی
 ← گرامر

دوره ۵ : No ۸۰ : دهم مجله ANN

ارائه های ترویج شده ← تحلیل های ریاضی و این

قانون دلتا ← ساختن و بارگذاری تحلیل

شبکه های پهنیله ← روی برای شبکه های ریاضی ریاضی

شبکه های گشت و شری خود سازماندهی ← کومپوننت
Self Organizing Feature Map

شبکه نظریه تشدید تطبیقی ← پارامتر + تراست + نقشه های اولیه

انتشار خطا از خروجی به لایه های عقبتر ← پارامتر فرمولاسیون
را اطلاعات، سینون و ویلیانز
استفاده از آن در MLP
انتشار در تمام
علاقه محدود تشدید به ANN

پس از ۸۴ : روش چشمگیر

اصل جدیدی برای خود سازماندهی ← لینکر

Subject:

Year: Month: Date: (A)

که بر سبای مناصبی از نظریه اطلاعات ← اصل حدالترساری (اطلاعات سبای)

شبهه های شعاعی ← کردهد ← نسخه اول
که پروتو و لیروسی ← دخانه کردن نظریه منظم سازی تیخوزف

ناسیمهای بردار پشیمان ← ویند

کیرالین بر سمت دلهای واقعی تر شبهه های عصبی طبیعی ← درودی غریبه بر جای 0/1
Spiking Neurons

Subject:

Year: Month: Date: ()

* کاربرد های شبده های مصنوعی

• شناسایی الگو های بصری ماشین

دسته بندی و خوشه بندی

تولید تقاریر

شناسایی متن بر اساس علائم در زبانهای مختلف

شناسایی اثر انگشت، چهره و امضا

برایت بدون سرشین

چهارشنبه حرکت

تذکر سازی اشغال

رومایی چندگانه

• پردازش تصویر

بهراری

بازگردانی

فشارده بهاری

• آموزش مصنوعی طلا سبب

سیستم های خبره و تقسیم یار

پردازش زبانهای طبیعی

Classical AI

Computation Intelligence

سنتی ← جستجو، بازیابی، ...

شبده های مصنوعی، پردازش کلامی، منطق مازی

رومایی یادگیر

• کنترل سیستم

شناسایی سیستم های منطقی و غیر منطقی

کنترل موتور سرد و روان

کنترل پیچیده، کنترل تطبیقی

• پردازش سیگنال

فیلتر
تخمین
شناختی و تولید لغات
تبدیل فضا به لغات
پردازش سیگنالهای صوتی

• پیش بینی سری های زمانی

به صورت مدل
به صورت ترکیبی با روشهای آماری
بازار بورس
زلزله

• آیینته سازی

مسائل هندسی (دانش یا سخن)
مسائل مدیریتی

• دولسنز

انتهای دماهی
پیش بینی وضعیت اقتصادی
پیش بینی وضعیت سهام

• تشخیص پزشکی

تشخیص بیماری از روی علائم
بیماری های قلب و ریتم و کاردیو

دل پروردہ را کہ شامی
آفتابیش در میان زبان بینی

موزن است بے خسارت دین کج

Subject: _____
Year: _____ Month: _____ Date: _____

اشیای با سبک های عصبی طبیعی

* مغز انسان

- بزرگترین سگه زلیت شناسی
- بافتی خالصی - حدودی حدود ۱۵۰۰ گرم
- دو نیمه تقریباً سادی با تبادل آئینه ای
- چین و چروکهای مشابه در محل های تقریباً مشابه ، شبیه چینهای گردن
- تقسیم بندی مغز به نواحی مختلف ← بر مبنای همان چین و چروکها

* کجتهای مغز

- قاعده پیشانی ← تعلیم ، یادگیری ، حافظه و خصوصیات رفتاری
- قاعده جانبی ← هماهنگی و کنترل درون نوزادی حسی و نوازش حرکتی ، مستوایی
- قاعده کجکاهی ← تعلیم ، یادگیری ، حافظه و خصوصیات رفتاری
- قاعده پس سری ← ناخود آگاهی
- نخچه ← کنترل حرکات ظریف بدن
- ساقه مغزی ← ارتباط مغز به نخاع ، رشته اعصاب انتقال پیام

* نخچه

- متعارف ← تارن آئینه ای
- متقل به بجه مغز

* قشر مغز

- دو نیمه مغز = قشر
- سطح خارجی ← ۳-۴ mm ضخامت ← قشر
- قشر ← مملو از نورون ← سلول عصبی ، پی یاخته

تعلیم فقط دو یک نمره ← در بر دو صفت دارد.
 یک لایه کانون قشری فعال ← در دندری غیر فعال
 در خانم ۱۱ سپرد !!!
 ازاد چپ دست ← نمره دست ← بالعکس

کترال نیمه دست بدن ← نمره چپ ← بالعکس

ناحیه ششزایی خردی تحریف شود (شبهایی، فیبری، ...) فرد میزری می شود.

در زردی تشنج ← جسم بیضی ← ارتباط میان دو نمره
 Carpus Collasum

ساختار دمی مغز از هم مستقلند اما در مناطقی مشخص بهم متصل هستند.
 فضای بین ساختارها ← زنجیره های از غار ← بطن
 پر از مایع مغزی - نخاعی ← غذا رسانی
 ششتری سوار زائد

ساخته مغزی ← سوار کاوشته دی مغزی
 ← ادامه نخاع

در صورت از بین رفتن سلولی از مغز بدیش مجددی در کار نیست.
 وی برای جریان عوارث از قسمت های غیر فعال استفاده می شود.

مغز به مدت به استیران و طول از خون دالت است ← چند ثانیه کمبود ← عیش
 ← چند دقیقه کمبود ← اغما

Subject:

Year: Month: Date: ()

* لایه ها

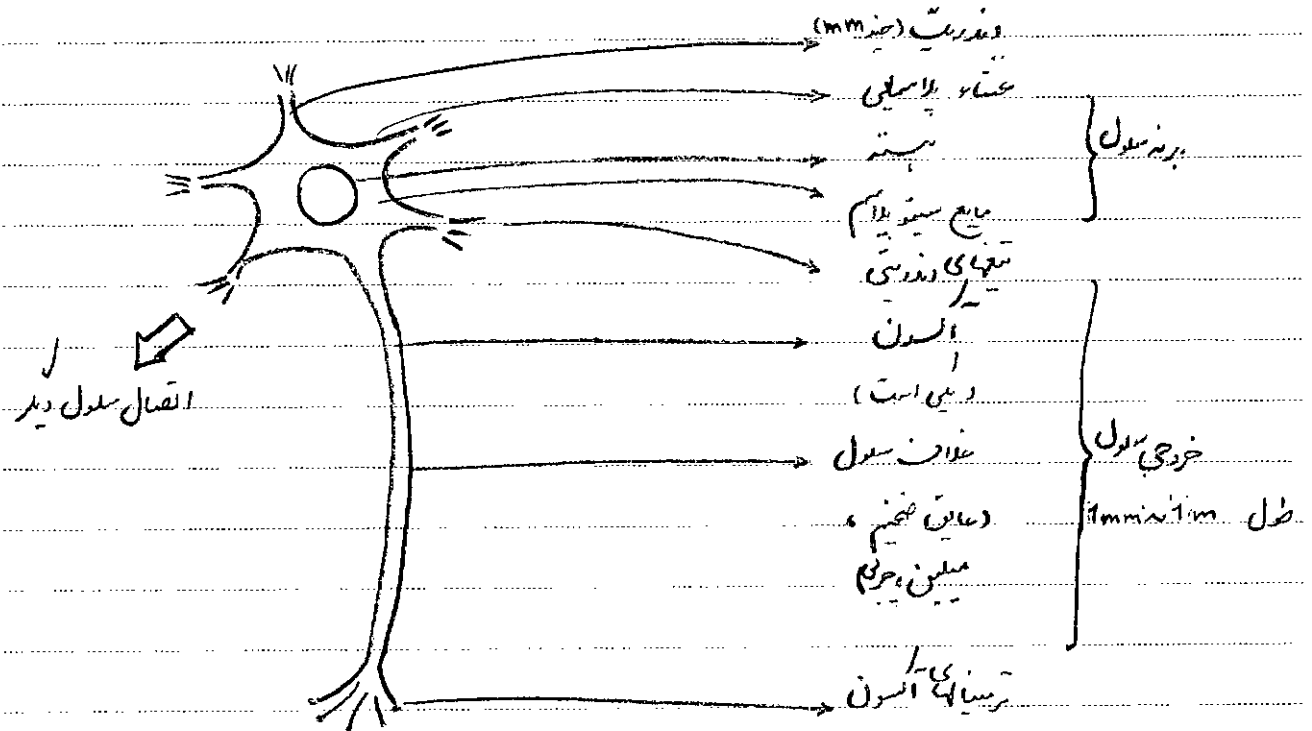
• سازماندهی در مجموعه های لایه ای ← ۶ لایه

• تعداد مجموعه های نوردی ← 10^3 تا 10^4

• تعداد نوردن در هر لایه از مجموعه ← 10^7 تا 10^8

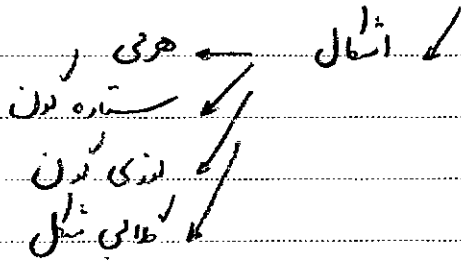
• تعداد نوردن نوردی ← 10^{10} تا 10^{12}

• ساختار نوردن



• مشخصات

تقریباً ۱۰ تا ۱۰۰ میکرون
 اجزای اصلی: دندریت + آکسون + سوما
 Dendrite Axon Soma



• تعداد زیاد رودی + حدالتراب خودگی


• القالات بین رودها ← غیر انسانی ، دینی ، منظم
 که سیم کشی تماماً حساب شده در سطح مقرر
 تعداد القالات

میلین $> 10^4$
 انسان $> 10^{14} \sim 10^{12}$

سیانپس

القالت السنن بی سلال به سلال بعدی
 زنج القالت ← باوذویت بعدی
 اسرن ← با بدنه بعدی

Terminal Button




سلولهای پیش سیانپسی

سلول پس سیانپسی

• درون بدنه سلول
سینولندی
ویوزوم

• علاوه بر فرودها در قشر نخ سلولهای دیگری هم هستند
Glia
نیم طبقه
۱۰ برابر مقدار نورونها
سازنده میلین

• عملکرد میلین
آرایش سربست اتصال سیناپس
عایق کاری خروجی



• خصوصیات الکتریکی

• دلایل
وجود مولکولهای پروتئین، بار منفی در داخل مانع سلولی
که توزیع نابرابر یونهای Na^+ و K^+ در درونی غشاء


• اختلاف پتانسیل در طرف غشاء
 10^{-8} متر = 10^{-2} cm
 $70 \sim 100$ mV
تپانسیل استراحت
که معادل 100 kV در درون سلول cm

• تحریک نورون
مکانیکی، شیمیایی، الکتریکی

• اختلاف پتانسیل
موج، ضربه
تپانسیل فعالیت یک

Subject :

Year . Month . Date . ۸۲



شکل و اندازہ بتائیں فعالیت

ثابت

منتقل از تحریک

تحریک توتیرہ وضعیترہ ۱۲

تحریک توتیرہ

دوبالہ لہر ہے؟ → مودلاسیون مرگلس

توتیرہ → مرگلس بالیتر

سجڑی ایجاد بتائیں فعالیت

پورے → دندوتیا → شکر و صحت مانند
 برایت سینکاپ → بہ سمت دینہ معلول

دینہ معلول → دریافت سینکاپ

کے حد آستانہ

رسون بہ حد آستانہ → نیلک لہر
 انتقال دہ رسون → تسریع ذریعہ مبلین


آرسون → پس از لہر → درہ تحریک ناپذیری مطلق
 تا حدود 1ms

انتقال بتائیں فعالیت میں نودولہ
 در سینکاپ چه اتفاقی می افتد؟

شکاف سیناپسی ← در محل اتصال اکسون و دندوبت

— مراحل —

۱- رسیدن پتانسیل کار به سیناپس ← کسبه ذمی مواد انتقال دهنده - سمت شکاف می رود که کسبه ذمی مواد خرد را تخلیه می کنند.



↑ مواد تخلیه شده به دروازه شکاف نزدیک می شوند این مواد انواع مختلف وجود دارد که در برقراری یک پیوند با آن

۲- اثراتش چیست و در چه ضربی؟ ← نرخ آزاد شدن انتقال دهنده ؟ ↑

۳- مولکولهای گیرنده ← در بافت ماده انتقال دهنده → تلامب شدن / ساختار غشایی و وضعیت قطبی شدن پس سیناپسی تغییر می کند

— مواد انتقال دهنده : محرک / وادارنده / Excitatory

* پتانسیل استراحت سلول دوم ← تا همیشه می ماند

* کاهش اختلاف پتانسیل ← Depolarization

* آماده تر شدن سلول برای تحریک شدن ← کم شدن مانع

* مقدار کم ماده منتقل شده ← و پلازما سولن کم ← پتانسیل وادارنده کم

EPSP : Excitatory Post Synaptic Potential

Subject:

Year: Month: Date: ۱۳

* اثر در زمان سیناپس، سیناپسی مجاور قبل از آنکه اثر EPSP اولیه از بین برود
 یک EPSP دومی، سومی و... ایجاد می‌شود، اثر آنها با هم جمع می‌شوند.
 * مجموع محرک استنادی برود به فعال شدن سلول درام

* تجمع ماده منتقل‌کننده در ناحیه پس سیناپسی - حالت ثابت سلول - محرک محرک
 در بازترانسپورت ثابت
 راه حل طبیعی یار
 آنتزیمی برای سنتز ماده منتقل‌کننده

مادر استمال دهنده: بازدارنده / Inhibitory

* می‌خواهد جلوی فعال شدن سلول بعدی را بگیرد - ایجاد دهنده در سلول بعدی

* اثر این بازترانسپورت سلول پس سیناپسی - Hyper polarization
 کاهش آمپشن و ادبی برای شلیک

* متابول ایجاد شده: متابول بازدارنده پس سیناپسی جزئی

IPSP: Inhibitory Post Synaptic Potential

۴ - شلیک شدن، ایستادن سلول درام - مجمع تمام رخدادهایی که هر لحظه در سلول می‌رود.
 بالاضافه در جایی که دهنده استون برای می‌شود

- سهم همه سلولهای متصل در شلیک شدن این سلول یکسان نیست.

* این سلول + اثرات سلول درام - هزاران سیناپس

عوامل مؤثر در فعال شدن سیدل

- * تعداد سینه‌په‌ی ایجاد شده
- * نحوه سینه‌په نسبت به سیدل پس سینه‌په‌ی
- * طول اندوپیها
- * محل اتصال اندوپیها به بدن ← اتصالات نزدیک‌ترین مؤثرترین

این‌ها ماده منتقل‌کننده در سیدل در نزدیکی سیدل به لیزنده

تجزیه ماده‌ای سینه منتقل‌کننده که در لیزنده ایجاد می‌شود در با آن‌تیم می‌سود لیزین زود

غیر فعال به سیدل شدن آن‌تیم‌ی منهدم‌کننده

غیر فعال شدن سینه‌په‌ی

۱ سم کورار ← اختلال فرآیند ← فلج عضلانی ← صحنی


۲ بازدهی عصبی ← اثراتش مطلقیت مواد لیزنده ← مواد لیزین نمی‌درد ←
تهدیه و اشتباهی وایم عصب ← سرک دردناک

۳ نیکوتین، کشیش، LSD ← داخل با عکس سینه‌په‌ی

* جریان اطلاعات

• روط به تدویردی در سناریی بهم بندی ندهند - حالتیای معقدو مانسبها کنری

• چهار شکل




Diverging

۱- مدل و اجرا

ساختار درختی

جریان دو به پایین
ب نردن پیش سناریی باعث تحریک چندین نردن پس سناریی می شود
که اکثر رستمانیای همی در مفر




Converging

۲- مدل عمل

چندین نردن پیش سناریی باعث تحریک چندین نردن پس سناریی می شود
که نردن Motor ورودی لذستهی مختلف مخرمی کرد

Reverberating - Oscillating

۳- مدل زیانی



تحریک یک نردن پس سناریی در چندین نردن
پس سناریی اثر می تواند
ساختار موازی

که حرکتی عملاتی با جهت برای یافتن متن و ضربان قلب


Subject :

Year :

Month :

Date : ()

Parallel After Discharging - ۳




مدارات موازی پس از تخلیه
یک نوبت پیش می‌بینیم یک سری نودون پس بیندیشید یک نوبت
نهایی ختم می‌شود و تحریک می‌کند
در ارسال موازی یک سری ضربات مربع

© معرفی شبکه های عصبی مصنوعی

* تعریف: ساختار پردازشی توزیع شده دارای به شکل یک لایه پهن است

* ساختار کلی



لایه ورودی (X)

لایه های مخفی

لایه خروجی (Y)

• لایه ورودی: دارو استخوان دودها به آنها به بیج کاری روی سنبل انجام می دهد

$$X: x_1, \dots, x_n \rightarrow \dim(X) = n \times 1$$

• لایه خروجی: خودی های شبکه از گروه های گزینی می شود

$$Y: y_1, \dots, y_m \rightarrow \dim(Y) \neq \dim(X) \\ = m \times 1$$

• لایه های مخفی: نه از ورودی لایه های می شوند و نه از خروجی تعداد آنها از صفر تا بالا

• هر گروه از لایه ها: بدون، اما پردازشگر
هر تعداد ورودی + تنها یک خروجی

خروجی برآمده می‌تواند به تعداد هم مستقل شود.
مستقل این اتصالات به همان در برابر با مستقل خروجی

• هر پیل کران : دارای جهت
الوای وزن ← میزان تأثیر زره بر الی زره مستند

• زره ۶ راب لایه ۶ تقسیم می‌شود

• هر واحد می‌تواند به واحدی لایه خود یا لایه‌های دیگر وصل شود.

• واحدی یک لایه عمدتاً شبیه در نظری لایه‌ها

• عبور سگانه در اتصالات به صورت لحظه‌ای و بدون تأخیر در نظر گرفته می‌شوند.

• عمل واحد؟ ← غیر زمان ← در زمانهای خاصی فعال می‌شوند ← واحد زمان بندی

سنگردن / ایبرودی ← خود جبهه‌های جدید ← در دریاها
وضعیت قبلی واحد

غیر زمان / سنگردن / بویسته
بویسته در حال فعالیت
خود جبهه‌های جدید ← با درایت در دریاها

• معمولاً طیف واحدی بر شعله یا زمان بستند یا غیر زمان

• درهای اتصالات در یک فاز آموزش یا یادگیری معین می‌شوند. ← استاندارد از گذشته می‌باشد
در شعله نشان می‌دهیم.

آمودش


بنا فاعده یادگیری

مقدارهای مقدر > ورودی - خروجی <


تعیین وزنها

* واحدی پردازشگر

مدل McCulloch & Pitts برای نوردهای طبیعی (1943)



خروجی → تابع فعالیت → محاسبه و جداسازی → جمع محرکات در بدن سلول → وزن سناریسی → دوردها



$\omega > 0$ محرک
 $\omega < 0$ بازدارنده
 $\omega = 0$ بدون القاء

1 ب
 0 خنثی

$$y = f \left(\sum_{i=0}^n w_i x_i - \theta \right) = f \left(\sum_{i=0}^n w_i x_i \right)$$

$x_0 = 1$
 $w_0 = -\theta$

ملاحظات شایسته طبیعی (تفاوت مدل، پیچیدگی)

- پاسخ پرسشده - غیر پرمیان

- مجموع غیر خطی از دو دایره

- خروجی در دایره ضرب - پاسخ ثابت

- تأخیر غیر میان - میزان داده انتقال دهنده معیاریت - غیر قابل پیش بینی

هر چنانچه نشان داده شده است که، انتخاب مناسب در این ترکیبی از ورودیها، عملکرد پرمیان

می تواند مسائل محاسباتی خوبی را حل کند.

• واحد های ورودی شایسته


تعیین مدل ورودی شایسته

Activation - Squashing - Transfer - Gain تغییر تابع فعال شدن

کتاب تابع مثال

تابع پله : یک مثال

کامپیوتری قطعه قطعه خطی برای خطی نسبت مربع



$$f(x) = \alpha x \quad \alpha \neq 0$$

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

$$f(x) = \begin{cases} +\gamma & \alpha > \gamma \\ x & |\alpha| < \gamma \\ -\gamma & \alpha < -\gamma \end{cases}$$

$$f(x) = \tanh\left(\frac{\alpha x}{2}\right)$$

$$f(x) = \begin{cases} \frac{x^2}{1+x^2} & \alpha > 0 \\ 0 & \text{o.w.} \end{cases}$$

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

sgn(x) : 1, 0, -1 (ارای مجازات)

برای انتخاب تابع

Subject:

Year:


Month:

Date:

(14)

تابع سیگموئیدی

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




$$\alpha > 0, \alpha \approx 1$$

شتن پذیر: $f'(x) = \alpha f(x) [1 - f(x)]$

تابع سیگموئید باغی (لاصتیب) ↑
تابع لوجستی ←

$$f(x) = \frac{2}{1 + \exp(-\alpha x)} - 1 = \frac{1 - \exp(-\alpha x)}{1 + \exp(+\alpha x)} = \tanh(\alpha x / 2)$$

$$f'(x) = (\alpha / 2) [1 + f(x)] [1 - f(x)]$$



تابع گوسی

برخلاف سایر توابع اشتباع نمی‌شوند

۲- تابع فعالیت متناسب برای هر لایه

می‌توان تابع فعالیت برای هر لایه را نیز متناسب به نظر برد → رایج نیست

۳- ترکیب غیر خطی ورودیها

$$y = f\left(\sum_{i=0}^n w_i x_i + \sum_{k=1}^n \sum_{\ell=1}^n w_{k\ell} x_k x_\ell + k\right)$$

(در قویتر از نوردهی خطی)

۴- واحد های غیر همبند

سیستم در آوردن واحد ← انتخاب آسانی

شبکه تولید

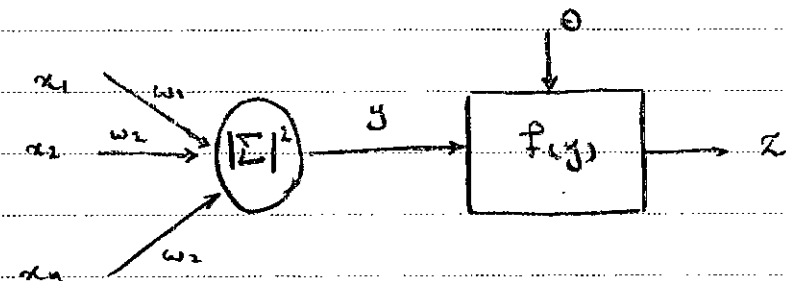
۵- منطق فازی

- ورودی های فازی

- پارامترهای واحد فازی

- فازی در نظر گرفتن ورودی و پارامترهای واحد

۶- نودهای دارای وزنهای مختلف



$$\omega_i = a_i + j b_i$$

$$y = |\omega_1 x_1 + \omega_2 x_2 + \dots + \omega_n x_n|^2 = (a_1 x_1 + a_2 x_2 + \dots + a_n x_n)^2 + (b_1 x_1 + \dots + b_n x_n)^2$$

↓ نودون مختلف بودن درجه ۲ است


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

آستانه‌ی سیلی؟

Subject:

Year: ... Month: ... Date: ... M

۷ - ورودهای سیناپسی



مجموع حاصل‌ضرایب ورودی

$$y = \sum_k \omega_k \prod_i x_i$$


فردان غیر خطی

۸ - ورودهای هم‌بندی


Spiking

ی‌اندک‌ها
خودجی وقتی فعال می‌شود که پتانسیل خودن برابر آستانه‌ی ۵۰ برسد
 P_v

$$P_v = \sum (EPSP) + \sum (IPSP)$$



شلیک سلول پیش‌سیناپسی u در زمان s
پتانسیل P_v در زمان t به اندازه



$$w_{u,v} \times g_{u,v} (t-s)$$

اثری ندارد

$w_{u,v}$ می‌تواند متغیر با زمان باشد

فردان پیش‌سیناپسی پتانسیل برسته خودن پس‌سیناپسی را در زمان t آستانه‌ی حرارتی حدود ۰.۷ mV به طرز تعدیلی تغییر می‌دهد


- 70 mV

+ 50 mV

Subject:

Year: Month: Date: ()

مدتی که در زمان t تولید کرده برای مدت کوتاهی قادر به تولید نیست
که مدل با تابع آستانه‌ای $\Theta_v(t-t')$



تأخیر تولید v

$$f_v(t) = \sum_u \sum_{s \in F_u} \omega_{u,v} \cdot \Theta_{u,v}(t-s)$$

که وابسته به زمان
 F_u : مجموع زمانهای تولید خوردن u
 که برسین $\Theta_v(t-t') \sim f_v(t)$ برزن تولید می‌کنند

Stochastic

۹- زودبندی انسانی

فعال شدن ایشان: احتمالاتی

خودجی خوردن: y → احتمال فعال شدن: $P(y)$

$$y = \begin{cases} +1 & P(y) \\ -1 & 1 - P(y) \end{cases}$$

$$P(+1) = \frac{1}{1 + e^{-I/T}}$$

T : دمای انتقالی سطح نور یا میزان عدم قطعیت

$$I = \sum \omega_i \cdot x_i \leftarrow \text{Net Input} : I$$

* دسته بندی فزودینامی مهندسی به سه نسل

نسل 1

خودجی در تطبیق /
بر اساس مدل مدالال و پیر
ک پرسپترون ، آپنیلد ، برلترمان

نسل 2

خودجی بویسته
توابع منطقی ، تعداد واحدی ترکیب نسبت به نسل اول پایه سازی می شود.
MLP ، RBF ، بازخشی

نسل 3

خودجی ضرب
نزدیکتر به فزودینامی طبیعی

* رفتار دینامیکی واحد

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

x_j : سیگنال ورودی بویسته ← محاسباتی لحظه ای ضربات دریافت شده
 y_j : متغیر بویسته ← فعالیت نورون

در حالت تعادل

$$\frac{dy}{dt} = 0 \rightarrow g(y) = I \rightarrow y = g^{-1}(I)$$

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

Subject:

Year: Month: Date: ()

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

✓

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

* اتصالات شبکه

• انواع همبندار = لبه = جهت جریان اتصالات

• انواع درختار = وزن = میزان تاثیر = تعیین شدن در فاز سادگی یا آموزش

• طراحی شبکه عصبی : همبنداری ← دربر لایه میگذارد ← تعیین درختار ← آموزش


• نوع داده ای درختار : صحیحی ، مختلف ، فازی ، ...

- $\omega > 0$ → محکم ، یادآورنده
- $\omega = 0$ → وزن اتصال ، بی تاثیر
- $\omega < 0$ → حمایت کننده ، یادآورنده

• نمایش اتصالات با ماتریس اتصالات

$$M_{n \times n} = [m_{ij}]$$


$$m_{ij} = \begin{cases} 0 & \text{اتصال از واحد } i \text{ به واحد } j \text{ وجود ندارد} \\ 1 & \text{وجود دارد} \end{cases}$$



• ماتریس وزن شبکه فرج ۱ : ثابت ← مورد استفاده در این اوس

برای شبکه به این لایه ← اتصالات یک لایه به لایه بعدی نشان می دهد

$$W_1 = [\omega_{ij}] \rightarrow \omega \quad \text{مقدار} \rightarrow \text{مقدار}$$



وزن اتصال از واحد i به واحد j = ω_{ij}

• ماتریس وزن شبکه نوع ۲ : همبستگی بین

اتصالات یک لایه از لایه قبل نشان می دهد

$$W_2 = [\omega_{ij}] \rightarrow \omega \quad \text{مقدار} \rightarrow \text{مقدار} \quad ; \quad W_2 = (W_1)^T$$

وزن اتصال به واحد j از واحد i = ω_{ij}

• انواع اتصالات بین واحدها

Full

۱- اتصالات کامل

از هر خروجی به تمام واحدهای لایه قبل

Uniformly Random

۲- اتصالات تصادفی یکنواخت

هر واحد بخود معینی ورودی از لایه قبل

انتخاب اتفاقی و با توزیع یکنواخت ← نحوه انتخاب بیشتر در نتیجه

۳. انفصالات یک به یک
هر واحد انفصال از لایه قبل

۴. انفصالات با توزیع خاص (افزاینده)
برقراری انفصالات به توزیع خاصی وابسته اند ← توزیع لایه

* معماری شبکه های عصبی

Feed Forward

• بدون بازخورد ، پیش خور ، حلوسو

کوان : فاند میر بسته
بدون فیدبک ← استایب ← دریاخ به ورودی تنها یک دسته خروجی ایجاد می شود

دریاخ مستقل از حالت فعلی
بدون حافظه ← حالت قبلی نشتی ندارد

Recurrent

• دارای بازخورد ، باز نشی

کوان : دارای میر بسته
دارای فیدبک ← دریاخ ← پس از اعمال ورودی ، خودجهای مشخص می شود
سپس از طریق میر فیدبک به ورودیها اعمال می شود (پویا)

امکان ناپایداری ← به علت وجود فیدبک
عدم همگامی هندرجی ← به ورودی می بخندد
بجده تر ← نویز

Classification

© دسته بندی

* مفردات

• بسیاری از ادوات انسان ← از طریق دسته بندی شناسایی می شود.

• یادگیری معنای اشیا با استفاده از نمونه های مشخص از دسته \rightarrow classifier
یادگیری + دسته بندی

• پس از یادگیری ، دسته بندی کننده با دریافت هر ورودی جدیدی توانمند تقسیم می شود که این ورودی به کدام دسته معنای دارد.

• عمل دسته بندی \equiv انتخاب بندی هنگام ورودی بر روی دسته بندی کننده

* نازدهی دسته بندی

۱- آموختن یادگیری


ورودی : نمونه \rightarrow پاسخ صحیح به نمونه
خروجی : یادگیری دسته بندی کننده

۲- آزمایش الگوریتم


ورودی : ورودی جدید
خروجی : شناسایی ، تعیین دسته
نهایت : یادگیری دسته بندی کننده

* ورودیها و خروجیهای دسته بندی کننده لزومی ندارد تعیین می شود.

* انواع مدل دسته بندی



• مدل دسته بندی
 تعلق (عدم تعلق) - برآمده
 پیاده سازی با شبکه عصبی: یک خروجی



• مدل دسته بندی
 m دسته - تعلق برآمده 1
 تعلق برآمده m
 پیاده سازی با شبکه عصبی: m خروجی
 یک خروجی یک طبقه هنوز

□ در دستار: رزنه بردار با قابلیت؟ (حتماً یکی از این دو)

بافت: ساختن دستگاهی برای تعیین این دو

بیماری: یک فرد - یک خروجی (بیمارستان)

رودها: انتخاب درختی - یک چیزی تا برای ایجاد می کند - (اندازه بهتر است؟)

تد، وزن، اندازه در لمر، ... (بیمارستان)

آزمایش: اندازه گیری تعداد وزن تعداد زیادی رزنه بردار و قابلیت (مختص رودی)




تعیین خط (یا مرز) برای تقسیم عموماً
 آزمون ← ناخودآگاهی

Subject:

Year. Month. Date. ۲۲

حل مسئله:



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

$$\underline{X} = \begin{bmatrix} 1 \\ x_1 \\ x_2 \end{bmatrix}$$

$$\underline{W} = \begin{bmatrix} -\theta \\ w_1 \\ w_2 \end{bmatrix}$$

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

\underline{w} رفتار آموزش تعیین می‌شود
 خط جداکننده
 مقدار x_1 و x_2 در سمت I را مثبت می‌کنند، و مقدار x_1 و x_2 در سمت I را منفی می‌کنند، و مقدار $I = 0$

$$-\theta + w_1 x_1 + w_2 x_2 = 0 \rightarrow x_2 = -\frac{w_1}{w_2} x_1 + \frac{\theta}{w_2}$$

(معادله خط)


* خطی جداپذیر
 اگر فضای مسئله به گونه‌ای باشد که همه نمونه‌های یک دسته در یک طرف خط جداپذیر و نمونه‌های دسته دیگر در طرف دیگر خط باشند.

linearly Seperable

مسئله‌ی دایریت نشان دادند که مسئله‌ای که به صورت خطی جداپذیر باشد با واحد پرسپترون قابل حل است.

XOR

خطی جداپذیر نیست ← غیر قابل یادگیری با پرسپترون



* واحد های پردازش

Hebb

۱- واحد هب

• عصبی ترین - ساده ترین

• نظریه روانشناسی - هب

• در سده های طبیعی هرگاه فردی i به طور مکرر و مداوم در فعال بودن فردی j

شرکت کند، میزان تأثیر این فرد بر فعال بودن فردی j افزایش می یابد.

سه وزن

• قانون یادگیری هب ← فعال شدن فردی i همراه است با فعال شدن j

Coincidence

که یادگیری هم رونویسی

• اهریتم

I. مقدار اولیه در زمان تکلیفی می شود.

$$\omega_i = 0, \quad i = 0, \dots, n$$

II. برای هر زوج نمونه $\langle s, t \rangle$ درهای III و IV را در نظر

$\langle s, t \rangle$ → زوج آموزش

s → دردی آموزش شده source

t → مقدار مطلوب خروجی target

نمای آموزش

III. به دردهای ورودی و خروجیها مقادیر نمونه داده می شود.

$$\begin{cases} x_i = s_i, & i = 1, \dots, n \\ y = t \end{cases}$$

IV. در زمان به حدت زیر اصلاح می شود.

$$\omega_i \text{ (new)} = \omega_i \text{ (old)} + x_i \cdot y, \quad i = 0, \dots, n$$

• برای تغییر وزن، هرودی y باید غیر صفر باشد

• در سال ۹۸، یک طبله در راهپایهات قانون بیب استرسش دادند — برگاه در فونین
خاندین باشند نیز ارتباط آنها به تقویت منور.

Perception

۲- واحد پرسپترون

• روزنیلات

Perception + Electronics


• اولین دستگاه

Mark I Perception

شبیه سازی شبکه انسان
کاربرد برای شناسایی حرف

توراب 20×20 از عناصر کردند — ۴۰۰ سینال
شبه علمی بدلا

تنظیم وزنها — ۵۱۲ تا پیوسته متغیر به کمک پرونده الکترونیک
اتصالات بعدی یک عنصر قابل دسترسی



تنظیم وزنها، قانون پرسپترون
وزنها بجز اتفاقی می از سه مقدار: 0, 1, -1

• سه دسته بندی در دستهای: دسته A ($y=0$), دسته B ($y=1$)

• t مقدار مطلوب آموزش ← $\langle s, t \rangle$ ← $s = X$

• محلی برای لایه اول مقدار مطلوب مشخص نیست، مقدار آنها اتفاقی انتخاب می شود.

Subject:

Year: Month: Date: ()

معادله یادگیری پرسپترون

$$\underline{W}(\text{new}) = \underline{W}(\text{old}) + (t - y) \underline{X}$$

اشارت می شود که این الگوریتم در یک تعداد عملیات محدود، مرتبه درستی در خطی جدا می پذیرد.
 سینه یادگیری کند. ← با هر تکرار اولیه

اصلاح وزن

$$t - y = \begin{cases} 1 & \rightarrow B = \text{صحیح} & A = \text{اصلاح} \\ 0 & \rightarrow & \text{اصلاح} = \text{صحیح} \\ -1 & \rightarrow A = \text{صحیح} & B = \text{اصلاح} \end{cases}$$

سینه دیگری از الگوریتم پرسپترون ← مینی می و پاریت

$$\underline{W}(\text{new}) = \underline{W}(\text{old}) + \alpha (t - y) \underline{X}$$

$$0 < \alpha < 1$$



α را

$$\alpha = \frac{\underline{X} \cdot \underline{W}}{\|\underline{X}\|^2}$$

$$\text{یا } \alpha = \frac{1}{\|\underline{X}\|}$$

درمی که برای اصلاح برداشته می شود متناسب است با ورودی

یادگیری پرسپترون درجه ۱: جداسازی




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

Subject: _____



Year: _____ Month: _____ Date: ۲۴

باید ۵۰ یا مقدار اولیه ای قرار داد ← خطی در صورتی خطی می کند




جواب نهایی: وقتی برای هیچ کدام از دیتاها تغییر نکند

یکپسردن درجه ۲



$$I = w_0 + w_1 x_1 + w_2 x_2 + w_3 x_1^2 + w_4 x_2^2$$

خطی جدا ناپذیر




Adaline

۳- واحد ادالاین

• وینراد ۱۹۵۹

• Adaptive linear



P4PCO

x Least Mean Square W خطی خطی

Subject:

Year:

Month:

Date:

()

• پیاده سازی اولیه ← آرانه ای از سوییچها ، تعداد آنها و مشخصه های اندازه گیری

• ورودیها ← باینری / پیوسته
وزن ← مثبت / منفی / حقیقی

• تعیین وزن ← LMS ← کمینه کردن متوسط خطای که جواب میده

$$I = w_0 x_0 + w_1 x_1 + \dots + w_n x_n = \underline{X} \cdot \underline{W} = \underline{X}^T \underline{W} = \underline{W}^T \underline{X}$$

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

• تابلو یادگیری آدالاینس

• جدولی میده با شروع از هر نقطه
کمینه یا بیشینه کردن تابع عملکرد

جزء تدافین Performance Learning

• فرآیند ریاضی

\underline{X} → تعداد: N → p : پیمایی

$$\underline{W} \rightarrow F(\underline{W}) = \min$$

$$F(\underline{W}) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N (t_k - I_k)^2 = E[(t_k - I_k)^2]$$

$$F(\underline{W}) = E[(t_k - I_k)^2] = E[(t_k - \underline{W}^T \underline{X}_k)^2]$$

$$= E[t_k^2 - 2 t_k \underline{W}^T \underline{X}_k + \underline{W}^T \underline{X}_k \underline{X}_k^T \underline{W}]$$

$$= E[t_k^2] - 2 \underline{W}^T E[t_k \underline{X}_k] + \underline{W}^T E[\underline{X}_k \underline{X}_k^T] \underline{W}$$

$$= P - 2 \underline{W}^T Q + \underline{W}^T R \underline{W}$$

P, Q, R

مقدار ثابت

بردار

ماتریس


F P, Q, R لادی عونه ۶ قابل محاسبه است. \leftarrow دیت تعیین w بر اینجه بران

$F(w)$ \leftarrow نرم درجه ۲ لادی w

متوازن R

$\forall x: \sum \sum r_{ij} x_i x_j \geq 0$ \leftarrow مثبت نیمه معین

w^* ضرایب منفی نمی شوند \leftarrow تقو درجه بالا \leftarrow دارای کمینه



سپایه بران w^* \leftarrow مثبت

$\nabla_w F(w) = -2Q + 2Rw = 0 \rightarrow$

$Rw^* = Q \rightarrow w^* = R^+ Q$

مطلوبین تعیین یافته R^+ \leftarrow مثبت معلوم

R معلوم پذیر

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

$w^* \sim$ کمینه \Rightarrow بهار \sim سطح خطا

R معلوم ناپذیر

ناهموار \sim سطح خطا

نزدیکترین کمینه \sim مبدأ تحقیقات $\sim w^*$

• دیتای بردار R و Q → پیش‌پردازش ویدیو و صدا

w^* را به شروع لایر نقطه اولیه و باین آدن روی سطح عملگر یادگیری
نزدک آوردن کلاسیک از جهت بیشترین کاهش برآورد رسیدن به مینیم

$$- \nabla_{\underline{w}} F(\underline{w})$$

$$\nabla_{\underline{w}} F(\underline{w}) = \nabla_{\underline{w}} \left[\lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N (t_k - I_k)^2 \right]$$

$$= \lim_{N \rightarrow \infty} \left[\nabla_{\underline{w}} \sum_{k=1}^N (t_k - I_k)^2 \right]$$

$$= \lim_{N \rightarrow \infty} \frac{1}{N} \left[\sum_{k=1}^N 2(t_k - I_k) \nabla_{\underline{w}} (-I_k) \right]$$

$$= \lim_{N \rightarrow \infty} \frac{1}{N} \left[\sum_{k=1}^N 2 \delta_k \nabla_{\underline{w}} (-\underline{w}^T \underline{x}_k) \right]$$

$$= \lim_{N \rightarrow \infty} \frac{1}{N} \left[\sum_{k=1}^N 2 \delta_k (-\underline{x}_k) \right]$$

$$= -2 E[\delta_k \underline{x}_k]$$

ویدیو و صدا تقسیم رشد بجای $E[\delta_k \underline{x}_k]$ از هر $\delta_k \underline{x}_k$ و تقسیم \underline{w} استانه
نشد

$$\underline{w}_{k+1} = \underline{w}_k + \alpha \delta_k \underline{x}_k$$

قانون دلتا

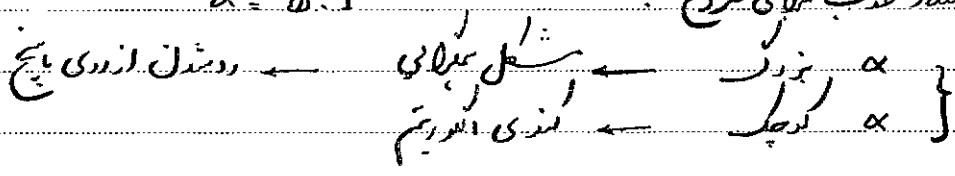
$$0 < \alpha < \frac{2}{\text{بزرگترین مقدار ویژه } R}$$

که قانون ویدیو و صدا، قانون ویدیو و صدا LMS

α ایسی دقت می‌دهیم R

مقدار معمول α : $0.01 \leq \alpha \leq 10$

مقدار جذب برای شروع : $\alpha = 0.1$



پیشینه ورودی در ۱۹۸۸ : (n : عدد ورودی) $\frac{1}{10n} \leq \alpha \leq \frac{1}{n}$

Batching

نسخه آموزش دستهای آدالاین

عدم تغییر w با اعمال مجددی X
 پس از تعداد زیادی X در w ثابت بیشتر اعمال می شود، بهنگام برآورده شود
 بهنگام سازی
 که متوسط گیری برداری $\delta_k X_k$ در بهنگام سازی w

Momentum


نسخه استفاده از ممنتوم در آدالاین
ممانت در برابر تغییرات زیاد

$$w_{k+1} = w_k + \alpha (1 - \mu) \delta_k X_k + \mu (w_k - w_{k-1})$$

$$\mu \gg \alpha \rightarrow \mu = 0.9 \ \& \ \alpha = 0.01$$

این نسخه \rightarrow در برداری کمتر، در برداری بیشتر
ممانت عملکرد نه چندان زیاد

با ممانت



Subject:

Year: ..

Month: ..



Date: ..

..

چون ترکیب سطحی در دو لایه انجام می‌گیرد
نیوزانده مسائل غیر سطحی محدودی پذیرا عمل کند

آرالاین نیز سطحی است

آرالاین درجه دو



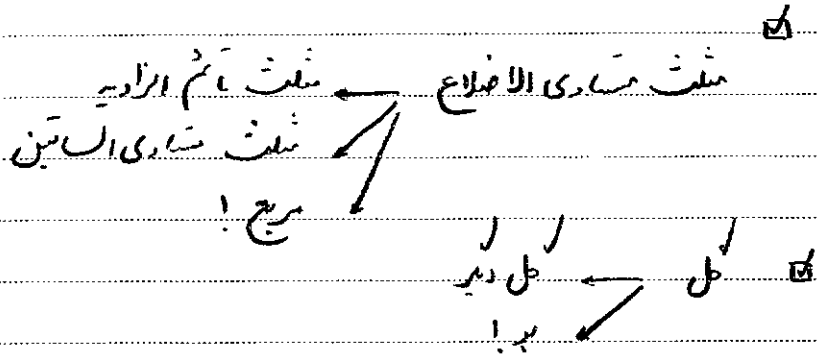
آرالاین درجه دوم

② تداعی الگوی و شبدهای تداعی در خط

* یادگیری : تشکیل تداعی بین الوده

* در وسط معتقد است که زمین انسان مطالب ① بر خلاف یادگیری ② از لحاظ زمانی / نزدیک بر یادگیری ③ شبیه به هم ④ به طور متوالی واقع شده اند و با هم مرتبط می شوند

* الوده‌ای ورودی و تداعی شده ممکن است لذت نفع باشند یا از انواع مختلفی باشند



* تداعی در انسان
الوده الوده تحریک شبیه الوده از جمله دیده باشند هم الوده با شیخ تداعی می سرزد
ورود الوده یقین لازم نیست.

کتابشناسی الوده علمی

* بدت : تداعی طریقم وجود خطا

* شبدهای تداعی در ، (مجموعی ، متداعی ، اشتباه ، یادآور

Linear Associative Networks

Associative Networks

Subject:

Year:

Month:

Date:

()

* تعریف ریاضی

$$\psi : \underline{x}_i \longrightarrow \underline{y}_i \quad i = 1, 2, 3, \dots$$

$$x_i \in \mathbb{R}^n$$

دودی

$$y_i \in \mathbb{R}^m$$

خروجی

نماست

$$\underline{y}_i = \psi(\underline{x}_i)$$

* دسته بندی اول شبکه های متداعی بر اساس

Feed Forward

۱- پیش خود : بدون بازخورد

Recurrent

۲- بازگشتی : دارای بازخورد

له خروجی بر نردن بر دودی لایه قبل

* دسته بندی دوم شبکه های متداعی بر اساس یاد آوری

Autoassociative

۱- خود متداعی (خود یاد آوری)

$$\underline{y}_i = \underline{x}_i \quad m=n$$

Heteroassociative

۲- غیر خود متداعی (دگر یاد آوری)

$$\underline{y}_i \neq \underline{x}_i$$

• در شبکه های خود متداعی پردازش آموزش الگوریتم دودی زنجیری که قبلاً بدون نویز آموخته شده آموزش داده بدیم تا به شبکه بهیم ، دودی بدون نویز را در خروجی تولید می کند

• در شبکه های غیر خود متداعی پردازش آموزش الگوریتم دودی زنجیری که قبلاً بدون نویز آموخته شده آموزش داده بدیم تا به شبکه بهیم ، دودی بدون نویز را متداری تغییر داده و در خروجی تولید می کند

Subject: _____

Year: _____ Month: _____

Date: ۲۸

* دسته بندی سوم شبکه های تداعی بر اساس لحاظ تعداد

Assertive

۱- تکبارنده

$$\varphi(x_i + \varepsilon) = y_i$$

خطای کوچک: ε

Interpolative

۲- دروناب

$$\varphi(x_i + \varepsilon) = y_i + \sigma$$


$$|\varepsilon| \rightarrow 0 \Rightarrow |\sigma| \rightarrow 0$$

* شبکه تداعی در پیش خود

• لایه ورودی: به تعداد ورودی هر لایه درون دارد.
 • لایه خروجی: به تعداد ورودی هر لایه درون دارد.

• اتصالات کامل: هر خروجی = ترکیب خطی از ورودیها

• معاری



$$\underline{X} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad \underline{Y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{bmatrix} \quad \underline{T} = \begin{bmatrix} t_1 \\ t_2 \\ \vdots \\ t_m \end{bmatrix}$$

$$\underline{W}_i = \begin{bmatrix} w_{1i} \\ w_{2i} \\ \vdots \\ w_{ni} \end{bmatrix}$$

وزنه های لایه بردار ورودی

$$\underline{W} = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1m} \\ w_{21} & w_{22} & \dots & w_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ w_{n1} & w_{n2} & \dots & w_{nm} \end{bmatrix} = [\underline{W}_1 \ \underline{W}_2 \ \dots \ \underline{W}_m]$$

$\underline{X} \quad \underline{W} \quad \underline{T} \quad \underline{Y}$

$$\underline{Y} = \underline{W}^T \underline{X}$$

Subject:

Year: Month: Date: ()

شبهه ← عملکرد درون‌یار

ار ما زوج $\langle s_i, t_i \rangle$ به ازای $k = 1, 2, \dots, k$ برای آموزش

شبهه به کار روند پس از پایان آموزش، ورودی $\underline{x}_k = \underline{s}_k$

به شبهه اعمال شود، خروجی باید برابر $\underline{y}_k = \underline{T}_k$ گردد اما در ورودی

$\underline{x}_k = \underline{s}_k + \underline{\epsilon}$ به شبهه داده شود، خروجی باید برابر $\underline{y}_k = \underline{T}_k + \underline{\delta}$ گردد

آموزش شبهه ← تا این باب

$$\underline{s}_k = \begin{bmatrix} s_{k1} \\ \vdots \\ s_{kn} \end{bmatrix} \quad \underline{T}_k = \begin{bmatrix} t_{k1} \\ \vdots \\ t_{kn} \end{bmatrix}$$

کمین زوج آموزش

$$W(\text{new}) = W(\text{old}) + \underline{s}_k \underline{T}_k^T$$

$$= s_1 \underline{T}_1^T + s_2 \underline{T}_2^T + \dots + s_k \underline{T}_k^T$$

$$= \sum_{i=1}^k s_i \underline{T}_i^T$$

⊛ مقدار اولیه رزنها برابر همفر ← آموزش با k زوج نمونه

$$w_{ij}^{\text{new}} = w_{ij}^{\text{old}} + s_k + t_{kj}$$

آیا این آموزش رفتار در نهایت و بازایا. چگونه ادا به صورتی انجام می دهد؟

یک ورودی S_k که با یکی از ورودی های آموزش به نسبت در نظری لایم داریم

$$\underline{W}^T \underline{S}_k = T_1 S_1 S_k + T_2 S_2 S_k + \dots + T_k S_k S_k + \dots + T_L S_L S_k$$

این باید برابر T_k شود. (ورودی S_k باید خروجی T_k بدهد) پس باید:

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

یعنی مجموعه های ورودی S_i باید متعامد (orthogonal) باشد.

این شرط بسیار محدود کننده است ← برداری در ردی متعامد

بردارهای ورودی باید

همدالته تعداد ورودی قابل ذخیره محدود

تعداد بردارها \rightarrow فضای n بعدی

تعداد بردارهای متعامد که در فضای n بعدی $n =$ فضای سه بعدی: ۳

برای ما مطلوب است که بتوانیم هر تعداد از دلخواهی ورودی و خروجی را داشته باشیم.

بجز شرط متعامد:

$$\underline{W}^T \underline{S}_k = T_k + \sum_{j \neq k} T_j \underline{S}_j^T \underline{S}_k = T_k + \eta$$

جنگای بازایا T_k

Subject:

Year: Month: Date: ()

w باید به نحوی انتخاب شود که η کوچک باشد

آموزش با حداقل کردن متوسط مربع خطا

ماتریس متجه‌ای S : $S = (S_1, S_2, \dots, S_L)$

$T = (T_1, T_2, \dots, T_L)$

متوسط مربع خطا $F(w) = \frac{1}{L} \sum_{k=1}^L |T_k - w^T S_k|^2$

نرم ماتریسی $F(w) = \frac{1}{L} \|T - w^T S\|^2$

بهی حداقل کردن $F(w)$

$$F(w) = 0 \rightarrow w = (TS^+)^T$$

محدودیت در درجهها \leftarrow متجه خطی بودن $(S^+S = I)$

$$S^+S = I \rightarrow F(w) = 0 \rightarrow \psi(x_i) = y_i$$

S^+ : شبه معکوس، معکوس تعمیم یافته S

محدودیت محدودیت متجه خطی بودن:

$$S^+S \neq I \rightarrow \underline{S}_i = \sum_{i+j} \alpha_j \underline{S}_j$$

Subject:

Year: Month: Date: ۶۵

$$W^T S_j = \sum_{i \neq j} \alpha_i \quad W^T S_i = \sum_{i \neq j} \alpha_i T_i$$

اگر بخواهیم $F(W) = 0$

$$F(W) = 0 \rightarrow T_j = \sum_{i \neq j} \alpha_i T_i$$

یعنی همان رابطه خطی S_i باید در T_i نیز وجود داشته باشد. در غیر این صورت

$$W^T S_i \neq T_i \Rightarrow F(W) > 0$$

Singular Value Decomposition

تجزیه مقدار منفرد

بر ماتریس $S = n \times h$ ، $n \leq h$ را می توان به صورت زیر تجزیه کرد:

$$S = \sum_{i=1}^h \sqrt{\lambda_i} \underline{P}_i \underline{Q}_i^T$$

$\underline{Q}_i : h \times 1$ ، $\underline{P}_i : n \times 1$ ← مجموعه بردارهای ویژه متعامد پایه در ماتریس

$$S^T S : h \times h, \quad S S^T : n \times n$$

λ_i : مقدار ویژه که از جدول به لایحه مرتب شده اند (اعداد صحیحی، غیر منفی)

$$S^+ = \sum_{i=1}^r \frac{1}{\sqrt{\lambda_i}} \underline{Q}_i \underline{P}_i^T$$

$r \rightsquigarrow$ rank: مرتبه ماتریس S ، تعداد ویژه غیر صفر، تعداد سطری غیر صفر، تعداد ستونی غیر صفر

Subject :

Year : Month : Date : ()

مجموعه‌ای در شریک غیر قابل S^+ غیر قابل

مجموعه‌ای در شریک $S^T \leftarrow n > k$ قابل تجزیه

مجموعه‌ای در شریک \square 2

تأثیر یادگیری ویدرو

اثبات با روش Greville

$$W(\text{new}) = W(\text{old}) + \alpha \underline{S}_k (T_k - W^T(\text{old}) \underline{S}_k)^T$$

$$W_i(\text{new}) = W_i(\text{old}) + \alpha \left[\underbrace{(t_k - (W_i^T(\text{old}) S_k))}_{\text{خطا}} S_k \right]$$

آموزش به دفعات متوالی در صورت آسانی پذیرا است

α کوچک و مثبت

کسر عمل کردن با داشتن $e \neq 0$ به واسطه \leftarrow نتیجه

Recurrent Associative Networks

شبدهای تداعی گریز بازگشتی

* رفتار نگهدارنده (Assertive)

اگر دودی اندکی تغییر کرد، سعی می کند خودی را نگه دارد.

* سیر بازگشتی

خودجی به دودی متصل است.

سند بیداری

* این شبده عموماً از یک نقطه اولیه شروع می کنند و به این از نقاط بیدار شبده می شوند.

سعی می کنیم با پنجهای ما در این زمینه باشد.

* در طراحی این شبده مورد نظر است:

I، شبده از هر نقطه که شروع به کار کند باید به این از حالات بیدار برسد.


II، حالت بیداری که شبده به آن می رسد باید سرچشمه نوعی معیار تشخیص نزدیکترین حالت بیدار به حالت اولیه باشد.

III، باید بتوان هر تعداد حالت بیدار که مورد نظر باشد به یک شبده ایجاد کند.

* عملکرد شبده بازگشتی تداعی های توان به یک سیستم سازنده محدود تشبیه کرد که توان

بر تعداد کمه جذب کننده در هر نقطه از جاذبه از فضای n جوی مدار داده شود. نوری جاذبه

بر کمه تنها به فضای اثر دارد که به آن کمه از سایر کمه نزدیک است. ما شبیه به این ترتیب




شرح می شود که یک جسم آزمایشی در این فضا مدار داده می شود.

جسم به حرکت درآمده به نزدیکترین کمه جذب می شود.

* در طراحی شبده های بازگشتی مدارهای ساده، تنها یک اول تأمین می شود.

* معماری طی شبده های بازگشتی مدارهای تک لایه

الفصلات کامل



• ماتریس درونها متعادلی

• ماتریس درونها با تاملین سبب یقین می شود

• عناصر قطری: همز (تزدلیت به متواحد می شود) یا غیر همز

• تاریخ شد آیه ورودها بطور نامحدود بزرگ می شود → تابع سختی فعالیت
 که باید محدود شود.

* (BSB) Brain State in a Box

• اندرسون ۱۹۷۷

• n واحد + اتصالات بازگشتی


• ورودی \propto تنها به حالت : که اعمال می شود:

• تابع فعالیت → تنها متادبر داخل یک ابرمربع $[-1, +1]^n$

• سیستم در آدن واحد : بزرگان (سنگین) → اصلاح در زمان سیستم رسیدن به حالت پایدار

• اتصالات : کامل یا غیر کامل ابتدایی

• حالات پایدار : رتوس ابرمربع
 اولیه : نقطه ای داخل ابرمربع
 (نقشه سنج)



• در زمان متادبر اولیه : کوچک
 سیستم زمانی : سیستم رسیدن به حالت پایدار

الدرستم BSB

①. وزنها = مقدار پیراچر ابتدایی
نرخهای یادگیری α و β = مقدار پیراچر اولیه

1. به ازای هر بردار آموزشی \underline{S}_i

2. $\underline{y}_i = \underline{S}_i$ (مقدار اولیه خروجی برابر بردار ورودی)

3. تا زمانی که خروجیها برابر نشده اند

4. محاسبه خود همبستگی مخفی

$$I_{ij} = \omega_{ij} z_j - y_i \sum_{j \neq i} z_j$$

مقدار اتصال یادگیری از خروجی خود واحد i برابر 1 است

$$y_i = \begin{cases} -1 & \text{if } I_{ij} \leq -1 \\ 1 & \text{if } 1 < I_{ij} \\ 0 & \text{if } -1 < I_{ij} \leq 1 \end{cases}$$

5. خروجی

6. اصلاح وزنها (قانون سب)

$$\omega_{ij}(\text{new}) = \omega_{ij}(\text{old}) + \beta y_i z_j$$

مربوط به خروجی اندکی که در دوری آن نیز هستند
دورهها تقابلی \leftrightarrow آبر ملقب

• هر حالت پایدار α stable دارای یک زوج اضافی α stable - نیز خواهد بود.


← این در واقع درودی ω دارای وزن ω ، حذف حالات اضافی

• اصلاح وزن با قانون ویلارد $W(new) = W(old) + \eta \sum (y^d - y^a)^T$

* شبکه های تغییر

• معماری ← اتصالات کامل ← معمولاً وزن فیدبک به خود برابر است

← هر درودی تنها یک واحد ← دردیها مانند وزن



• جان ؟ پیلد ۱۹۸۲

$w_{ji} = w_{ij}$
 $w_{ii} = 0$

• اتصالات بازگشتی ← درونی متساوی
← خود اتصالی ندارد

• نسخه گسترده ← حالات شبکه در مقادیر باتری
در تقابلی $[0, +1]$
 $[-1, +1]$

• نسخه نویسی تعدادی در بازه $[0, +1]$

• هنگام بردار کردن \rightarrow آستانه \rightarrow انتخاب واحد انتخابی
 \downarrow
 آستانه

• ورودی از خارج به هر واحد این است \rightarrow ثابت تا نسخه نویسی
 \downarrow
 آستانه در متن جدول از این هنگام سازی

• مقدار آستانه ای واحد \rightarrow صفر یا غیر صفر

• انتخابی محمل \rightarrow هنگام سازی تا زمان
 \downarrow
 آستانه
 \downarrow
 مقدار صفرهای آستانه

• هنگام سازی تا زمان یک تابع انرژی با لیدرینف می توان برای شبکه پیدا کرد.

• نسخه نویسی آستانه می شود. (درش آستانه در توری سیستم ای غیر خطی)

• تابع تبدیل واحد
 در قطبی

$$y_i(\text{new}) = \text{Case} \left(\sum_j w_{ij} x_j \right) \begin{cases} > \theta_i : +1 \\ = \theta_i : y_i(\text{old}) \\ < \theta_i : -1 \end{cases}$$

• انرژی

$$\text{Case}(\sim) < \theta_i \rightarrow y_i(\text{new}) = 0$$

• هر واحد: ابرصنوی ای در فضای حالت $\langle \underline{w}_i, \theta_i \rangle$

$y_i(\text{old})$ - سمت مثبت ابرصنوی $y_i(\text{new}) = +1$

$y_i(\text{old})$ - سمت صیب ابرصنوی $y_i(\text{new}) = -1$ / 0

$y_i(\text{old})$ - روی ابرصنوی (عبارت از حالت پایدار) $y_i(\text{new}) = y_i(\text{old})$

جای سبلیری از عبور ابرصنوی از حالات پایدار، می توان برود وزن \underline{w}_i را به طری

جزئی تغییر داد. بر این ترتیب دیگر حالت سازی پیش نمی آید. پس:

$$\text{bipolar} : y_i(\text{new}) = \text{sgn} \left(\sum_{j=1}^n w_{ij} y_j(\text{old}) - \theta_i + \alpha_i \right)$$

$$\text{binary} : y_i(\text{new}) = u \left(\sum_{j=1}^n w_{ij} y_j(\text{old}) - \theta_i + \alpha_i \right)$$

تابع پله

• اگر α_i تنها در لحظه فعال شدن اعمال شود، $\theta_i = 0$:

$$y_i(\text{new}) = \text{sgn} \left(\sum_{j=1}^n w_{ij} y_j(\text{old}) \right)$$


• نای انرژی (Energy landscape)

تک - اشات سبلیری شبکه و پهنی - تابع انرژی به تابع پایداری

تابع پایداری ← تابع محلی انرژی
از پایین گراندار

Subject: _____

Year: _____ Month: _____ Date: _____ ()



تابع ارزی: E بسبب

$$E = -\frac{1}{2} \sum_{i \neq j} \sum_j \omega_{ij} y_i y_j - \sum_i \alpha_i y_i + \sum_i \theta_i y_i$$

تغییر حالت \rightarrow استلردن: نهایت باجرمانده k

$$\Delta E = E(\text{new}) - E(\text{old})$$

$$\Delta E = - \sum_{j \neq k} \omega_{kj} (y_k(\text{new}) y_j(\text{new}) - y_k(\text{new}) y_j(\text{old}))$$

$y_j(\text{new}) = y_j(\text{old})$

مرحله 1

$$- \sum_i \omega_{ij} (y_i(\text{new}) - y_i(\text{old}))$$

$i = k$ \ominus \ominus \ominus

$$+ \sum_i \theta_i (y_i(\text{new}) - y_i(\text{old}))$$

$i = k$ \ominus \ominus \ominus

$$= - \left[\sum_{j \neq k} \omega_{kj} y_j(\text{old}) + \alpha_k - \theta_k \right] \Delta y_k$$

$$\Delta y_k = y_k(\text{new}) - y_k(\text{old})$$

$$\Delta E = - \left[\sum_{j \neq k} \omega_{kj} y_j(\text{old}) + x_k - \theta_k \right] \Delta y_k$$

این بیان شرط تابع تبدیل است.

a) $y_k(\text{old}) = +1$ و $y_k(\text{new}) = -1 \Rightarrow \sum \omega_{kj} y_j(\text{old}) + x_k < \theta_k$

$\Delta y_k = -2$ و داخل برداشته مثبت \Rightarrow

$\ominus \times \ominus \times \ominus \Rightarrow \Delta E < 0 \Rightarrow$ کاهش انرژی

b) $y_k(\text{old}) = -1$ و $y_k(\text{new}) = +1 \Rightarrow \sum \omega_{kj} y_j(\text{old}) + x_k > \theta_k$

$\Delta y_k = +2$ و داخل برداشته مثبت \Rightarrow

$\ominus \times \ominus \times \ominus \Rightarrow \Delta E < 0 \Rightarrow$ کاهش انرژی

پس با تغییر حالت شبکه، انرژی کاهش می‌یابد تا به حالتی برسد که دیگر تغییر حالت رخ

نهد ($\Delta E = 0$) شبکه بیدار می‌شود. لذا در این شبکه همواره $\Delta E \leq 0$

• یک مدول شبکه \Leftarrow نظر همین در فضای انرژی \Leftarrow هدایت به سمت دره انرژی \Leftarrow به دره = حالت پایدار

پس: هر حالت بیدار شبکه = منبسط محلی در فضای انرژی

جای تعین بیداری در تعداد آنها محدود: $\omega_{ij} = \omega_{ji}$ و $\omega_{ii} = 0$

Subject:

Year. Month. Date. ()

• یادگیری دژها

دژها باید طوری تعیین شوند که انرژی که می خواهیم در شبکه ذخیره کنند حالت یادگیرنده

گردند (مقدار انرژی برای این دوره حداقل شود)

$$E \rightarrow \min \Rightarrow \sum_{i \neq j} \sum_j w_{ij} \cdot y_i \cdot y_j \rightarrow \max$$

$$\underline{S}_k = \begin{bmatrix} S_k(1) \\ \vdots \\ S_k(n) \end{bmatrix}$$

$$w_{ij} = S_i \cdot S_j \Rightarrow \sum \sum w_{ij} \cdot y_i \cdot y_j > 0$$

$$\Downarrow \sum \sum w_{ij} \cdot y_i \cdot y_j = \sum \sum S_i^2 \cdot S_j^2 > 0$$

$$\Downarrow S_k \uparrow \rightarrow E \downarrow$$

اگر شبکه ای که انرژی در تقاضای S_k را ذخیره کرده، انرژی جدیدی اعمال کنیم که کمتر از انرژی از برود

آن با برودتی متناظر از S_k متناظر باشد، شبکه به حالت یادگیرنده می رسد.

اگر بیش از نصف برودت متناظر باشد، انرژی جدید به حالت یادگیرنده می رسد. حالت

S_k - حالت معکوس (Reversed) می باشد

شبه خود ستادی: S_k رودی S_k ← خودی S_k

اگر 49.7% هم شبه S_k باشد جواب S_k است در نه S_k - (بسیار عالی)

همی ذخیره بیش از یک الگوی تقابلی:

$$\omega_{ij} = \begin{cases} \sum_{e=1}^L s_{e(i)} \cdot s_{e(j)} & , i \neq j \\ 0 & , i = j \end{cases}$$

گاهی یک ضرب $\frac{1}{n}$ به جدولی که به اضافه اضافاتی شود ← ایجاد پایداری ← قانون هم تقسیم مایته الگوی مابینری:

$$\omega_{ij} = \sum_{e=1}^L (2s_{e(i)} - 1)(2s_{e(j)} - 1)$$

• مرتب؟ ← سهولت رمادی بسط الگوریتم یادگیری ← محاسبه با الگیری عمل جمع و ضرب

• قانون هم تقسیم مایته در شبکه که پنلید موجب قرار گرفتن حالات پایدار در سیستم می تابع انرژی می گردد

این حالات را حالات بازیابی (Retrieval) می نامند. S_i

• حالات معکوس حالات بازیابی نیز میسیم می تابع انرژی خواهد بود. S_i -

• حالات مخلوط: ترکیبی خطی از هر تعداد ورودی حالات بازیابی S_i^{mix} ←

$$S_j^{mix}(i) = \text{sgn}(\pm S_k(i) \pm S_e(i) \pm S_m(i))$$

Subject:

Year:

Month:

Date:

()

• حالات Spin Glass: برای حالتی که تعداد زیادی اسپین زنجیره سرد، میسینگ می

محلی دیگری ایجاد می کنند که با هیچ یک از حالات بیدار ارتباط خاصی ندارند.

• حالت بلی یا جعلی (Spurious States)

— حالات مغفوس + محوط + spin glass + ناخواسته

— میدان سازنده کوچک — با هم نزدیک می توان از روی آنها پرید

— راههای حذف این حالات

— حالت مغفوس — علامت برنده خاصی از اینجا و از قبل بدانیم و در حالت مشابه


حذف آن دیده شود — اصلاح: ضرب تمام مولفه های

خارجی در 1-

□ بر سطحی که می خواهیم در حالتی از آن min ساخت، بالا بجاود در حالتی دیگری از آن نیز

min ساخته می شود — بلکه وجود حالات ناخواسته


• عملکرد شبکه در بپلید



Subject:

Year: Month:


Date: ۲۷



سوال بی جواب:

چه سبب آنکه خط راجل بین دو حالت

بیدار نتوانند؟



حالت بدی

• اگر تیم شبانه کسب کند

• روزی شبانه را از قانون بیدار بیدار می کنیم

1. به ازای بردار ورودی x_i

2. ستاد برادریه حالات برابر بردار خارجی x_i $y_i(\text{old}) = x_i$

3. داده سیکله بیدار شده است

4. برای بردار واحد i

5. خروجی خطی واحد $I_i = x_i + \sum_j w_{ij} \cdot y_j(\text{old})$

6. محاسبه خروجی $y_i(\text{new}) = \begin{cases} 1 & I_i > \theta_i \\ y_i(\text{old}) & I_i = \theta_i \\ -1 & I_i < \theta_i \end{cases}$

7. ارسال مقدار (new) y: به مقدار صحیح

8. سلبی شبه را آزمایش می کنیم.

ظرفیت شبه ← چند عدد قابل ذخیره است؟

بسی خطای قابل قبول چند عدد؟

(n) تعداد واحدها \propto ظرفیت

↑ خطا \rightarrow ↑ h \Rightarrow (h) تعداد الود \propto ظرفیت

با اثبات ریاضی: حداقل تعداد الودی قابل ذخیره بدون ایله خطای غیر قابل قبول پیش بیاید

خطای از پیش معلوم

نتایج تحلیل اول: تعداد دوری n

- خطای کمتر از 1% $\Rightarrow h \leq 0.15 n$
 - خطای کمتر از 5% $\Rightarrow h \leq 0.37 n$
 - خطای کمتر از 10% $\Rightarrow h \leq 0.61 n$
- n: دقت شده شده

سلب با 17 دوری ← برای خطای کمتر از 1% الودی نداریم
بسی ذخیره الودی بیشتر ← افزایش نوددها

افزایش نوددها ولی ردی ثابت ← تغییر دوری برای بالا بردن تعداد برنده دوری

نتایج تحلیل دم : بازیابی صحیح همه n بیت با دقت 99٪

$$L \leq \frac{n}{2 \ln n}$$


بازیابی کامل همه داده

$$L \leq \frac{n}{4 \ln n}$$

ن = 100 دودی

- تحلیل اول 1٪ خطا : $L \leq 15$
- تحلیل دوم 1٪ خطا : $L \leq 11$
- تحلیل دم 100٪ دقت : $L \leq 5$!!!

شکل ۶ پیله



1 : ماده سازگی شکل ۶ پیله گسترده

واسط کار به ← نمایش دودی و خروجی تغییر یافته
- داده ای مناسب برای نشان دادن در شکلها

Subject:

Year: Month: Date: ()

* قانون لاپلاس گراسبرگ

شبه معین: n بردار $n \times n$ ، خود همبندی y_i ، تابع واحد ω_{ij}

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

شرایط:

۱- برای ω_{ij} و $\omega_{ii} = 0$ و $\omega_{ij} > 0$ و $\omega_{ji} = \omega_{ij}$

۲- تابع $a_i(u)$ $\forall u > 0$ \rightarrow همیشه مثبت

۳- تابع $b_i(u)$ $\forall u > 0$ \rightarrow همیشه بزرگتر از ۰

۴- تابع $f_j(u)$ $\forall u > 0$ \rightarrow مشتق پذیر $f_j'(u) > 0$

۵- $u \rightarrow \infty$: $[b_i(u) - \omega_{ij} f_j(u)] < 0$

۶- یک لداک از این شرایط

$$\left\{ \begin{array}{l} \lim_{n \rightarrow \infty} b > \infty \\ \lim_{n \rightarrow \infty} b < \infty \end{array} \right. \text{ AND } \exists u : \int_0^u \frac{ds}{|s|^{a_i}} = \infty$$

• این شرایط برقرار باشد اگر حالت شبکه در زمان صفر در بخش مثبت فضای حقیقی

• یعنی باشد، شبکه همیشه بابت نقطه پایدار در بخش \oplus فضای حقیقی پهن می شود. در جای

انتخابی بایر دارد W ، همچنین تعداد نقاط پایدار محدود خواهد بود.


• مدلی بایر عموماً ← معادلات حاکم بر شبکه های زیادی حالات خاصی از مدل لاینی-گراسبرگ

$$y_i' = -A_i y_i - (B_i - C_i y_i) [I_i + F_i(y_i)] - (D_i y_i + E_i) [$$

$$y_i' = G_i y_i (1 - \sum_{j=1}^n H_{ij} y_j)$$

BAM \equiv Bidirectional Associative Memory * شبکه متوازی دو طرفه

• کازدر: ۱۹۸۸ تا ۱۹۹۲



• لایه ۱: لایه x ، لایه ۲: لایه y ؟

لایه ۱ x ؟ متصل به لایه ۲ y ؟، ماتریس وزن W

لایه ۲ y ؟ متصل به لایه ۱ x ؟، ماتریس وزن W^T

$m \neq n$

• ورودی به لایه ۱ x اعمال شود ← خروجی در لایه ۲ y ؟

• ورودی به لایه ۲ y اعمال شود ← خروجی در لایه ۱ x ؟

Subject:

Year: Month: Date: ()

• این شبکه تعمیم شبکه پرسپیکس به حالت غیر خرد تعدادی

• شبکه‌های لوزالون : باینری ، در قطبی ، پرسپیکس

• معمولاً عملگر نتیجه لیست در قطبی تعدادی اهمیت

• آموزش شبکه با استفاده از زمان منب

$$\langle S_i, T_i \rangle \begin{cases} \text{در قطبی} & \omega_{ij} = \sum_{k=1}^h S_k(i) T_k(j) \\ \text{باینری} & \omega_{ij} = \sum_{k=1}^h (2S_k(i) - 1)(2T_k(j) - 1) \end{cases}$$

• تابع فعالیت واحد - شبکه پرسپیکس

$$x_i(\text{new}) = \begin{cases} I_i > \theta_i & , +1 \\ I_i = \theta_i & , x_i(\text{old}) \\ I_i < \theta_i & , -1 \end{cases}$$

$$y_j(\text{new}) = \begin{cases} I_j > \theta_j & , +1 \\ I_j = \theta_j & , y_j(\text{old}) \\ I_j < \theta_j & , -1 \end{cases}$$

• واحدی لایه α به با هم هنگام در آورده می شوند و در تمام بعدی واحدی لایه β می باشد

• به صورت می در می آید

الگو نیم سنج

۰. محاسبه وزنهای یادگیری با زوج بردار آموزشی و خروجی واحد برابر هنر

1. به (زای هر بردار درودی آموزشی

2. حالات لایه z_i و x_i هر بردار درودی حاضر (احتمال درودی S به لایه z_i)

درودی I به لایه z_i

3. با دامبله واحد پایدار نشده اند

4. هنگام سزای حالات واحدی لایه z_i ؟

$$I_i = \sum_j \omega_{ji} z_j$$

$$y_i = f(I_i)$$

5. هنگام سزای حالات واحدی لایه x_i ؟

$$I_i = \sum_j \omega_{ji} z_j$$

$$x_i = f(I_i)$$

6. آزمایش سنجی: خانه آموزش در صورت به حال رسیدن هر حالات در درو لایه

شبه سنجی در طرفه پیوسته

خروجی $[0, 1]$ از [دیر بسته] درودی

$$f_i(I_i) = \frac{1}{1 + e^{-I_i}}$$

تابع فعالیت: سلیبند لا جینستیک

Subject:

Year: Month: Date: ()

• معادلات حاکم بردندمان شبکه

$$\dot{x}_i = -a_i x_i + \sum_{j=1}^m \omega_{ij} F(y_j) + S_i, \quad a_i, s_i > 0$$

$$\dot{y}_j = -c_j y_j + \sum_{i=1}^n \omega_{ij} F(x_i) + t_j, \quad c_j, t_j > 0$$


• قضیه کانزاک

اگر شبکه تداعی دو طرفه از سه حالت اولیه $(x(0), y(0))$ شروع به کار کند، شبکه به حالت


پایدار میاید خواهد شد ← اثبات با استفاده از قضیه لایپنیت - کانزاک

• کاربرد شبکه بازیابی تقادیر، کد دیگ کردن اطلاعات

✓ (مادر ۱۶ به ۹)



...



رددی نژیری



خودجی

Learning Paradigms

@ اشغال یادگیری

* انواع مدل‌های یادگیری
- یادگیری با نظارت

Supervised h , h with a Teacher

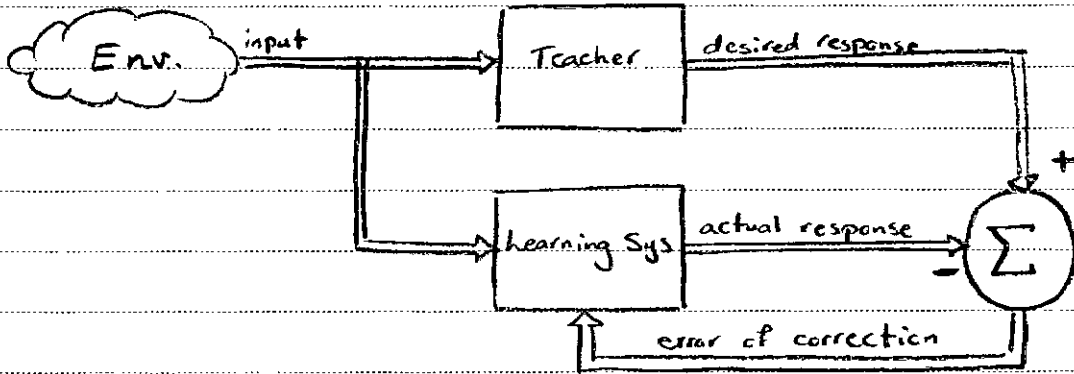
- یادگیری بی نظارت

Unsupervised h

- یادگیری تقویتی

Reinforcement h , h with a Critic , Graded h

* یادگیری با نظارت



• معلم : دارای دانش محیط ← پاسخ مطلوب برای هر ورودی

• آموزش : ارائه زودگی \langle ورودی ، خروجی \rangle

• تنظیم پارامتر : تحت تاثیر حالت محیط و خطای موجود

← تدوین و بهینه‌سازی عملکرد عمل آموزش

• مجموعه آموزش : شامل نمونه‌ای تحت تاثیر او یا چند دسته

• هر نمونه آموزش : $\langle S, T \rangle$ S : feature / attribute

T : desired response


دسته مطلوب ، پرسید درستی

Subject:

Year: Month: Date: ()

یادگیری ← تحلیل بردن خطا (LMS) و دیدن
 پس انتشار (BP)

* یادگیری بی نظارت



- بدون معلم
- خروجی مطابق با نیاز ورودی : تشخیص اشیاء
- نمونه های بدون برچسب
- شباهت خود اکتفا به کشف ویژگیها، الگو، نظم در داده ها یا دسته بندی موجود در ورودی می کند و آنرا به خروجی نشان می دهد.

• نمونه های خروجی :

۱- تشخیص یا شباهت : خروجی همیشه شباهتی را نشان می دهد که ورودی ورودی

خبریه یک الگوی نماینده که قبلاً مشاهده کردیم شبیه است.
 typical

□ چند در صد شبیه ؟

۲- تحلیل مولفه اصلی : گسترش بردار نون به ضمیمه واحد منحصر به ایجاد مجموعه مورد نیاز

Principle

Component

Analysis

پایه می رود که در استاندارد آن مورد شباهت ورودی به الگوی نماینده basis

۳- خوشه بندی : شبکه دارای m خروجی با نیری که بر لایه با نیری خوشه است <

Clustering هر زمان تنها یکی فعال است < خروجی فعال : انوی ورودی معقل به لایه

خوشه < تعداد خوشه : تنظیم اوزان آموزش

۴- نمونه (پی) : شکل دسته (مانند خوشه بندی) < خروجی شبکه : انوی غایبه خوشه

Prototyping انتخاب شده (میالین خوشه) < دولای خروجی : با نیری (

لایه خوشه فعال است) یا غایبه شبیه ترین خوشه (میالین خوشه ...)

۵- لایه لرون : تبدیل ورودی به خروجی گذشته < نیاز به شبکه دوی برای لوشایی

۶- کاشت ویرگی : واحدی خروجی دارای فرم تکراری خاص (مثلا آرایه یک بعدی یا دو بعدی

Feature Mapping تنظیم) < در هر لحظه یک خروجی فعال < شبکه هر انوی ورودی را


به یک نقطه خاص از آرایه خروجی کاشت می کند < انوی مشابه ورودی

عملی ترین به هم در نقشه را فعال می کند < کار شبکه : مکان یک آرایه <


عمل در آرایه معادله است کاشت : نگاه کردن به خروجی بعدی برای به ویرگی ورودی پی برد

Data Visualization

* یادگیری تقویتی



• یادگیری با تقارن ← نمونه‌های $\langle S, T \rangle$ ← T : معلم



نمونه‌های ورودی باید کل فضای سگ را پوشش دهد

• بودن خروجی مطلوب برای پرسش!



• عدم پوشش تمام فضای سگ در نمونه‌ها!

• یادگیری تقویتی ← ورودی‌های ورودی به معلم نیاز ندارد

• براند چندانایی به سیستم می‌دهیم که کارات خوب داشته باشد

• شباهت بازی «تین تن بود حلو» ← هر چه نزدیکتر به «تین تن بود حلو» می‌شود

• داشتن خروجی مطلوب برای نمونه‌های ورودی مثبت

• شباهت بین لفظی همین مرحله یادگیری ارزش یابی شده → عملکرد آن استیاری داده می‌شود

• ارزیابی در مقابل تابع نریز انجام می‌شود

مشابهی مبتنی بر یادگیری تقویتی عمدتاً ۴ صفت تر از شبکه های با ناظر مستند ، لذا برای جای مناسبند
دخروجی موجود نباشد.

* یادگیری با تقارن (VS) - یادگیری تقویتی

معلم : اطلاعات دقیق و گسترده / نماند : اطلاعات کلی

نیروی : آموزش (مورد به مورد) / نیروی : ارزیابی

اطلاعات : علمی و لحظه ای / اطلاعات : عمومی و دارای تأخیر

اطلاعات مستقیم : سیستم محدود تطبیق باید / اطلاعات غیر مستقیم : مبتنی بر معنی و محتوا

سرعت : بیشتر / سرعت : کمتر (تأخیر محبت دایمی دارد)

* یادگیری با تقارن (VS) - یادگیری بدون تقارن

معلم : اطلاعات دقیق و گسترده / بدون معلم : نماند (اطلاعات خاص)

نیروی : آموزش دهنده / نیروی : کنترل از دور

تعیین پذیری : ضعیف / تعیین پذیری : لایه

Subject:

Year:

Month:

Date:

()

Competitive Networks

شبکه های رقابتی

Maxnet
* شبکه

هدف: افزایش کارایی نسبت به ورودیها / افزایش کارایی در میزان فعال بودن واحدها

• مبتنی بر لین ۱۹۸۷

• کاربرد: شبکه استیل / قابل استفاده شدن به سایر شبکه ها

• مشخص می کند که کدام واحد آن دارای بیشترین ورودی است

• معادله n واحد

انتقالات قابل ستاد

وزنهای مثبت

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

تابع فعالیت خطی ربع مثبت

ورودی تنها در شروع شبکه به کار گرفته می شود

Subject:

Year: Month:

Date: ۳۴

الگوریتم

بر اساسی در این سلسله می‌باشد
 در این می‌خواهیم محدودیت فعال
 باشیم و در بیان مسئله می‌خواهیم
 محدودیت بیرونی ارزش محدودیت
 مثبت بودی و در هر بار به نسبت
 کاهش می‌کنند.

مقدار اولیه ϵ

$$0 < \epsilon < \frac{1}{n}$$

$$y_i(\text{old}) = x_i$$

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

1. ارزشی شروع می‌کنیم

2. مقدار در اصل مقدار فعالیت واحد i

$$y_j(\text{new}) = f \left(\sum_k \omega_{kj} y_k(\text{old}) \right)$$

$$= f \left(y_j(\text{old}) + \epsilon \sum_{k \neq j} y_k(\text{old}) \right)$$

3. ذخیره مقدار فعالیت برای تکرار بعدی

$$y_j(\text{old}) = y_j(\text{new})$$

4. اگر بیش از یک واحد مقدار فعالیت غیر صفر دارد، الگوریتم ادامه می‌یابد در غیر این

صورت خاتمه می‌یابد

در نتیجه تنها نودون می‌بماند، مقدار فعالیت غیر صفر دارد - منتهی به \max ورودی

Subject:

Year:

Month:

Date: ()


* شباهت گاه مغزینی

• دین : افزایش تأثیر دین در دوره های سبک

• سبک : کم بودن

• معاری ← هر واحد با روزهای نسبت به همبستگی کمتری گنجه و با روزهای سستی

• همبستگی در تنب و راجع در لایه سبز در عمل می شود.




• روزهای مربوط به واحدهای متوالی نسبت به i یعنی واحدهای $i+1$

• و $i-1$ معاری در نظر گرفته می شوند وانی آخر


Subject :

Year . Month . Date . ۴۵




↓ تابع پلاک ملزلی

• حسیت نزدیکی دري همجو



• انواع همسایگی برای گزیده



• وزن فعال ← فعال واحد به واحد w_{i+k}

راصدی همسایگی گزیده $(R_1 < |K| < R_2)$ مثبت

راصدی رقابت گزیده $(R_1 < |K| < R_2)$ منفی

خارج از R_2 من

• تابع رقابت

$$y_i(t) = f \left(\alpha_i(t) + \sum_{k=R_2}^{R_1} w_{i+k} \cdot y_{i+k}(t-1) \right)$$

Subject:

Year: Month: Date: ()

الموضوع

متغيرات اولية t_{max} , R_2 , R_1 : پارامتره

$$y_i(0) = 0$$

تغایب واحد : 0

درجه

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

$$y_i(0) = \alpha_i$$

1. اعمال سبیل خارجی و همزه $y_i(0)$

مقدار اولیه t بر صفر قرار داده می شود.

2. زمانی که $t < t_{max}$

3. خودی صلی واحد

$$I_i = \sum_{k=-R_2}^{R_2} w_{i+k,i} y$$


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

4. اعمال تابع تغایب

Subject:

Year: Month: Date: ۴۴

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



$$I_i^{(old)} = y_i$$

5. زنجیره خوردگی در (old) y

$$t = t + 1$$

6. اعمالش مشاهده

7. ازین شرط خارج $t < t_{max}$

Hamming Net

* شبکه

فاصله همسبک: فاصله همسبک بین دو بردار \underline{x} و \underline{S}_j برابرست با تعداد سلفه های در بردار \underline{x} باهم متفاوت هستند (d_j)

میزان \underline{x} به دو بردار با n سلفه $a_j = n - d_j$

برای بردار \underline{x} در تقبی

$$\underline{S}_j \cdot \underline{x} = a_j - d_j$$

$[1 = \text{مانندیم}]$ و $[-1 = \text{مخالفیم}]$ → مجموع حاصلضرب سلفه های نظیرها
تعداد دفعاتی که مخالفند - تعداد دفعاتی که شبیهند


$$\underline{S}_j \cdot \underline{x} = a_j - d_j = a_j - (n - a_j) = 2a_j - n \rightarrow a_j = \frac{1}{2} \underline{S}_j \cdot \underline{x} + \frac{1}{2} n$$

Subject :

Year . . . Month . . . Date . . . ()

$$a_j = \frac{1}{2} \sum_i S_{ij} x_i + \frac{1}{2} n \rightarrow \text{شبیه‌القطب‌نوردی}$$


می‌توان چنین تفسیر کرد که یک واحد اجزین در حقیقت میزان شباهت x و S_{ij} را محاسبه می‌کند
 برای چنین عمل بردار S_{ij} را در دو طرف آن ذخیره می‌کنیم و سرچانه ورودی اعمال می‌کند، خروجی میزان



• کاربرد → تعدادی واحد مانند

درودی که دارد می‌شود ← خروجی : میزان شباهت ورودی به بردار ذخیره شده

↓ پیدا کردن شبیه‌ترین → قرار دادن یک شبیه Maxnet در خروجی



• الگوریتم (n ورودی، m بردار S_{ij})

۱. وزنهای شبکه
 $w_{ij} = \frac{1}{2} s_{ij} \quad i=1, \dots, n \quad j=1, \dots, m$

۱. برای بردوری x


۲. محاسبه خروجی خطی
 $y_j = \frac{n}{2} + \sum_i w_{ij} x_i \quad j=1, \dots, m$

۳. تعیین مقدار برادلیه شبکه Maxnet
 $y_j(0) = y_j$

۴. اجرای الگوریتم Maxnet برای اولین تطبیق

$e_1 = (1, -1, -1, -1)$

$e_2 = (-1, -1, -1, 1)$



↑ اجرای بردوری: x ↑ مقدار برادلیه: y ↑ Maxnet ($\epsilon = 0.3$)

$a = (1, 1, -1, -1)$

آزادگی:

$y_1 = 3 \quad y_2 = 1$

$x_1 > x_2$

* شبکه‌های خود سازماندهی از یادگیری رقابتی استفاده می‌کنند، بیشتر بر شبکه‌های خطی از

مغز انسان توسعه یافته‌اند، سلولها در مغز در نزاع مختلف طوری سازمان داده شده‌اند که شباهتی

مجموعه‌های مرتب‌شده محاسباتی (Topologically Ordered Computational Maps) معنی دارد.

ارائه می‌دهند. مثلاً ورودی‌های حس لامسه، بینایی، شنوایی و... بر یک پایه ترتیب منبسطی معنی دار به نواحی مختلف مغز منتقل می‌شوند.

یک نقشه محاسباتی برای زمان مستقل از آن است که به طور موازی ورودی اطلاعات حساسی ورودی محلی می‌کند. در این محاسبات اطلاعات ورودی به توزیع احتمال مکانی تبدیل می‌شود که متناوباً محاسبه شده یا کمتر از با میزان فعالیت نسبی مجتهد، نقشه ارائه می‌دهند.

دیک نقشه ویژگی خود سازمانده (Self Organizing (Feature) Map \equiv SOFM \equiv SOM)

واحدهای بیرون‌شده درون‌های یک شبکه (نوری) یک بصری یا در بصری قرار داده می‌شوند. واحد ورودی

یک فرآیند یادگیری رقابتی نسبت به دسته‌های ورودی تنظیم می‌شوند. محل واحدهای تنظیم شده شبکه

به گونه‌ای تنظیم می‌یابد که برای ویژگی‌های ورودی دیک دستگاه محققان معنی دارد در روی شبکه ایجاد

می‌دهد. لذا یک نقشه خود سازمانده یک نقشه تولیدی از ورودی و اتصالات می‌دهد که در آن

محل قرار گرفتن واحدهای متناظر ویژگی‌های ورودی است.

یادگیری رقابتی که در این شبکه به کار رفته می‌شود برین صحت است که در هر قدم یادگیری واحدهای

فعال شدن با بیلد بر سه ثابت می پردازند

در پایان یک مرحله رقابت تهیه واحد برد می شود. در این حال تغییر دهنده های واحد برنده نسبت

به سایر واحدها به طور متفاوت انجام می شود. ریادگیری تکرار می شود.

* تاریخچه شبکه های خود سازمانده

• ریشه های قانون کوپونز ← مباحث خوشه بندی بی نظارت (Clustering)

۱۹۴۲ دتلر و زان

۱۹۷۰ مالزبرگ ← قانون یادگیری خود سازمانده

(مجموع دهنده های گرفته شده از خروجی بستی ثابت باشد)

(سه فرض ثابت بدون میزان برداشتی در سناریو)

۱۹۷۴ کوپونز ← در قانون مالزبرگ

• ۱۹۷۰ کوپونز ← تابع چگالی درودی بعد از سخت فرض ← قانون اولیه کوپونز

در قانون یادگیری بستی ساختن یک مجموعه بردار \vec{w} که ارائه های

هم احتمال یک تابع چگالی احتمال ثابت P تشکیل می دهند باشند

معنی برداری w_i باید خود را طوری تغییر دهد که برای بردار x دوری

نتایج جهانی احتمال P داشته باشیم

احتمال اینکه x به w_i نزدیکترین باشد $\frac{1}{m}$

۱۹۷۸ دسیو - حل مشکل پرداخت بودن تابع توزیع


* شبکه لایه‌های

• فضای یک جوی : یک لایه لایه‌های از واحد است که به صورت یک بردار K


بعدی آرایش یافته اند

• m : نودهای لایه لایه‌های و n : حجم ورودی

• انواع نما



1D



2D

• در آموزش این شبکه در اساس قانون لایه‌های برمی آید از نودها تا شبکه بردار وزن خود را با بردار

دردی X پیدا می‌کند : تابعه اطمینانی، گامی بردی $(D(x) = 1 - \cos \varphi)$ ، اما لاابین

• بر نوردن ی جزای نزدیکترین w به x دارا شده باشد و در نهایت به طور خاصی تغییر کند

• همچنین منظور با داصدی دیر به رقابت ی پردازد — نوردن برنده : پیروز در مسابقه

• تشخیص نوردن برنده در شبکه ی بوی

۱- دریافت اطلاعات سایر نوردینا — خردن ی نورد برنده است بانه

۲- اتصالات جانبی باز دارند — تنها واحد برنده فعال می ماند

۳- داصد برنده ریزی — در حالت تمام I_i در تعیین برنده

۴- داصد برنده ریزی — فرستادن مقدار استانه به همه واحدها — اولین داصدی که دارای I_i

خبر از استانه باشد برنده است

• تشخیص نوردن برنده در شبکه ی بوی

برنده = نزدیکترین نوردن به دوددی

نوردن برنده (دائمه لایمب باطنش) به بعداد دوددی نزدیک می شوند

↳ اصلاح وزن

Subject:

Year: _____ Month: _____ Date: _____ ()

• قانون یادگیری


پس از تعیین کردن برون‌یابی برای ورودی خاص x خروجی این نرون (z_i) برابر با ۱ شود

در همه خروجیهای دیگر برابر ۰ می‌شود

همچنین در زمان

$$\underline{w}_i \text{ (new)} = \begin{cases} \underline{w}_i \text{ (old)} & z_i = 0 \\ (1 - \eta) \underline{w}_i \text{ (old)} + \eta x & z_i = 1 \end{cases}$$

در ادای نام یادگیری η مقدار نرون
 بیشتر یادگیری η



$$x - w_{old}$$

$$\eta(x - w_{old})$$

$$w_{new} = w_{old} + \eta(x - w_{old})$$

• مشکلات قانون یادگیری


دیف: تنظیم خودکار w به طوری که برای سرتیغ ورودی x با تابع توزیع $P(x)$ احتمال برنده شدن تمام نرونها برابر و مساوی $\frac{1}{m}$ باشد.

شرط رسیدن به دیف: ورودی x که از ناحیه مستقل دارای برون‌یابی با تقریباً ساده

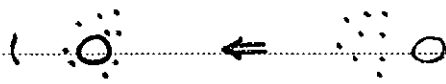

داغ بر روی این شرط: نرونهای مرده - توضیحات بدون توزیع

وجود نرون در حالتهای انزوله


• ابتداحت بزوان تیزع - برخی از زنده‌ها بر زنده می‌شوند



• وزن آنها پیچیدگی اصلاح می‌شود - زدن مرده

(اصلاح زنده):  ← 

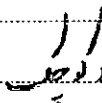
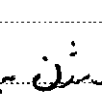
• زدن جدا افتاده پیچیده - یعنی زنده به سایر زنده‌ها



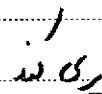
نزدیک شود

• راه حل رشد دادن شفافی (Radial Sprouting)

- تمام برداری اوزن اجباری

• برداری دوروی در ابتدا ضرب اولی بود  - نزدیک شدن به مبدأ دوروی 

• با گذشت زمان مقدار ضرب شده افزایش می‌یابد - تا جایی برابر ۱ شود

• با لیرگی 

• راه حل اضافه کردن تیزتری ثابت

- اضافه کردن تیزتری با تیزج ثابت به برداری دوروی

- در ابتدا تیزتری - علیه برداری

Subject:

Year: Month: Date: ()

— با گذشت زمان دوز صغیر تر — در نهایت صغر

— حتی کمتر از اوش پیش

• راه حل اصلاح بیش از یک نندون

— ویب مسابقی واحد برنده در زمان اصلاح می شوند — خروج از حالت Winner Takes All

— در ابتدا شغاع مسابقی بزرگ — اصلاح همه نندونها

— با گذشت زمان کاهش شغاع مسابقی — در نهایت مسابقی تنها شامل واحد برنده

— سریع

• راه حل دسیمنو

— تقویت وجوه ای سلبه — هر نندون بیش از حد برنده نشود

— اگر نندونی بیش از حد برنده شد، حذف شود

— پیاده سازی (ویب نسخه)

* محاسبه نام نندونهای ورودی X

* نسبت زمانی که واحد نام برنده شده است محاسبه می شود

Subject:

Year: Month: Date: 21

$$f_i(\text{new}) = f_i(\text{old}) + \beta (x_i - f_i(\text{old}))$$

$$\beta \equiv 10^{-4}$$

* محاسبه β

$$b_i = \gamma \left(\frac{1}{m} - f_i(\text{new}) \right)$$

$$\gamma = \text{cte} \rightarrow \text{تغییر 10}$$

* اصلاح فاصله \leftarrow اصلاح نحوه انتخاب نودان برنده

$$D'_i = D(w_i, x) - b_i$$

\uparrow نودان کم برنده شده است $\leftarrow f_i(\text{new}) \leftarrow b_i > 0 \leftarrow D'_i \leftarrow \uparrow$ نودان \uparrow
 \uparrow نودان زیاد برنده شده است $\leftarrow f_i(\text{new}) > \frac{1}{m} \leftarrow b_i < 0 \leftarrow D'_i \leftarrow \uparrow$ نودان \uparrow

• الگوریتم یادگیری لاجین

1. مقدار اولیه برای w و b را برآورد
 پارامترهای نرخ یادگیری
 پارامترهای همبستگی و اصطلاح برنده

2. با داده شرط خالصه ارض تست

3. برای هر بردار ورودی X_i

4. محاسبه حاصل D برای بردن n

5. پیدا کردن بردن n دارای D کمینه

6. نوشتن درآیند وزن بردن در محاسبی بردن n ($N(n)$)

$$W_{ij}(\text{new}) = (1 - \eta) W_{ij}(\text{old}) + \eta X_i$$

7. نوشتن درآیند نرخ یادگیری η

8. ارزش شغای محاسبی در مراحل معین




9. درآیند شرط بلندی (چند بار تکرار، ...)

انتخاب محاسبی

۱- محاسبی سبزی در اطراف بریده ← با توجه به جدولوزی $r=1$ مربع ، دایره ، ...


۲- محاسبی مغزپخته در وسط تابع ← تابع پیوسته جدول بریده

$r=1$ سبزی



نتیجه بیشتر به عملکرد نودهای طبیعی

این واحد فعال بر روی سمپله نزدیکتر بیشتر تأثیری ندارد تا دورتر




مانند تابع گوسی

$$h_{ij}(x) = e^{\left(\frac{-d_{ij}^2}{2\sigma^2}\right)}$$

اندازه سمپله‌ی تعیین شده برخط σ

کاهش فزاینده اندازه سمپله‌ی σ تأثیری نزدیک به از بین

$$\sigma(n) = \sigma_0(n) \cdot e^{-\frac{n}{T_1}} \quad \sigma_0, T_1 = \text{cte}$$



تأثیر یادگیری اصلاح شده (پس از اعمال σ و n)

تابع سمپله‌ی نزج یادگیری طبیعی

$$\underline{W}_j(n+1) = \underline{W}_j(n) + \eta(n) \cdot h_{ij}(n) \cdot (x - \underline{W}_j(n))$$

$$\left\{ \begin{array}{l} \sigma(n) = \sigma_0(n) \cdot e^{-\frac{n}{T_1}} \\ \eta(n) = \eta_0(n) \cdot e^{-\frac{n}{T_2}} \end{array} \right.$$

جذب بیشتر \leftrightarrow سمپله نزدیکتر

یادگیری (داده‌های تصادفی) ← تخمین صحیحی در درون‌ها

I فاز مرتب شدن Ordering

صحت‌های کمی اساسی

تعداد مورد ۱۰۰۰۰

تعداد n

$$\left\{ \begin{array}{l} \eta : 0.1 \rightarrow 0.01 \\ \eta_0 = 0.1, T_2 = 1000 \end{array} \right.$$

نام خرد بازتابی

تخمین

$$\left\{ \begin{array}{l} \text{نورن برنده و چند تا بعد از آن} \\ T_1 = 1000 / \log(100) \end{array} \right.$$

تعداد مورد ۱۰۰۰۰

II فاز همگرایی Convergence

تنظیم دقیق تر

تعداد مورد ۵۰۰۰

تعداد n

تعداد مورد ۰.۵۱

تخمین (شامل نورن برنده و چند نورن اطراف آن)


کامپیوترهای جدید توان نوردهای عمیق را با خطای بسیار کم می‌دهند. مثلاً برای ساخت دیالیزهای بر اساسی سطح می‌توان از شبکه‌های عمیق استفاده کرد.

کامپیوترها: در سازی مثل، تقاطع تصاویر، بازیابی اطلاعات، پردازش تصویر

* شبده یادگیری لوانیزاسیون برداری Learning Vector Quantization (LVQ)

• لوانیزاسیون (چندبندی) برداری

برای بهره برداری از سامانه موجود در بردار و زیاده ← منظور نشده سازی داده




A/D

Quantization

لوانیزاسیون چندبندی ← لوانیزاسیون در بردار

✓ شافل: نشرده سازی بهتر ✓

بازی ایستار ← لوانیزاسیون ایستار: لوانیزاسیون تعیین شده (سود)
بردار ← برداری: " (بردار)



محدوده بندی نقطه

بازی برناجیه یک بردار بازسازی تعیین می شود
محدوده تمام داده بازسازی: کتاب در بازسازی

در یک لوانیزاسیون شده برداری با حداقل خطا، تقسیم بندی نقطه با استفاده از فاصله نزدیکترین همسایه
مستقیم برناجیه اقلیدسی است

لوانیزاسیون شده درونوی ← محدوده سلولهای درونوی (Voronoi)

Subject:

Year: Month: Date: ()

• تعیین برداری استاندارد به صورت تقریبی با یادگیری تقابلی

• برای دسته بندی الگو از یادگیری گزینشی برداری استاندارد شده است.

استفاده از یک طبقه برداری تقارن:

یک بردار دوروی S به صورت انسانی از فضای دوروی

که تعیین دسته مربوطه با نزدیکترین بردار دورویی W

$$\left. \begin{array}{l} W \text{ جذب به } S \\ W \text{ دفع از } S \end{array} \right\} \text{ تعیین } S$$

• فرم LVD

$S = (S_1, S_2, \dots, S_n)$

S بردار آموزشی

C دسته صحیح برای S


W بردار وزن واحد خردی W و A

C دسته ارائه شده واحد خردی W و A



$\|S - W\|$ فاصله اقلیدسی S و W

• شبکه سازی: بردارهای بردار \leftarrow اندیس در کتاب

• تعیین بردارهای دورویی به صورت تقریبی می تواند توسط SOM که می تواند این نتایج شود



سپس می تواند برای تنظیم دستورالعمل یادگیری با تقارن استفاده کرد



الگوریتم LVQ

۰. برداری شدن واحد α و مقدار اولیه α

۱. تا زمانی که شرط خاتمه برقرار است.

۲. برای هر بردار آموزشی


۳. بیشترین $\|S - w_j\|$ را پیدا کن

۴. بهنگام سازی w_j

$$w_j'(\text{new}) = \begin{cases} w_j(\text{old}) + \alpha (S - w_j(\text{old})) & C_s = C_j \\ w_j(\text{old}) - \alpha (S - w_j(\text{old})) & C_s \neq C_j \end{cases}$$

۵. بیشترین نرخ یادگیری α

۶. بررسی شرط خاتمه



Subject: _____

Year: _____

Month: _____

Date: _____

()

تعیین اولیای دانه

توزیع شاخص SOM

یک روش خوشه بندی k -means

m بردار اول دوری

m بردار انتهای از دوری

نسخه های دیگر kVQ

بجای آنکه تنها بردار بزنه که نزدیکترین بردار به بردار دوری است اصلاح شده

دومین بردار نزدیک به دوری (نایب بزنه) نیز اصلاح می شود. ($kVQ2$)

به شرط ارضای شروط زیر

بردار دوری متعلق به دسته نایب بزنه باشد.

فاصله بردار دوری تا بردار بزنه و نایب بزنه نزدیکتر باشد

S بردار دوری ، w_c بردار بزنه ، w_n بردار نایب بزنه
 d_c فاصله بزنه ، d_n فاصله نایب بزنه

$$\left. \begin{aligned} \frac{d_c}{d_r} > 1 - \epsilon & \quad \frac{d_r}{d_c} < 1 + \epsilon & (d_c < d_r) \end{aligned} \right\} \text{ شرط}$$

PAPCO S دسته = w_c دسته

$$W_c(\text{new}) = W_c(\text{old}) + \alpha (S - W_c(\text{old}))$$

بارش این سرخط

شماره 2.1 LVQ

در نظر گرفتن دو بردار نزدیکترین به ورودی

این بردار به شرطی اصلاح می شود که می توان آنها متعلق به کلاس صحیح برای ورودی S

دورتری متعلق به آن کلاس نباشد.

$$\min \left(\frac{dc_1}{dc_2}, \frac{dc_2}{dc_1} \right) > 1 - \epsilon$$

$$\max \left(\frac{dc_1}{dc_2}, \frac{dc_2}{dc_1} \right) < 1 + \epsilon$$

در این حالت برای بردار متعلق به کلاس دورتری S ← حذف

در برای برداری که متعلق به کلاس نیست ← دفع

• برای دسته بندی ورودی با دلتا برای کلاسی که استاندارد می شود.

با تفاوت

استاندارد از اطلاعات مربوط به دسته های ورودی


بردارهای عددی که در روش با تفاوت تعیین شده به طور جزئی تغییر می دهند.

• لوازمی که دسته برداری سلسله مراتبی

Subject:

Year: Month: Date: ()

اولاً عزیز ایمن برادری ← محاسبات سنگین ← مقاله فاصله درودی با تمام کتاب که
نویسنده اردن عجب در کتاب که ← ساختار سلسله مراتبی برای چند کتاب که در چلتر



شبکه‌های پرسپترونی جدید لایه (تجلی) در تاندن یادگیری پس انتشار خطا (پایخ) MLP BP

* نسخه استاندارد



• برای حل مسائلی که به صورت خطی جدا پذیر نیستند ← حل شدن ایراد دارد و به درجهت

پایخ فعالیت شبکه نباید بلای باشد
با اطلاعات ترنمه از لایه میانی به خروجی انتقال پیدا کنند

• معماری

دارای ۳ لایه یا بیشتر : لایه ورودی + لایه‌های خردی + لایه‌های مخفی

اتصالات کامل



Subject :

Year . . . Month . . . Date . . . ()

• تانن یادگیری : پس اشعار خطا / اشعار خطا - عقب / تانن انای تقیم یانه

• مراحل یادگیری

۱- اعمال دوددی آموزشی ← اشعار تا خردی ← محاسبه خردی

۲- مقایله خردی با مقدار مطلوب ← محاسبه خطا ← اشعار خطا به سمت دوددی

۳- به محیط در آمدن دوزها با درجه به خطای تعیین شده

• استخراج تانن BP

$$\underline{S}_P = \begin{bmatrix} S_{P_1} \\ S_{P_2} \\ \dots \\ S_{P_n} \end{bmatrix}$$

$$\underline{T}_P = \begin{bmatrix} T_{P_1} \\ T_{P_2} \\ \dots \\ T_{P_m} \end{bmatrix}$$

خردی مطلوب S_P

$$\underline{y}_P^{(e)} = \begin{bmatrix} y_{P_1}^{(e)} \\ y_{P_2}^{(e)} \\ \dots \\ y_{P_n}^{(e)} \end{bmatrix}$$

$w_{ij}^{(e)}$ وزن اتصال از واحد i در لایه $l-1$ به واحد j در لایه l

$$E_P = \frac{1}{2} \sum_j (t_{P_j} - y_{P_j})^2$$
 تابع خطا

$$I_{P_j}^{(e)} = \sum_k w_{kj}^{(e)} y_{Pk}^{(e-1)}$$

مغایب واحد j در لایه l برای لایه $l-1$

activation

$$y_{P_j}^{(e)} = f(I_{P_j}^{(e)})$$

خردی واحد j در لایه l برای لایه $l-1$

حل از تانل زنجیره ای داریم:

$$\frac{\partial E_P}{\partial w_{ij}^{(e)}} = \frac{\partial E_P}{\partial I_{Pj}^{(e)}} \times \frac{\partial I_{Pj}^{(e)}}{\partial w_{ij}^{(e)}}$$

$$\frac{\partial I_{Pj}^{(e)}}{\partial w_{ij}^{(e)}} = \frac{\partial}{\partial w_{ij}^{(e)}} \left(\sum_k w_{kj}^{(e)} y_{Pk}^{(e-1)} \right) = y_{Pi}^{(e-1)}$$

تنها برای $k=i$ مقدار شدن صفر نیست

$$\delta_{Pj}^{(e)} = - \frac{\partial E_P}{\partial I_{Pj}^{(e)}} \quad \text{افزایش}$$

$$- \frac{\partial E_P}{\partial w_{ij}^{(e)}} = - \nabla_w E_P = \delta_{Pj}^{(e)} \times y_{Pi}^{(e)}$$

تافل یادگیری را طوری در نظر می گیریم که مناسب با پیش دراستی برادین باشد.

• نزول در استادی برادین (Gradient Descent)

$$w_{ij}^{(e)} (\text{new}) = w_{ij}^{(e)} (\text{old}) + \eta \delta_{Pj}^{(e)} y_{Pi}^{(e-1)}$$

تعیین $\delta_{Pj}^{(e)}$ از طریق محاسب

$$\delta_{Pj}^{(e)} = - \frac{\partial E_P}{\partial I_{Pj}^{(e)}} = - \frac{\partial E_P}{\partial y_{Pj}^{(e)}} \times \frac{\partial y_{Pj}^{(e)}}{\partial I_{Pj}^{(e)}}$$

$$y_{Pj}^{(e)} = f_j(\cdot) \rightarrow \frac{\partial y_{Pj}^{(e)}}{\partial I_{Pj}^{(e)}} = f_j' (I_{Pj}^{(e)} \times \alpha_{Pj}^{(e)})$$

Subject:

Year:

Month:

Date: ()

$$E_P = \frac{1}{2} \sum (t_{pj} - y_{pj})^2 \rightarrow \frac{\partial E_P}{\partial y_{pj}} = -(t_{pj} - y_{pj})$$

سهای واحدی لایه خروجی (لایه آخر)

$$\delta_{pj} = (t_{pj} - y_{pj}) \cdot f'_j (I_{pj} \times \alpha_{pj})$$

سهای واحدی لایه مخفی

$$\frac{\partial E_P}{\partial y_{pj}^{(l)}} = \sum_k \underbrace{\frac{\partial E_P}{\partial I_{pk}^{(l+1)}}}_{\text{①}} \times \underbrace{\frac{\partial I_{pk}^{(l+1)}}{\partial y_{pj}^{(l)}}}_{\text{②}}$$

$$\text{①} = -\delta_{pk}^{(l+1)}$$

$$\text{②} = \frac{\partial}{\partial y_{pj}^{(l)}} \sum_i w_{ik}^{(l+1)} \cdot y_{pi}^{(l)} = w_{jk}^{(l+1)}$$

$$\rightarrow \frac{\partial E_P}{\partial y_{pj}^{(l)}} = - \sum_k \delta_{pk}^{(l+1)} w_{jk}^{(l+1)}$$

$$\delta_{pj}^{(l)} = f'_j (I_{pj}^{(l)} \alpha_{pj}^{(l)}) \times \sum_k \delta_{pk}^{(l+1)} w_{jk}^{(l+1)}$$

Back Propagation ← سهای واحدی لایه مخفی و لایه است

نتیج f بدست می آید

Subject:

Year: Month: Date: 5A

مثال برای تابع فعالیت لوجستیک

$$f(x) = \frac{1}{1+e^{-kx}} \Rightarrow f'(x) = k f(x) [1-f(x)]$$

$$f(x) = \frac{2}{1+e^{-kx}} - 1 \Rightarrow f'(x) = \frac{k}{2} [1+f(x)][1-f(x)]$$

الگوریتم آموزش شبکه

انتخاب متادیر اولیه و وزن متادیر لایه آغایی

1. تا وقتی شرط خاتمه اشتباه است

2. برای هر زوج بردار آموزشی (S_p, T_p)

3. محاسبه خروجی از لایه مخفی اول تا خودیها

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

$$y_{pj}^{(e)} = f_j \left(\sum_{i=0}^n w_{ij} y_{pi}^{(e-1)} \right), e > 1$$

4. محاسبه δ_{pj} برای واحدی خروجی

$$\delta_{pj} = (t_{pj} - y_{pj}) f' \left(\sum_{i=0}^n w_{ij} \alpha_{ij} \right)$$

5. محاسبه δ_{pj} برای واحدی مخفی

Subject: _____

Year: _____ Month: _____ Date: _____ ()

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

6. اصلاح درختی

$$w_{ij}^{(l)} \text{ (new)} = w_{ij}^{(l)} \text{ (old)} + \eta \delta_{pj}^{(l)} \cdot y_{pi}^{(l-1)}$$

7. آزمون شرط خاتمه (خطا کمتر از حدی / بزرگتر از اندازه خاص)

روی آموزش شبکه باینی الوریتم تجزیه آموزشی ملوک شبکه اعمال شود اصلاح درخت انجام گیرد

برادر که تجزیه آموزشی شبکه اعمال می شود را یک اپ (Epoch) گویند.

به همین دلیل آموزش MLP بسیار زمانبر است.

• الوریتم استفاده از شبکه

• درخت را به همراه متغیر یاد گرفته شده قرار می دهیم

1. اعمال هموار ورودی

$$y_i^{(1)} = f \left(\sum_{j=0}^n w_{ji}^{(1)} x_j \right) \quad 2$$

$$y_i^{(l)} = f \left(\sum_{j=0}^n w_{ji}^{(l)} y_j^{(l-1)} \right) \quad 3 \quad \text{برای بقیه لایه ها}$$


4. پاسخ = خروجی های آخرین لایه

• نمایش عملکرد شبکه


شبکه دارای یک تابع خطی یا انرژی است.

در این شبکه: حداقل کردن تابع خطی با نزول


در امتداد گرادیان



انتخاب مناسب نقطه شروع در رسیدن به جواب شبکه تأثیر زیادی دارد.



• مینیمم محلی



دقتی شبکه به نقطه مینیمم می رسد از هر طرف که می رود با افزایش خطای مواجه می شود.

شبکه نمی تواند از مینیمم محلی خارج شود ← مشکل روشهای مبتنی بر امتداد گرادیان

• ناحیه محاب

ناحیه ای که در هر دو نقطه داخل آن شبکه با یک خط به هم متصل کنیم آن ناحیه محاب می گویند.

• عملکرد MLP به عنوان دسته بندی کننده





برای برقراری ارتباط در فضای ورودیها رسم می کنند. (که در فضای دو بعدی: خط)

Subject: _____

Year: _____ Month: _____ Date: _____ ()

لايه مخفي 1 مجموعه اي از ابر صغيره ؟ — لايه پنهان : ترتيب ابر صغيره ؟ ترتيب لايه مخفي 1




تعداد نودها در لايه مخفي اول : تعداد ابر صغيره ؟ : تعداد ابر صغيره مخفي نهميه



اگر پس از لايه مخفي اول لايه مخفي ديگر تعداد دهيم ، خروجي بي لايه قبل داده توابعي مخرب

است به هم ترتيب مي دهند و توابعي پيچيده تر توليد مي کنند — توابعي غير مخرب ، غير منقل ...

7 نود در لايه ورودی در لايه مخفي




• با داشتن در لايه مخفي مي توان فقط داده بر شغل دلخواه ناصحيح بندي كرد پس بر مساله استه بندي با

يب سبله چهار لايه BP حل مي شود : 1 لايه ورودی + 2 لايه مخفي + 1 لايه خروجي

Subject :

Year _____ Month _____ Date _____ 90



• قدرت حفظ کردن شبکه (Memorization)


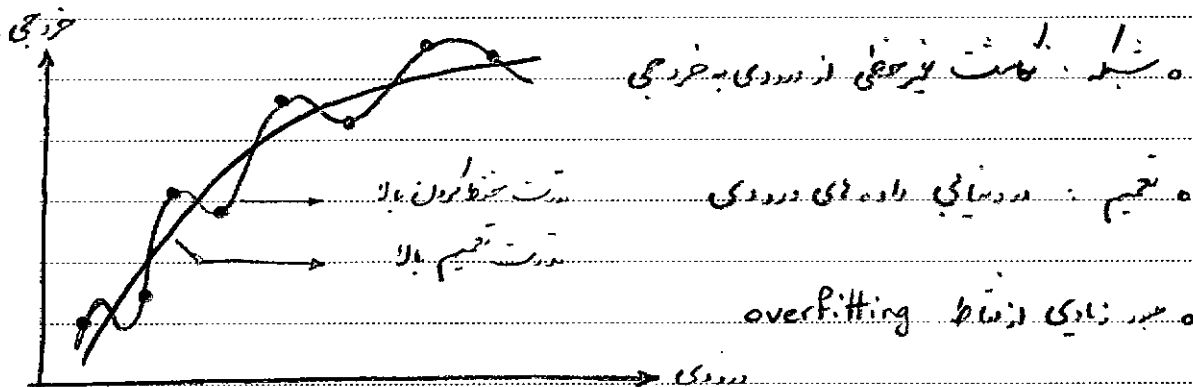
• توان شبکه در پاسخ دادن صحیح به نمونه‌های آموخته‌شده پس از خامه آموختن

• قدرت تعمیم شبکه (Generalization)

• توان شبکه در پاسخ دادن صحیح به نمونه‌های جدید پس از خامه آموختن


• قدرت حفظ کردن و قدرت تعمیم شبکه در مقابل هم قرار دارند ← نیاز به برقراری تعادل

• فرآیند یادگیری را می‌توان مشابه عمل به‌عنوان منحنی و تقویت $Curve Fitting$



Subject:

Year: Month: Date: ()



کتابی ادوات خطای زیادی را متحمل می شود

overfitting

تعداد زیاد زوج آموزش و با تعداد دفعات زیاد آموزش

شد → خطا دین نزوده ← لطف به بدت تقیم

تعداد واحدی تخمی ← افزایش ← بیش از حد نیاز


پیدا کردن مدل تخمی در حالت

شکل تخمی ← زمانی

برازش تخمی ← پارامترای زیاد ← خنثیات ویر و لوز

درون یا بیرون یا با معین

خلاصه: زیاد بودن واحد ← پارامترای ↑ ← تقسیم ↓ ← دنبال کردن جزئیات ↑



نردن در لایه تخمی

۳۰ نردن در لایه تخمی


۳ نردن در لایه تخمی

۵ نردن در لایه تخمی

• در سائل حاصل چندین اطلاعات منطقی در جهت خلاف این گفته در مسائل بنا شد، ساده ترین

در مدارترین تابع که حاصل را با صحت مورد نظر تعیین میزند انتخاب می شود به محاسبات کمتر

• با توجه به تعدادی موجود در شکل و نقصان اطلاعات پزشکی به تعیین همیشه از مواد مثبت



U : تمام دردها و خرابیها

R : تعدادین مورد نظر

T : مجموع آلودگی R

X : مجموع آلودگی

--- : تعیین

میں از آلودگی شکل اطلاعاتی در مورد T پیدا کرده ، نه X و یا R

تعیین ای شکل منطقی با T به تعدادش آلودگی است که جواب مورد نظر صحت مثبت می دهد

① اجباراً تعیین T را نمی پوشاند ② دوست داریم تعیین X را بپوشاند

* تقریب توانع با MLP

• عمده روشها بر مبنای از روش حداقل کردن مربع خطا ← عذر ذاتی MLP (😊)

• شکل های عصبی ناشی : تقریب توانع

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

پاداشن عذردهی (S_i, T_i) که

$$T_k = f(S_k)$$

Subject:

Year. Month. Date. ()

• اندازه آموزش : استفاده از نمونه برای یادگیری کماست

• اندازه آموزش : ارزیابی عملکرد با نمونه های محدود آموزش و اما آموزش


• معیار کار

• مربع خطای خودی : $F_k(x_k, w) = |f(x_k) - g_k(x_k, w)|^2$

• متوسط : $F(w) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N F_k(x_k, w) \geq 0$

• حد نفع برای بیشترین سطح ، با افزایش تعداد نمونه ، به مقدار خطای میانه می نرسد

• اندازه نمونه آموزش مناسب (N^*)




• به تدریج اندازه نمونه آموزش و آموزش را بزرگتر کنیم

• تا جاییکه خطای به سمت پایین نرسد ثابت میماند

• چه زمانی آموزش تعداد نمونه را بزرگتر کنیم - اگر خطای قابل تحمل در مطلوب باشد

• سطح خطای شتاب



• سطحی در فضای آموزش $F(w)$

• هدف آموزش - این سطح

Kolmogorov's Theorem

قضیه کولمگوروف

$$f: [0, 1]^n \rightarrow \mathbb{R}^m$$

تابع بردار پیوسته

تابع f را می‌توان به n ورودی خود سه لایه با n واحد ورودی در لایه اول، $2n+1$ واحد

مخفی، m واحد خروجی در لایه سوم می‌تواند سازد.

$$z_k = \sum_{j=1}^n \lambda^k \varphi(x_j + k\varepsilon) + k$$

واحد k لایه مخفی:

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

z : مقدار محقق ثابت، وابسته به n ، متعلق از f

φ : تابع حقیقی پیوسته، افزایشی، وابسته به n ، متعلق از f

$$\varepsilon = c\varepsilon \in \mathbb{Q} \quad (0 < \varepsilon < \delta)$$

g_j : تابع حقیقی پیوسته، وابسته به f و ε

قضیه کولمگوروف تنها محدود به سه لایه می‌باشد. برای میانه سازی بر تابع f و طرح می‌تواند φ و g را

تکرار تابع از $[0, 1]^n$ به هر یک محدود شده. قابل گسترش است. \leftarrow نشانه = بسته + کرانه

Subject:

Year. Month. Date. ()

• $\mathbb{R}^m \rightarrow [0, 1]^n : f$ درست باشد، می گویم f در \mathbb{R}^m است.

معین به \mathbb{R}^m است. اگر برای \mathbb{R}^m محقق f در \mathbb{R}^m واحد - سطح مربع قابل انقباض

$$\int_{[0, 1]^n} |P(x)|^2 dx \text{ محدود داشته باشد.}$$

از این تابع برداری از \mathbb{R}^m متغیر برداری \mathbb{R}^m باشد، هر یک از مولفه‌هایش می تواند به هر دو جهت صحت

درجه اول با سری نزدیک شدن نزدیک شود.

قضیه: فرض کنید

درجه $\epsilon > 0$. $f : \mathbb{R}^m \rightarrow [0, 1]^n$

این شباهت سه لایه اش را خط به خط در \mathbb{R}^m وجود دارد. f را با جداول متوسط خطی ϵ

تقریب زد. فضای \mathbb{R}^m شامل هر ناحیه که در عمل مطرح باشد می شود. (هر دو جهت صحت درجه اول)

• هر تابع f را می توان با یک شباهت سه لایه پایه سازی کرده. اما از تابع پیچیده باشد:

↑ تعداد نودهای لایه مخفی ↑ → تعداد درای لایه مخفی ↑

↓ تعداد سطوح لایه مخفی ↑ → تعداد درای لایه مخفی ↓

• نکته مهمی این شباهت: آموزش سخت

۲ پیاده سازی شبکه

۱۱ SOM استاندارد

۱۲ MSOM

الگوریتم آموزش شبکه MSOM Modified

۱. انتخاب تصادفی یک نمونه از برداری ورودی P و اعمال آن به شبکه

۲. یافتن نورون برنده

۳. تغییر بردار وزن نورون برنده بر طبق قانون کوپسون

۴. تکرار مراحل ۱ تا ۳ به تعداد دفعات اضافی

۵. متناوب عملکرد ورودیها و تعیین کم کارترین نورون و حذف آن از شبکه به نورون برده

۶. اضافه کردن یک نورون با بردار وزن تصادفی به شبکه

۷. بازگشت به مرحله ۱

پیشنهاد خردم ← یک heuristic برای ساخت مجدد مجدد

ساختن یک الگوریتم تطبیقی Steady State برای ساخت نورون جدید از روی ورودیهای موجود

Subject: _____

Year: _____ Month: _____ Date: _____

* عوامل مؤثر در بهبود عملکرد شبکه BP

I. انتخاب اولیه وزنها

• رسیدن یا نزدیک شدن به مینیمم محلی


• سرعت رسیدن به مینیمم عمومی

• الگوریتمهای اولیه خیلی خوب ← درابع فعالیت لایه آخر: اشباع ← تغییرات کم

← β کوچک ← اصلاح وزنها کند

• الگوریتمهای اولیه خیلی کوچک ← درددیابی خیلی لایه آخر: لایه کوچک ← اصلاح

وزنها کند



• معمولاً وزنها اولیه در

$$[-1, +1]$$

$$[-\frac{1}{2}, +\frac{1}{2}]$$

• پیشنهاد دیوید (widrow & Nguyen)

ابتدا همه وزنها به طور تصادفی از $[-0.5, +0.5]$

$$\beta = 0.7 \sqrt{P}$$

برای تعداد واحد n و تعداد واحد های لایه مخفی P

$$w_{ij} (new) = \beta \times \frac{w_{ij} (old)}{\|w_{ij} (old)\|}$$

تغییر وزنهای لایه مخفی

$$w_{oj} \in [-\beta, +\beta]$$

سپس باید مقدار بایاس اصلاح شود

باید لایه بسیار سریعتری شود

II. ارائه داده

• حل شدن اشکال سنگین - حل ساده تر / دینورتر

• پیوسته / گسسته - در محروم داده های مختلف

• یادگیری دسته بندی / مسائل نیمه نظارت شده / داده تر و سریعتر انجام می شود

• داده در تابع تلفات در قطبی در مقابل با همبرج اوج است

← یادگیری : واحد غیر فعال ← تاثیر در یادگیری

← در قطبی : واحد غیر فعال ← تاثیر در یادگیری ← بهبودی سریعتر

III. مقدار واحد های مخفی

• افزایش مقدار واحد واحد ← تصحیح کلاس مغزی غلط

← کاهش مقدار بینیم های مخفی (دنبال پیش از محدودیت)

Subject:

Year: Month: Date: ()

• اگر دو دسته سهام در بورس ایران یک دسته در نظر گرفته شود، سیستم محلی ایجاد خواهند شد.

• در مواردی تعداد واحدی معنی فیزیکی با هر دوری مرتبط است، با برابر تعداد گونه‌های

آموزشی تکرار داده می‌شود.

IV. تعداد گونه‌های آموزشی لازم

• نظریه Hussler & Baum

اگر ① شبده NW وزن داشته باشد، و ② صفای قابل قبول دو دسته بندی

آموزشی آزمایش E باشد، با انتخاب NW / E نوعی آموزشی در آموزش شبده

آزمایش صفای آموزشی آموزشی E12 بر سر، حداقل صفای E برای گونه‌های آزمایشی

حاصل خواهند شد

$$NW = 80, \quad E = 10 \quad \therefore \quad 0.1$$

$$\frac{80}{0.1} = 800 \rightarrow 5\% \text{ خطا}$$

لا. مجموعه‌های آموزشی آزمایشی و میزان آموزش شبده


• شبده BP در ابتدای یادگیری سعی بر ترتیب تابع ایک فرم هموار دارد ← لودینگ

Subject:

Year: Month: Date: ۹۵

• در ادامه آندیش نرم داده بیچیده تر شده از داده بهتر عبور کند. هر از حال

• تعادل: درونی و عبور از خط



• بیدار کردن با سعی در خط

x: نقطه وقت آندیش
تربیه: معادل نقطه توازن
شدن فضای آندیش

VI. شکل نمونه های آندیش و آزمائشی

• داده های زیاد → آندیش: نصف داده → بخشی که به مقدار سالیه آندیش داده شود.
 → آزمائشی: نصف داده

• داده های کمتر (مثلاً 1) → آندیش: همه داده → نقطه با نقطه شروع سطح آندیش
 F_Training مقدار

2. ما با روش 1 ما، نمونه آندیش هم در خط و برای
 نمونه ما هم محاسبه می کنیم → متوسط سعی خط
 سنجشی از جهت آندیش است → نقطه آندیش
 برابر در نقطه شروع سطح آندیش مقدار
 F_Training (leave one out)

3. جعل داده از روی داده های موجود
 که تغییرات در داده → نویزی بودن داده

Subject:

Year: Month: Date: ()

* برای حل یک مسأله بار محلی ذی بارندگیهای مختلف را در نظر بگیریم. در واقع یک

حالت سعی و خطا برای پیدا کردن روش حل داریم

* نحوه ذی مختلف داریم BP

• ضعف داریم: گذردن آموزش و ایراد آن در سیستم ذی محلی

• چاره اندیشی؟ ← روشهای مبتنی بر تغییر نحوه اصلاح وزنها


↓ روشهای مبتنی بر تغییر تابع فعالیت واحد؟

↓ برخی روشهای ترکیبی دیگر

* روشهای مبتنی بر تغییر نحوه اصلاح وزنها

• استفاده از لحتم (اینرسی)

روش تدریجی را استفاده کردیم برای رسیدن به سیستم و سهولتی مانند زیر در چهار شکل می بیند



برای ایجاد امیدواری و کاهش به درون اینرسی می دهیم

Subject:


Year: Month: Date: ۹۴

$$W_{ij}^e(t+1) = W_{ij}^e(t) + \alpha \delta_{p_j} y_{p_j}^{e-1} + \mu [W_{ij}^e(t)]$$

با افزودن جمله ایترشی - حالت با بهای بزرگتر - احتمال پرش از روی بینیم دی محلی

از افزایش سرعت بهای

حالت فقط در استوار برادبان در نظر نمی آید - در حالت برادبان در نظر نمی آید



Batch Mode - سیستم در آوردن دسته ای ازها

روش استاندارد آموزش الگوهای یادگیری (Pattern Mode) که در آن دی شبها پس

از اعمال برگرفته از سیستم می شود. در حالت استه ای، وزن دی شبها پس از اعمال تعدادی نمونه

استه ای می شود. در حالت استه ای متوسط خطای ایجاد شده در خروجی برای اصلاح درها استفاده می شود.


$$E_{avg} = \frac{1}{2L} \sum_{p=1}^L \sum_{j \in C} e_{p_j}^2$$

میانگین از خطای استه ای

$$e_{p_j} = t_{p_j} - y_{p_j}$$

c: مجموع داده های خروجی

تطبيق كرون نرغ ياديري



تطبيق كرون نرغ ياديري دلتا - باردت

بروزن اراي نرغ ياديري محفوظن شود - در نها به تدرج بازيان تغيري كند

تاسه تجربي براي اصلاح نرغ ياديري : ارا تغيرات وزن در چند دم سوالي ديك همت باش

نرغ ياديري ↑ دلي ارا عوض شود در همت كرون

نرغ ياديري ↓

$$W_{jk}(t) = W_{jk}(t-1) - \alpha_{jk}(t) \frac{\partial E}{\partial W_{jk}}$$

$$= W_{jk}(t-1) + \alpha_{jk}(t) \delta_k y_j$$

بروزن با نسبت ستادتي از مشتق تغيري كند - داسداد كرون با نسبت

$$\Delta_{jk} = \frac{\partial E}{\partial W_{jk}(t)} = - \delta_k y_j \quad \text{داحد خزجي}$$

$$\Delta_{jk}^{(e)} = - \delta_j^{(e)} y_j^{(e-1)} \quad \text{داحدي لايه مخفي e}$$

Subject:

Year: Month: Date: ۶۸

$$\bar{\Delta}_{jk}(t) = (1 - \beta) \Delta_{jk}(t) + \beta \bar{\Delta}_{jk}(t-1) \quad \text{لايه خردجي}$$

$$\bar{\Delta}_{ij}^e(t) = (1 - \beta) \Delta_{ij}^e(t) + \beta \bar{\Delta}_{ij}^e(t-1) \quad \text{لايه فني ل}$$

ايجاد صورت $\rightarrow 0 < \beta < 1$

$$\alpha_{jk}(t) = \begin{cases} \Delta_{jk}(t-1) \times \bar{\Delta}_{jk}(t-2) > 0 & , \alpha_{jk}(t-1) + \chi \\ \Delta_{jk}(t-1) \times \bar{\Delta}_{jk}(t-2) < 0 & , \alpha_{jk}(t-1) \times (1 - \lambda) \\ \text{otherwise} & , \alpha_{jk}(t-1) \end{cases}$$

سه پارامتر آزاد $0 < \beta, \lambda, \chi < 1$ در دسترس!

$\chi \downarrow$: راندهاي نه چندان توي دولتها \rightarrow ترميم دارد
 $\chi \uparrow$: روشن از دست راندها

□ سنه XOR ۲ بيتي با شبيهه ۱۰: ۱۰: ۹

۲۰ با شبيهه سازي \rightarrow داده آيه شدن


استاندارد < با ديري تغير < دتا باره دتا < مستم : ميايدين دتا دتا، جديدي

□ شناسايي چهار حرف A, B, C, D با شبيهه چهار لايه ۴: ۲۰: ۲۰: ۱۲۸

مستم < استاندارد < برخ با ديري تغير < دتا باره دتا

Subject:

Year. Month. Date. ()



کامیاب سازی تابع XOR در بین با سبب سه لایه ۲:۲:۱

اصلاح روزها: Batch
 خفایه یادگیری: با رسیدن مجموع مربع خطا به ۰.۰۵ در هر بار متوسط لری شده به اندازه ۰.۰۴
 درمایش با ۲۵ بسته تعداد اولیة محاسبات

متغیر پارامتر	α	μ	λ	γ	β
استعداد	0.1				
ختم	0.75	0.9			
ΔΔ	0.8		0.035	0.333	0.75

نتیج	تعداد شیر سازی	تعداد بهرمانی	تعداد متوسط دور بهرمانی
استعداد	۲۵	۲۴	۱۹۸۴۰
ختم	۲۵	۲۵	۲۰۵۶
ΔΔ	۲۵	۲۲	۴۴۷

در هر بار که شد سریع است

* لایه های مبسوطی بر تغییر تابع فعالیت واحد

• اگر تابع فعالیت یادگاران باشد
 $f(-x) = -f(x)$
 سرعت یادگیری ↑

Subject:

Year: _____ Month: _____ Date: ۹/۸

1

تابع سیگموئید باثیری

$$\frac{1}{1 + e^{-\alpha x}}$$


تابع سیگموئید دو قطبی

$$(b-a) \frac{1}{1 + e^{-\alpha x}} + a$$

تابع سیگموئید با محدوده و نخوابه $[a, b]$

$$(b-a) \frac{1}{1 + e^{-\alpha(b)x}} + a$$

تابع سیگموئید با شیب متغیر



α متغیر ← بهر چه مقدار بیشتر
 فاصله دانه
 α ↑ ← شیب ↑

$$X = \alpha_k^{(e)} \mathbf{I}_{PK}^{(e)}$$

$$y_{PK}^{(e)} = f(X)$$

$$\delta_{Pj} = [t_{Pj} - y_{Pj}] f'(y_{Pj}) \quad \text{لایه خروجی}$$

$$\delta_{PK}^{(e)} = - \sum_k \delta_{PK}^{(e+1)} \alpha_k^{(e+1)} w_{jk}^{(e+1)} f'(y_{Pj}^{(e)}) \quad \text{لایه مخفی}$$

$$\Delta w_{jk}^{(e)} = \eta \delta_{PK}^{(e)} \alpha_k^{(e)} y_{Pj}^{(e-1)}$$

$$\Delta \alpha_k^{(e)} = \eta \delta_{PK}^{(e)} \mathbf{I}_{PK}^{(e)}$$

استاندارد از ورودی تنظیم ، سایر روشهای تطبیقی ، مدل های شبکه

Subject:

Year . Month . Date . ()

* سر لداک از دوشه سده به نوح سده هجری بدر علی می کند کوشش منتم در دوشه سال کینی

Radial Basis Function Networks شبکه های تابع پایه شعاعی

* جدایی پذیری الگو

در این شبکه بعد از ورودی را بالا بردن می توانیم به جدایی پذیری الگو دست پیدا کنیم

$$X = \{ \underline{x}_i \} \Rightarrow \forall \underline{x}_i : \underline{x}_i \in X^+ \vee \underline{x}_i \in X^-$$




$$\Phi(\underline{x}) : \mathbb{R}^n \rightarrow \mathbb{R}^m \quad , \quad m \geq n$$
$$\Phi(\underline{x}) = [\varphi_1(\underline{x}), \varphi_2(\underline{x}), \dots, \varphi_m(\underline{x})]^T$$

اگر مجموعه $\{X^+, X^-\}$ از X با Φ جدایی پذیر است، آنگاه هر بردار m تایی w وجود خواهد داشت که:


$$\begin{cases} \underline{w}^T \Phi(\underline{x}) > 0 & \underline{x} \in X^+ \\ \underline{w}^T \Phi(\underline{x}) < 0 & \underline{x} \in X^- \end{cases}$$

اگر بعضی از سطح جدا کننده Φ وجود نداشته باشد


$$\underline{w}^T \Phi(\underline{x}) = 0$$



XOR



$$\varphi_1(\underline{x}) = e^{-\|\underline{x} - \underline{c}_1\|^2}$$
$$\varphi_2(\underline{x}) = e^{-\|\underline{x} - \underline{c}_2\|^2}$$
$$\underline{c}_1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad \underline{c}_2 = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$



بدون افزایش بعد هم می توان شبکه های جدایی پذیر پایه شعاعی را به جدایی پذیر تبدیل کرد

• در نهایت لایه خروجی باید روش RMS قابل باین است.

• می توان پس از انجام آموزش شبکه پهنای را محدود کرد آموزش داده را تنظیم کنیم « α »

* تقسیم نرم تابع از تبدیل شعاعی به تانگن هیپیدی Radial Sym \rightarrow Elliptical Sym


• جایگزینی $(z_j - x_j)$ با β_j / $(z_j - x_j)$

• می توان تعداد واحدهای لایه مخفی را کاهش داد.

• توانایی ما در کاربرد استنبذی بالایی دور از پایه به چینی

• عملکرد شبکه در کاربرد شناسایی الگو در تریب نزاع بهبودی یابد \rightarrow شبکه RBF تقسیم یافته

• تبدیل فاصله اقلیدسی به فاصله مانجی لاندریس



* یادگیری با انتخاب با تفاوت مرکز

• مراکز RBF همه پارامتری دیگر تحت یک فرایند یادگیری با تفاوت انتخاب می کنند

• استفاده از روش نزاع در اسناد مهم است

Subject:

Year: _____ Month: _____ Date: _____ ۷۲

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

↓
نرم D_i

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

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

$$E_0 = \frac{1}{2} \sum_{j=1}^L e_j^2$$

برای تعیین w_i ، c_i ، و S_i^{-1} به طور جداگانه محاسبه می‌شود.

با استفاده از روش نزول درامندگامی

$$w_i(n+1) = w_i(n) - \eta_1 \frac{\partial E(n)}{\partial w_i(n)}$$

— درجه اولی لایه خروجی

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

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

— براثر نزاع

$$\frac{\partial E(n)}{\partial c_i(n)} = 2 w_i(n)$$

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

— توزیع لایه

Subject :

Year : Month : Date : ()

$$\frac{\partial E(n)}{\partial S_i^{-1}(n)} = -\omega_i(n) \sum_{j=1}^L e_j(n) G'(\|\underline{x}_j - \underline{c}_i(n)\|_{D_i}) Q_{ji}(n)$$

$$Q_{ij}(n) = [\underline{x}_j - \underline{c}_i(n)][\underline{x}_j - \underline{c}_i(n)]^T$$

به دلیل نزول در استاندارد بردار \underline{c}_i محلی است در مینیمم گرفته شود.

* تقریباً مربع باشد RBF

مجموعه \underline{x}_i و متاثر متناظر d_i تابع f درونیاب

$$\underline{x}_i \in \mathbb{R}^n, \quad d_i \in \mathbb{R}, \quad i=1, \dots, h$$

$$f(\underline{x}_i) = d_i, \quad i=1, \dots, h$$

$$f(\underline{x}_i) = \sum_{j=1}^L \omega_j \varphi(\|\underline{x}_i - \underline{c}_j\|)$$

$$= \sum_{j=1}^L \omega_j \varphi_{ij}$$

φ_{ij} تابع پیراسته‌شده φ درجه

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

$$\underline{w} = \Phi^{-1} \underline{d}$$

Φ ماتریس درونیابی

Subject:

Year: _____ Month: _____ Date: ۷۳

• گونه های از براج φ

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

• پارامتر شیب اثر براج

$$\varphi(x) = \frac{x}{\sigma^2} \log \frac{x}{\sigma}$$

$$\varphi(x) = \sqrt{x^2 + \sigma^2}$$

$$\varphi(x) = \frac{1}{\sqrt{x^2 + \sigma^2}}$$

• مثال RBF و MLP

	RBF	MLP
سرعت	↑↑	↓↓
بهره ای تعیین شده	✓	x
زمان براج	↑	↓
حافظه	↑↑	↓
تعین	↑	↓

۳. پایه های شیب RBF → RBF تقسیم یافته

• سته بندی

• تقریب براج

Optimization

© بهینه سازی

* در مسئله بهینه سازی تابعی به نام تابع هزینه وجود دارد. هدف پیدا کردن حداقل آن است.

* روش های سنتی بهینه سازی

- فرایب خطی لاگرانژ
- برنامه ریزی خطی
- رنا بهینه سازی پویا

* بهینه سازی با شبدهای عصبی

• الگوریتم های خوب عمل می کنند

• در مواردی که روشهای سنتی خوب عمل نمی کنند، شبدهای عصبی جوابی نزدیک به بهینه می دهند.

این بهینه سازی تحت محدودیتهای مسائلی

• انواع شبدهای عصبی

- دقیق (deterministic)
- شکل برنامه ریزی در سیستم های محلی
- تصادفی (stochastic)

Annealing

* تابکاری منفذات

• گرم کردن منفذات تا نزدیک ذوب سپس سرد کردن تدریجی

• رفع تداخلات سیستمی شبدهای ارتباطی

• اختلالات جدید ایجاد نمی شوند.

Subject:

Year: Month: Date: V*

$\{\alpha_i\}$

مجموعه حالات ممکن یک ذره

E_{α_i}

انرژی هر سیستم در حالت α_i

T

درجه حرارت هر سیستم
که در T نزدیک به صفر مطلق باشد سیستم دارای ذرات حرارتی خواهد بود.

ذرات حرارتی: اشغال از حالتی به حالت دیگر انرژی را به طور خفیف کم یا زیاد می کند.

حالت تعادل حرارتی: ذرات سیستم سهم مساوی مدورظ ثابتی و از این مساوی دور نمی شود.

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

احتمال رفتن سیستم به حالت α_i از حالت تعادل
(تابع توزیع بولتزمن - لیست)

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

تابع احتمال بولتزمن

فرض $k_B = 1$

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

$$T \rightarrow \infty \Rightarrow \frac{P_{\alpha_i}}{P_{\alpha_j}} \rightarrow 1 \Rightarrow P_{\alpha_i} = P_{\alpha_j}$$

یعنی در حرارت بالا، احتمال رفتن سیستم به حالت با انرژی بالاتر مساوی احتمال رفتن سیستم

به حالت با انرژی پایینتر ← انرژی هم بالا می تواند برود هم پایین ← نه از سیستم محلی

Subject:

Year. Month. Date. ()

Simulated Annealing (SA)

* شبیه سازی تابکاری

Analogy • تابع انرژی همبسته سازی به تابع انرژی فنر

متغیرهای مسئله به ذرات فنر

تبدیل نقاط استثنائی به تابع هزینه را کاهش می دهد به کاهش بروج دما

گراحتداد در سیستم محلی به ترک برداشتن واحدهای انرژی

اجازه بالارفتن از سیستم محلی به

روش SA یک جنبه استاتی به روش نزول در استعدا گراحتداد اضافه می کند که با پایداری کنترل می شود


• الگوریتم هم اجازه انتقال به انرژی بالاتر را می دهد و هم پایبند

$$\alpha_i \rightarrow \alpha_j$$

$$E_{\alpha_i} \rightarrow E_{\alpha_j}$$

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

$$\Delta E \begin{cases} \text{احتمال پذیرفته شدن انتقال} = 1, & \Delta E \leq 0 \\ \text{احتمال پذیرفته شدن انتقال} = e^{-\frac{\Delta E}{T}}, & \Delta E > 0 \end{cases}$$



$$P(\Delta E) = \begin{cases} e^{-\Delta E/T}, & \Delta E > 0 \\ 1, & \Delta E \leq 0 \end{cases}$$

* حالت اول $f(x)$ ، x باری

$$e^{-\frac{\Delta E}{T}} > 0.999$$

1. انتخاب تصادفی بر دامن x
انتخاب مقدار اولیه نزدیک T بظرف

2. انتخاب نزدیکه x از x با تصادفی بیزاخت

3. بوقت x' همه نزدیکه ای x' برابر x بجز نزدیکه $(\alpha_i = \bar{\alpha}_i)$

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

4. اگر $\Delta E < 0$: $x = x'$

5. اگر $\Delta E \geq 0$: x را با احتمال $e^{-\frac{\Delta E}{T}}$ برابر x' قرار دهیم

• انتخاب تصادفی بیزاخت ξ از $[0, 1]$

• اگر $\xi < e^{-\frac{\Delta E}{T}}$ باشد $x = x'$ در غیر این صورت تغییری نماند

6. اگر M بار تغییر بوقت x باشد N بار تغییر x از زمان آخرین تغییر در همه حرکات

$$T = \alpha \cdot T \quad , \quad 0.8 < \alpha < 0.999 \quad \text{و } \alpha \text{ باری}$$

7. اگر مقدار حداقل P در M بار آخر بیش از ϵ تغییر نیافته \rightarrow خاتمه

در غیر این صورت \rightarrow قدم 2

$$N \ll M$$

Subject: _____

Year: _____ Month: _____ Date: _____ ()

• میدانی در پی نهایت → جوابی خوب پیدا نمیشود

• توابع خوش رفتار → تعداد زیاد بود نیاز به عدم

جوابی بدست آمده نزدیک به پاسخ بهینه

* اعمال روش SA بیشتر در پیله بسته

• تغییر تابع تبدیل

$$y_i \text{ (new)} = \begin{cases} y_i \text{ (old)} & \text{otherwise} \\ -y_i \text{ (old)} & \Delta E < 0 \\ -y_i \text{ (old)} & \Delta E > 0 \wedge \epsilon < e^{-\frac{\Delta E}{T}} \end{cases}$$

$$\Delta E = 4 \sum_{j=1}^n y_j \text{ (old)} [\sum_{j=1}^n y_j \text{ (old)} - \theta_j]$$

• اگر بیش از حد حرارت : تعداد زیاد بسیار می‌شود / اگر بیش از حد انرژی

• پایخ صحتی در پایله می‌ماند تعداد معمولاً نزدیک به پاسخ بهینه است

• بعضی در این شده بولتزمن می‌گویند (Hopfield + SA)

• مانند شده در پیله تعداد یک واحد بسیار می‌شود → انتخاب صحتی

Boltzman Machine

* ماشین بولتزمن

• رسال ۱۹۸۳ توسط هینتون و سمخوفسکی

• واحد دارای حالت باثباتی در احوال احتمالی

• وزن و انرژی مقادیر ثابت - آموزش نماد

• بدون نیاز به نشاندن از میزان مطلوبیت فعال بودن نرون واحدی خارجی

• مجموعه‌ای از واحدها ، اتصالات دو طرفه و وزنهای متقابل ، امکان خوداتصال

• هدف : حداقل کردن تابع آرا (Consensus Function)

$$C = \sum_i \sum_{k \neq j} y_i^k y_j^k$$

• حداقل کردن تابع فریدر توسط SA

• اگر واحد از اجازه تغییر حالت داده شود

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

• شبیه این تغییر حالت را با احتمال زیری پذیرد


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

• کاهش تدریجی T

Subject :

Year . . . Month . . . Date . . . ()

معادری و استیجاب کاربرد — تعداد دورهای و زمانه . . .



آرایه در لابی
 الفصالت قابل در طول ستون
 وزن ثابت
 -P برای همسایه و
 b برای خودش

وزن بین واحد (I, J) و (I, I)

$$\omega(I, J; I, I) \longrightarrow \omega(I, I; I, I) = b$$

$$\omega(I, I; I, J) = -P$$

اهدایم

1. متاخر اولیه وزنها — محدودیت نمی سئد و اور بر لید

متلا اولیه ونا ← T₀

متلا اولیه واحد ← با بیزی و لهادنی

2. تا رضایتن شرط خانه

3. $1 \text{ epoch} = n^2$ ، در اینجا دهید

4. انتخاب مقدار صحیح I بین 1 و n

5. محاسبه تغییر تابع آرا

$$\Delta C = [1 - 2 U(z_{ij})] [b + \sum_{j: j \neq I} \sum_{j: j \neq I} w(z_{ij}, I, j) U(z_{ij})]$$

6. احتمال تغییر حالت

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

7. تقسیم لری در مورد قبولی یا رد تغییر حالت

قبولی : $z_{ij} = 1 - z_{ij}$

رد : $z_{ij} = z_{ij}$

8. کاهش T $T(\text{new}) = 0.95 \times T(\text{old})$

9. شرط خاتمه

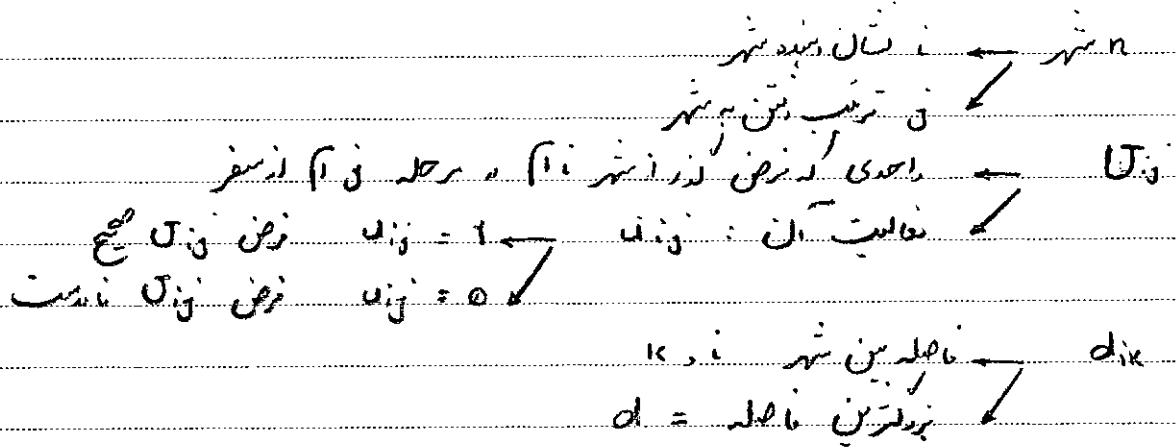
• دمای سردانی ؟

• حد تغییر برای مدت زمانی ؟

Subject: _____

Year: _____ Month: _____ Date: _____ ()

حل مسئله فروشنده دوره گرد (TSP) با این روش



	1	2	...	n
A	U_{A1}	U_{A2}		U_{An}
B				
⋮				
J	U_{J1}			U_{Jn}

جدول: U_{ij} در جدولی
بر شرط شهر
بر ستون ترتیب عبور

در هر ستون فقط یک عدد در هر شرط فقط یک عدد فعال خواهد بود (شرایط سفر)

معادلی: خود انتخابی بودن p - مطلوبیت عبور از شهر i
 اتصال به همه واحدهای سفر p - اتصال به سایر واحدها در شرط i = ایجاب عبور از شهر i
 اتصال به سایر واحدها در شرط i = اتصال واحدها در شهر i

اتصال واحد i از n به واحد $i+1, j, k$ با وزن d_{ik}

که اتصال فاصله طی شده از شهر i تا شهر k در مرحله $i+1$ از n

$p > d$: تابع آ را برای یک راه حل قابل تبدیل مقدار بودلتری دارد تا راه حل غیر قابل قبول
 $p > 2d$: تابع آ را برای یک راه حل قابل تبدیل و بهتر مقدار بودلتری دارد تا راه حل قابل تبدیل طراحی تر

Group Method of Data Handling

نمودار GMDH

* ترتیب آیراخنسکو، ۱۹۶۸، برای پیدا کردن جمعیت‌های در درختچه‌ها؟ در این ترتیب


* کاربرد آن عمدتاً برای ترتیب تابع بردار

f: R^n -> R

برای ترتیب تابع برداری باید برای هر دو تابع بردار خروجی همین نمودار داشته

* معماری

• هر واحد دارای تنها دو ورودی به جز واحدی پایه ورودی



• تابع تبدیل

z_k^e = a_k^e (z_i^{e-1})^2 + b_k^e (z_i^{e-1} z_j^{e-1}) +

c_k^e (z_j^{e-1})^2 + d_k^e (z_i^{e-1}) + e_k^e (z_j^{e-1}) + f_k^e

• بازتابش بر لایه‌ها و شبکه‌ها درجه چند جمله‌ای ایجاد می‌کند در ۲ ضرب می‌شود و در شبکه‌ها به خازن

ورودی h سطح داشته باشیم چند جمله‌ای از درجه ۲ خواهد بود ← چند جمله‌ای آیراخنسکو

Ivakhnenko

Subject:

Year: _____ Month: _____ Date: _____ ()

* ساخت شبکه

• عمل ساخت لایه به لایه

• در هر لایه برای هر زوج خروجی لایه قبل یک واحد تهارمی داریم

$$\begin{aligned} & \bullet \text{ تعداد واحدها در لایه } l \text{ برابر } n_l \\ & \text{تعداد واحدها در لایه } l+1 \text{ برابر } \binom{n_l}{2} \end{aligned}$$

• هر لایه که اضافه می شود به طر استیل تعیین داده و ثابت می شود.

• هر واحد در هر لایه (به جز دودی) تلاش می کند خروجی خودش را به بهترین حالت برساند.

• تنظیم 4 پارامتر بر واحد با استفاده از تعداد زیادی نمونه دودی - خروجی انجام می شود.

• هر لایه که اضافه می شود، به طر استیل از سایر لایه ها تعیین داده می شود و هر لایه به طر استیل آموزش

داده می شود. این موضوع باعث می شود در آن هم لایه ها آموزش برکت می کند متفاوت است

• اعمال دودی SP خروجی لایه $l-1$ را تولید کند و به l می رود.

• هر واحد می خواهد متدله مطابق t_p را تولید کند ← آموزش t_p .

• برای هر واحد به هر نمونه آموزشی $\langle s_p, t_p \rangle$ یک معادله 4 مجهول

• هر لایه با کمک عدد آموزشی جدید آموزش داده می شود.

• بدست آوردن پارامترها : معادلات حاصل از آموزش یک واحد را در لایه l

$$\begin{bmatrix} (x_i^{l-1})^2 & (x_i^{l-1} \times z_j^{l-1}) & (z_j^{l-1})^2 & x_i^{l-1} & z_j^{l-1} & 1 \\ \vdots & & & & & \end{bmatrix} \begin{bmatrix} a_k^l \\ b_k^l \\ x \end{bmatrix} = \begin{bmatrix} t_1 \\ t_2 \\ \vdots \\ t_e \end{bmatrix}$$

$$T, z_k^{l-1} \Rightarrow z_k^{l-1} \times P_k^l = T$$

• این معادله دارای پاسخ تقریبی خواهد بود. چون غیر مقل است هرگونه آموزشی خروجی مطلوب تولید کند.

• حداقل کردن خطا (MSE)

$$P_k^l = \underbrace{(z_k^{l-1})^+}_{\text{Generalized Inverse}} \cdot T$$

• با تعیین پارامترهای هر واحد در سطح l عملکرد هر واحد در اسپین به هدف حداقل کردن MSE یک

مجموعه آزمونهای آموزشی ارزیابی می شود. ← r : تعداد نمونه های مجموعه آزمونهای

$$e = \frac{1}{r} \left\| z_k^{l-1} P_k^l - T \right\|^2$$

• اولین خطا (e) برای واحدی از یک مدله جدا کننده نزدیکتر باشد، واحد مذکور را حذف می کنیم.

این روش واحدی پس از دیگری در لایه ایجاد می شود تا جاییکه معیار توقف ارضا شود.


Subject: _____

Year: _____ Month: _____ Date: _____

• روند: ترکیب هر صفت نودون ← آموزش

دوردهای ← ساختن لایه
استفاده گیری
عایق سازی


• چندی وقت: در هر لایه لاچترین MSE را پیدا می کنیم



• همین تعداد لایه کافی است: e^*

نودون دارای کمترین e را خروجی در نظری می گیریم و بهترین نودونهای لایه e^* را حذف می کنیم

• سپس اتصالات و نودونهایی که منتهی به خروجی می شوند را حذف می کنیم. این روش نظم شبکه را



• محوه تعیین اندازه مجموعه آموزشی

• باید مجموعه پارامترها را محاسبه کنید

• اندازه این مجموعه را زیاد کرده و مجدداً محاسبه کنید

• در تغییر پارامتر زیاد نباشد، اندازه مجموعه آموزشی کافی بوده است

۳. شبکه GMDH

Adaptive Resonance Theory

© نظریه تشدید تطبیقی

* ۱۹۸۷، کورامبرگ

- * منجر به توسعه سه شبکه ← ART 1 : خوشه بندی پیرامی پایداری
- ART 2 : خوشه بندی پیرامی پایداری
- ART 3 : اصلاح شبکه ART
- نوع: Fuzzy ARTMAP, ARTMAP

* مسائل مطرح شده

• بایاداری شبکه

• یادگیری از نمونه های مجددی یک سیستم آموزش دیده ← Incremental learning

* بدون بودن نرخ یادگیری در یادگیری رقابتی

• تضمینی وجود ندارد که دسته بندی تشبیل شده پدیدار باشد

• دسته بندی های نمونه ای ممکن است بدون پایا تغییر کنند

• راه حل: کاهش تدریجی نرخ یادگیری ← از دست رفتن توان شبکه برای یادگیری گونه های جدید

• مسئله بایاداری رقابتی شبکه مقابل هم هستند. Stability - Plasticity

Dilemma

Subject:

Year _____ Month _____ Date _____ ()

• حتی اگر مسئله بایزاری - تاثیر پذیری حل شود باز هم تعداد دستة یا هزینه که توسط اقواد

ندروهای لایه آخر مشخص می شود ← عدم امکان تولید هزینه جدید

شکل عدم تعلق داده جدید به هیچ دستای

• راه حل دیگر: با ورود هزینه جدید، تمام هزینه از اول کمزش داده شود ← هزینه بر

* شکل ART 1

• دستبندی داده های بازاری
تدائلی تغییر حالت بین در حالت تاثیر پذیری و بایزاری

• در حالت تاثیر پذیری: بایزاری در تغییر پارامترهای شکل

• در حالت بایزاری: بدون هزینه - بایزاری قبلی شکل، دستبندی ثابت

• معماری

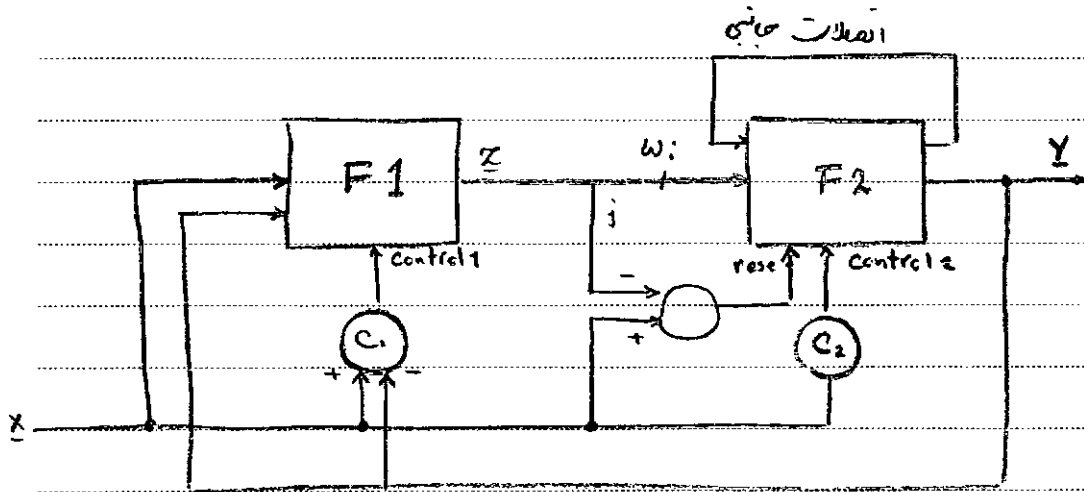
دولایه اصلی - لایه ورودی ، متابله ، F1

لایه خروجی ، هزینه بندی ، F2

تدائلی شکل اضافی برای کنترل جواب داده در هر مسئله (تبدیل تکلیفی مسئله)

Subject: _____

Year: _____ Month: _____ Date: _____




شبه دارای تطابق reset کردن واحدی خروجی

دردی در این مدار است که برانقب (Vigilance) مانع می شود دقیق شدن اندازه های اصلی و جدید ورودی باید دست جدید ایجاد شود یا غیر

دولای شبه با اتصالات اطالی بین خود و این خود

واحدی خروجی دارای اتصالات جانبی

تالیین دیر



محکمہ انسداد

I. تازیقین معیار اولیہ

- جرمان واحد؟ در لایہ ورودی توسط 1 control تعیین می شود.
- مقدار این سیگنال با تیزی است ← حالت ورودی 1 :
- حالت متابہ ← 0 :
- C1 برابر است اگر ورودی غیر صفر باشد (عمل شود)
- دقت کمی از واحدی لایہ خروجی نقل می شود، C1 ایجاد صفر می شود

سیگنال C2 لایہ خروجی را فعال یا غیر فعال می کند

برای هر عددی ورودی قابل قبول، C2 برابر 1

Vigilance Test

پس از آزمون مراقبت، C2 برابر 0

مقدار صفر بجای C2 واحدی لایہ خروجی را غیر فعال می کند خروجی کمی آنرا صفر

معیار اولیہ W_{iz} برابر 1

معیار اولیہ W_{iz} برابر $1/(n+1)$ ← n تعداد ورودی

$$0 < P < 1$$

مقدار آستانه نزدیک به 1

II. تازیقین معیار

ورودی لایہ ورودی X

خروجی لایہ دوم (لا) C_1

کنترل عبور ورودی از این لایہ : قانون $\frac{2}{3}$ → اگر دو تا یا بیشتر از این ورودی؟

فعال باشد. از واحد تکدی خروجی 1 در غیر این صورت 0 صادر می شود.

شماره 2 - نشانه‌های باشد در خروجی داده.

هر بردار وزن W در هر واحد لایه خروجی یک الگوی ذخیره شده می باشد.

بردار ورودی X الگوی ذخیره شده مقابله می شود (با W) و بهترین تطبیق را

این کار را محاسبه حاصلضرب داخلی X و بردارهای وزن مشخص می شود.

$$|X \cdot W| \cos \theta$$

و بردار نزدیکتر

مکان است چند واحد خروجی در پاسخ به ورودی دارای فعالیت تری باشند
 - فعالیت بازدارنده جانبی بین واحدها در حالت آماده رخ داده می شود و دارای بهترین
 پاسخ است بسته به آموزش می شود.

حالت واحد بردار الگوی ذخیره شده را به لایه ورودی ارسال می کند.

این الگو به صورت باینری به وزن های فعالیت بازگشتی ذخیره می شود.

III. بازتاب

لایه خروجی دارای یک واحد فعال $C_1 = 0$

ورودی X و خروجی لایه دوم که دیگر ورودی های واحد های خروجی لایه اول را تأمین می دهند

به استفاده از تأمین $\frac{1}{2}$ خروجی لایه مشخص می شود.

به محال AND بودن بردارهای ورودی خارجی بردار ذخیره شده گفته

به بردار متابله C_1

این بردار بردار لایه بخش reset داده می شود.

Subject: _____

Year: _____ Month: _____ Date: _____ ()

در این بخش reset میزان نشانه برابری در دو طرف حساب در رابطه با آستانه برابری متالیه می شود.

$$r = \frac{\text{تعداد 1 ای متالیه در } X}{\text{تعداد 1 ای } X} = \frac{\sum_i V_i X_i}{\sum_i X_i}$$

$r > p$: خانه استه بندی ← واحد فعال لایه F2 : دست X

$r < p$: شباهت اندک ← بهترین الگوی گذشته برای X برپا شده است ← باز جستجو

IV. باز جستجو

شبهه سعی خواهد کرد الگوی ذخیره شده در محبت تطبیق برابری در دو طرف پیدا کند

← ابتدا واحد فعال خروجی را غیر فعال و خروجی آنرا صفر می کنیم (خروج از سابقه)

← این واحد در نقش بهترین تطبیق دهنده برای این ورودی شرکت می کند

$$e_1 = 0$$

دوباره ورودی به لایه دوم اعمال می شود و بهترین تطبیق برست می آید (برنده خوبی)

شبهه دوباره دارد باز متالیه می شود ← آزمون برای ارزشی متالیه آستانه

تعداد آید شدن واحد مناسب

از چنین واحدی پیدا شود، شبهه ورودی جدید را به یک واحد جدید نسبت می دهد.

← یعنی در لایه F2 واحد جدیدی را به وجود می آورد ← افزودن دسته جدید به شبکه

Subject:

Year: Month: Date: ۸۳

درجه بندی (تسدید) : داده ها ابتدا از ورودی به خروجی در ماتریس حرکت می گذرانند
به نتیجه می رسند

• الگوریتم ART 1

1. تعیین مقادیر اولیه

$$p = 0.9$$

$$v_{ij}(0) = 1$$

$$0 \leq j \leq n-1$$

$$w_{ij}(0) = \frac{1}{1+n}$$

$$0 \leq i \leq n-1$$

2. اعمال ورودی جدید پسند

3. محاسبه میزان تطبیق با ورودی عرضه w

$$\mu_j = \sum_{i=0}^{n-1} w_{ij} x_i$$

4. تعیین بهترین تطبیق

$$J = \text{Arg Max}_j (\mu_j)$$

5. آزمون برابری

$$r = \frac{\sum_{t=0}^{n-1} v_{tj} x_t}{\sum_{t=0}^{n-1} x_t}$$

$$r > p \leftarrow \text{مرحله 4}$$

$$r \leq p \leftarrow \text{مرحله 6}$$

6. واحد J را غیرفعال می کنیم

$$y_j = 0$$

آیا همه واحدهای خروجی غیرفعال شده اند؟

خیر: مرحله 3

بله: افزودن یک واحد جدید PAPCO

در مرحله 2 F2

7. اصلاح وزن های مرتبط با بهترین تطبیق

$$w_{T_i}(t+1) = \frac{V_{T_i}(t) \cdot X_i}{\frac{1}{2} + \sum_{i=0}^{n-1} V_{T_i}(t) \cdot X_i}$$

$$V_{T_i}(t+1) = V_{T_i}(t) \cdot X_i$$

8. واحد های غیر فعال را فعال نموده و به مرحله 2 برمی گردیم

• این شبکه در روزنامه‌ها دارد نیاز آموزش را یادگیری می نمود

• شبکه ART در طول آموزش نسبت به متادیر، پایداری بسیار حساس است.

• P : حساس ترین پارامتر

$P \downarrow$ (اصغر 0.1) → دست بندی روز روشن پایین

↓ قواعد دست بندی

$P \uparrow$ (بزرگ 1) → دست بندی روز روشن بالا

✓ تغییرات کم منجر به ایجاد حلاهای جدید می شود.

• P بزرگ → حساسیت بیش از حد شبکه به تغییرات بین نمونه های هر دسته

ایراد ART → عملگر صفین در دو باره پی با داده های تکراری

راه حل: P متغیر → ابتدا P کوچک: خوشه بندی خالص و سپس

✓ افزایش P : افزایش وقت دست بندی

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

نشان دهید

$$y = |w_1 x_1 + \dots + w_n x_n|^2 = (a_1 x_1 + \dots + a_n x_n)^2 + (b_1 y_1 + \dots + b_n y_n)^2$$


$$w_i = a_i + b_i$$

نشان دهید

نشان دهید

نشان دهید

$$y = f \left(\sum_{i=1}^n w_i x_i + \sum_{i=1}^n w_{i+1} x_{i+1} + k \right)$$



نشان دهید

نشان دهید

$$\left(\frac{x^2}{1+x^2} \right) \rightarrow$$

نشان دهید

نشان دهید

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

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

نشان دهید


۸- فرودهای سینوسی ← فرم کلی $y = \sum_k \omega_k \prod_i x_i$

۹- فرودهای هزینه‌ای

پتانسیل تریگنر: $P_v = \sum EPSP + \sum IPSP$

آستانه تریگنر: $P_v > \Theta_v$

مدت تریگنر: $\omega_{u,v} \times \epsilon_{u,v}(t-s)$



فرودهای تریگنر F_u : $P_v(t) = \sum_u \sum_{s \in F_u} \omega_{u,v} \times \epsilon_{u,v}(t-s)$

۱۰- فرودهای انبساطی

$$y = \begin{cases} +1 & P(I) \\ -1 & 1 - P(I) \end{cases}$$

$$P(I) = \frac{1}{1 + e^{-I/T}}$$

* سلهای ندرودها

۱- سل اول: مدل اطلاعات دیتیر، خودی درتقی، پرسپترون، دینلید، بوتزمن

۲- سل دوم: خودی بویکه ← RBF, MLP، بولش

۳- سل سوم: خودی هزینه، نردلیتر بندهای طبعی

* رفتار دینامیکی واحد

$$\frac{dy}{dt} = -g(y) + I$$

قابل: $g(y) = I \rightarrow y, g'(I) = f(I) \rightarrow g = f^{-1}$

* انواع انفلات

- ۱- انفلات کامل
- ۲- انفلات تقاضای بی‌انجام
- ۳- انفلات آب‌سپین
- ۴- انفلات به‌تدریج حاصل

* دست بندی

- ۱- بازآموزش ← درودی : گونا گونا + باغ آبیاری خودی : یادگیری دست بندی کننده
- ۲- بازآموزش ← درودی : یاد جدید خودی : یقین دست (یادگیری ثابت)

* واحدی دست بندی کننده

- ۱- واحدی ← سبب
داده های طبیعی بر گاه نردن : به طور مکرر و مداوم در فعال کردن نردن ن سبب نردن
تاثیر این نردن بر فعال کردن نردن ن نردن می باشد
یادگیری هم درونی

Coincidence learning

$$\omega_i(\text{new}) = \omega_i(\text{old}) + \alpha_i \cdot x \cdot y$$

تایید سبب

تقسیم سبب ← طلب و رابطیات ← در نردن خاموش باشند نیز ارتباط آنها باید تقویت شوند.

۲- واحدی پرستون ← زنبلات

$$\omega_i(\text{new}) = \omega_i(\text{old}) + (t - y) \cdot x$$

تایید یادگیری پرستون

$$\omega_i(\text{new}) = \omega_i(\text{old}) + \alpha (t - y) \cdot x$$

تقسیم ← منسبی و یاپرت

$$\alpha = \frac{x \cdot \omega}{\|x\|^2} \quad \text{یا} \quad \alpha = \frac{1}{\|x\|^2}$$

اصلاح منسب با درودی

$$I = -\theta + \omega_1 x_1 + \omega_2 x_2 + \omega_3 x_1^2 + \omega_4 x_2^2$$

پرستون درجه ۲

۳- واحدی آرالاین ← درودی

Performance learning

نمونه کردن hMS ← سبب نردی

Subject: _____

Year: _____ Month: _____ Date: _____ ()

$$F(w) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum^N (t_k - I_k)^2 = E[(t_k - I_k)^2]$$

$$\nabla_w F(w) = -2Q + 2Rw = 0 \rightarrow w^* = R^{-1}Q$$

$$\nabla_w F(w) = \nabla [2 \dots] = -2 E[\underbrace{(t_k - I_k)}_{\delta_k} X_k] = -2 E[\delta_k X_k]$$

که شیب نودی

$$w(\text{new}) = w(\text{old}) + \alpha \delta X$$

ماتریس دلتا

$$0.01 \leq \alpha \leq 10 \rightarrow \alpha = 0.1 \quad \text{معدل توزیع}$$

$$\frac{1}{10n} \leq \alpha \leq \frac{1}{n}$$

بیشتر دیر

بیشتر دیر: آموختن دسته‌ای ← پس از تعداد زیادی X و w ثابت ← متوسط لری $\delta_k X_k$

$$w_{k+1} = w_k + \alpha(1-\mu)\delta_k X_k + \mu(w_k - w_{k+1}) \quad \text{بیشتر دیر: استاندارد از محتم}$$

$$\mu \gg \alpha \rightarrow \mu = 0.9 \ \& \ \alpha = 0.01$$

$$I = w_0 + w_1 x_1 + w_2 x_2 + w_{11} x_1^2 + w_{22} x_2^2 + w_{12} x_1 x_2$$

آرالاتین درجه ۲

* تدای در مقراان (ارسط) ① مطالب شبیه به هم

* استبدادی شله ای مترای ② بر خلاف بدیدر

۱- بین حدر VS بارستی

۲- خود مترای (y_i = x_i) VS غیر خود مترای (y_i ≠ x_i) عملر مترای نوزیر

۳- همدرزه (y = 4(x+4)) VS درونیاب (y(x+4) = 4+5) از لحاظ نهداری

* شله تدای لریش حدر

• در لایه (n : m) - انقال کابل - بر خردی ترکیب عملی در دویا

• درونیاب
$$\begin{cases} X_k = S_k \Rightarrow Y_k = T_k \\ X_k = S_k + \epsilon \Rightarrow Y_k = T_k + \delta \end{cases}$$

• خردی:
$$Y = W^T X$$

• آبرزش : مانن هب
$$w(\text{new}) = w(\text{old}) + S \cdot T$$

• بد خطی: S معامد
$$X = S \Rightarrow Y = WS = T$$
 تعداد ابر = n

• دارای خطای n: سائل لرین LMS

$$F(w) = \frac{1}{L} \| T - WS \|^2$$

$$F(w) = 0 \longrightarrow w = (TS^+)^T$$

• سائل خطی: $S^+S = I \rightarrow F(w) = 0 \rightarrow \varphi(X_i), Y_i$

• سائل نرد: $S^+S \neq I \rightarrow S_i = \sum \alpha_j S_j \rightarrow w^T S_i = \sum \alpha_j T_j$

• برای $F(w) = 0$ ابر سائل رابط خطی س: این T. نوزیر

حاسبه S^+ به کمک تجزیه مقدار سترد
$$S = \sum^L \sigma_i P_i^T Q_i \rightarrow S^+ = \sum^{\text{rank}} \frac{1}{\sigma_i} Q_i P_i$$

Singular value decomposition

Subject:

Year: Month: Date: ()

• قانون یادگیری دیدو در صورت وجود نویز

$$w_{(new)} = w_{(old)} + \alpha \left[\underbrace{(t_{sk} - (w_{old} S_{sk}))}_{\delta \text{ خطا}} \right] S_{sk}$$

آزمایش به دفعات متعدد به صورت انشائی پیرواجت - α درجه و + - $\theta \neq 0$ بهتر است

* شبکه ذاعی را با روش ساده

- ادان - با شروع از هر نقطه به هر حالت یادار برود ✓
- به تر اولین حالت یادار برود x
- ایجاد بر تعداد حالت یادار برای شبده

• تک لایه - ماتریس وزنها معادل - ظاهر نظری هنر (مدل ذاعی) یا غیر هنر

• آموزش : قانون سبب

• پاسخ شبده به ورودیها به طوره محدود و نزولی می شود - تابع خطی فعالیت

* شبکه Brain State in a Box (BSB) - آموزش


• ورودی تنها یک واحد منتقل می شود

• اتصالات : قابل یا غیر قابل (انعاشی) و $w_{ij} = 1$

• حالات : یادار - ریزش امریاب اولیه - نظری داخلی امریاب

• وزنها : اولیه - کرجک هر روز زمانی - سزبان - نتیجآم رسیدن به حالت یادار

• تابع فعالیت



• آموزش : قانون هب - حالت یادار دارای زوج x_{stable}

$$w_{ij}(new) = w_{ij}(old) + \beta y_i y_j$$

• قانون دیدو - حل مشکل نون

$$w_{ij}(new) = w_{ij}(old) + \eta \sum (y_i^d - y_i^a)^T$$

BSB الیستیم

0 هزینه = مقدار لوجس انتخابی و زنجای یادگیری α, β

1 2 3 4 5 6

2 $y_i = S_i$

3 آزا نیکه یاد شده اند

$$I_i = y_i + \alpha \sum_{j=1}^n y_j w_{ji}$$

$$y_i = f(I_i)$$



6 اصلاح هزینه : حسب

شبهه تغییر دیند ؟ بیدار

انتقالات : کامل و $w_{ii} = 0$ و $w_{ji} = w_{ij}$

انتخاب : نهمان در قطعی $\theta_i = 0$

تابع مغالبت :

$$y_i(\text{new}) = \begin{cases} +1 & \sum w_{ji} y_j(\text{old}) > \theta_i \\ y_i(\text{old}) & \sum w_{ji} y_j(\text{old}) = \theta_i \\ -1 & \sum w_{ji} y_j(\text{old}) < \theta_i \end{cases}$$

همای جدگیری از حالت تادی (دری بر صحت) می توان با طر جزئی تغییر داد

$$y_i(\text{new}) = \text{sgn} \left(\sum w_{ji} y_j(\text{old}) - \theta_i + \alpha_i \right)$$

$$= \text{sgn} \left(\sum w_{ji} y_j(\text{old}) \right) \quad \alpha_i = 0 \text{ و } \theta_i = 0$$

سیستم سازی نهمان ← تابع بایزنت (ارزی) ← اثبات هدایی
تابع ارزی

$$E = - \frac{1}{2} \sum_i \sum_{j=1}^n w_{ij} y_j - \sum_i \alpha_i y_i + \sum_i \theta_i y_i$$

$$\Delta E = - \left[\sum_{j \neq k} w_{kj} y_j(\text{old}) + \alpha_k - \theta_k \right] \Delta y_k \quad \forall k \Rightarrow \Delta E \leq 0$$

سیستم محلی تابع ارزی = حالت بیدار ← تعیین بیداری : $w_{ji} = w_{ij}$ و $w_{ii} = 0$

Subject:

Year. Month. Date. ()

• خود سبدگی ← بهار درودی آ 497 شیب S_k ← خرجی S_k ← درون S_k

• ذخیره الود $w_{ij} = \begin{cases} 0 & i=j \\ \sum_{e=1}^L S_e(i) S_e(j) & i \neq j \end{cases}$

• قابل حسب تقیم باقیمانده ← اضافه کردن $\frac{1}{n}$ جوی مجموع ← اپید پایداری

• مزایا ← سبدت پایداری ← محاسبه پایداری عمل جمع و ضرب

• انواع حالات Retrieval ← پایداری S_i

• Inverse ← محاسبه حالات بازایی S_i

• Mix ← ترکیبی خطی از هر تعداد فرد از حالات بازایی S_{ij}^{mix}

• Spin Glass ← تعداد زیاد است ← min عملی می باشد بطور حالات پایدار

• Spurious ← مجموعه حالت ناخواسته است

• حذف حالت محسوس: علامت بولد خطی از پاسخ را از قبل برائیم ← در حالت شلر خلافت این دیده شود $x-1$

• الود

• محاسبه ذخیره: حسب تقیم باقیمانده

$\forall x \quad 1$

$y_i(\text{old}) = x_i \quad 2$

3. زمانی که پایدار نشده است

$\forall u_i \quad 4$

$I_i = x_i + \sum_j w_{ij} y_j(\text{old}) \quad 5$

$y_i(\text{new}) = f(I_i) \quad 6$

7. ارسال $y_i(\text{new})$ به همه واحدها

8. آزمون همگرایی

• حالات درودی قابل ذخیره


تحلیل اول: $L \leq 0.61n$ / $err < 10\%$ / $L \leq 0.37n$ / $err < 5\%$ / $L \leq 0.15n$ / $err < 1\%$

تحلیل دوم: $L \leq \frac{n}{4 \ln n}$ / بازایی کامل / $L \leq \frac{n}{2 \ln n}$ / رتت 99%

افزایش نزدیکی درودی ثابت ← لود درودی < 0.5 بالا بودن تعداد واحدها

* قانون لایب-نیزن - لایب-نیزن
 به ازای شرایط حین جمعیتی (۱) ثابت می شود که در حالت شبکه در زمان هر دو بخش مثبت
 فضای حینتی را در بر می آید، شبکه جهت به یک نقطه پایدار در این بخش هدایت می شود.

شبکه حینتی در طرفه (BAM) - کازلد



- لایب-نیزن در لایب-نیزن
- واحدی لایب-نیزن که هر دو سیستم را در بر می آید و می شود و می آید
- تعیین شبکه که تولید به حالت غیر خود حینتی
- آزمون: هب
- نتایج فعالیت: مشابه تولید
- آزمون

۵. محاسبه در زمان و خودی خاص برابر هر

$$V \times 1$$

$$2. X_i = S_i \quad (و \quad Y_i = T_i)$$

۳. دامنه پایدار شده است.

$$4. I_j = \sum_i w_{ij} x_i \rightarrow y_j = f(I_j)$$

$$5. I_i = \sum_j w_{ji} y_j \rightarrow x_i = f(I_i)$$

۶. آزمون هر دو: به عادل رسیدن حالات پایدار در لایب

شبکه حینتی در طرفه می شود

$$f_i(I_i) = \frac{1}{1 + e^{-I_i}} \quad و \quad \theta_i \neq 0 \quad و \quad \tau_i \neq 0$$

* تعیین کازلد

این شبکه حینتی در طرفه از هر حالت اولیه شروع می کند، شبکه به حالت پایدار هر دو خواهد شد.
 لایب-نیزن، تعیین لایب-نیزن - لایب-نیزن

۴.۱ - تکلیف حالت ۱

Subject:

Year. Month. Date. ()

سال ۸۷ در یک نگاه

شهریور

شعبان - رمضان ۱۳۲۹
Aug.-Sep. 2008

۲۰	۱	جمعه
۲۱	۲	شنبه
۲۲	۳	یکشنبه
۲۳	۴	دوشنبه
۲۴	۵	سه شنبه
۲۵	۶	چهارشنبه
۲۶	۷	پنج شنبه
۲۷	۸	جمعه
۲۸	۹	شنبه
۲۹	۱۰	یکشنبه
۳۰	۱۱	دوشنبه
۱	۱۲	سه شنبه
۲	۱۳	چهارشنبه
۳	۱۴	پنج شنبه
۴	۱۵	جمعه
۵	۱۶	شنبه
۶	۱۷	یکشنبه
۷	۱۸	دوشنبه
۸	۱۹	سه شنبه
۹	۲۰	چهارشنبه
۱۰	۲۱	پنج شنبه
۱۱	۲۲	جمعه
۱۲	۲۳	شنبه
۱۳	۲۴	یکشنبه
۱۴	۲۵	دوشنبه
۱۵	۲۶	سه شنبه
۱۶	۲۷	چهارشنبه
۱۷	۲۸	پنج شنبه
۱۸	۲۹	جمعه
۱۹	۳۰	شنبه
۲۰	۳۱	یکشنبه

مرداد

رجب - شعبان ۱۳۲۹
Jul.-Aug. 2008

۱۹	۱	سه شنبه
۲۰	۲	چهارشنبه
۲۱	۳	پنج شنبه
۲۲	۴	جمعه
۲۳	۵	شنبه
۲۴	۶	یکشنبه
۲۵	۷	دوشنبه
۲۶	۸	سه شنبه
۲۷	۹	چهارشنبه
۲۸	۱۰	پنج شنبه
۲۹	۱۱	جمعه
۳۰	۱۲	شنبه
۱	۱۳	یکشنبه
۲	۱۴	دوشنبه
۳	۱۵	سه شنبه
۴	۱۶	چهارشنبه
۵	۱۷	پنج شنبه
۶	۱۸	جمعه
۷	۱۹	شنبه
۸	۲۰	یکشنبه
۹	۲۱	دوشنبه
۱۰	۲۲	سه شنبه
۱۱	۲۳	چهارشنبه
۱۲	۲۴	پنج شنبه
۱۳	۲۵	جمعه
۱۴	۲۶	شنبه
۱۵	۲۷	یکشنبه
۱۶	۲۸	دوشنبه
۱۷	۲۹	سه شنبه
۱۸	۳۰	چهارشنبه
۱۹	۳۱	پنج شنبه

تیر

جمادی الثانی - رجب ۱۳۲۹
Jun.-Jul. 2008

۱۷	۱	شنبه
۱۸	۲	یکشنبه
۱۹	۳	دوشنبه
۲۰	۴	سه شنبه
۲۱	۵	چهارشنبه
۲۲	۶	پنج شنبه
۲۳	۷	جمعه
۲۴	۸	شنبه
۲۵	۹	یکشنبه
۲۶	۱۰	دوشنبه
۲۷	۱۱	سه شنبه
۲۸	۱۲	چهارشنبه
۲۹	۱۳	پنج شنبه
۳۰	۱۴	جمعه
۱	۱۵	شنبه
۲	۱۶	یکشنبه
۳	۱۷	دوشنبه
۴	۱۸	سه شنبه
۵	۱۹	چهارشنبه
۶	۲۰	پنج شنبه
۷	۲۱	جمعه
۸	۲۲	شنبه
۹	۲۳	یکشنبه
۱۰	۲۴	دوشنبه
۱۱	۲۵	سه شنبه
۱۲	۲۶	چهارشنبه
۱۳	۲۷	پنج شنبه
۱۴	۲۸	جمعه
۱۵	۲۹	شنبه
۱۶	۳۰	یکشنبه
۱۷	۳۱	دوشنبه

خرداد

جمادی الاول - جمادی الثانی ۱۳۲۹
May - Jun. 2008

۱۵	۱	چهارشنبه
۱۶	۲	پنج شنبه
۱۷	۳	جمعه
۱۸	۴	شنبه
۱۹	۵	یکشنبه
۲۰	۶	دوشنبه
۲۱	۷	سه شنبه
۲۲	۸	چهارشنبه
۲۳	۹	پنج شنبه
۲۴	۱۰	جمعه
۲۵	۱۱	شنبه
۲۶	۱۲	یکشنبه
۲۷	۱۳	دوشنبه
۲۸	۱۴	سه شنبه
۲۹	۱۵	چهارشنبه
۳۰	۱۶	پنج شنبه
۱	۱۷	جمعه
۲	۱۸	شنبه
۳	۱۹	یکشنبه
۴	۲۰	دوشنبه
۵	۲۱	سه شنبه
۶	۲۲	چهارشنبه
۷	۲۳	پنج شنبه
۸	۲۴	جمعه
۹	۲۵	شنبه
۱۰	۲۶	یکشنبه
۱۱	۲۷	دوشنبه
۱۲	۲۸	سه شنبه
۱۳	۲۹	چهارشنبه
۱۴	۳۰	پنج شنبه
۱۵	۳۱	جمعه

اردیبهشت

ربیع الثانی - جمادی الاول ۱۳۲۹
Apr. - May 2008

۱۳	۱	یکشنبه
۱۴	۲	دوشنبه
۱۵	۳	سه شنبه
۱۶	۴	چهارشنبه
۱۷	۵	پنج شنبه
۱۸	۶	جمعه
۱۹	۷	شنبه
۲۰	۸	یکشنبه
۲۱	۹	دوشنبه
۲۲	۱۰	سه شنبه
۲۳	۱۱	چهارشنبه
۲۴	۱۲	پنج شنبه
۲۵	۱۳	جمعه
۲۶	۱۴	شنبه
۲۷	۱۵	یکشنبه
۲۸	۱۶	دوشنبه
۲۹	۱۷	سه شنبه
۳۰	۱۸	چهارشنبه
۱	۱۹	پنج شنبه
۲	۲۰	جمعه
۳	۲۱	شنبه
۴	۲۲	یکشنبه
۵	۲۳	دوشنبه
۶	۲۴	سه شنبه
۷	۲۵	چهارشنبه
۸	۲۶	پنج شنبه
۹	۲۷	جمعه
۱۰	۲۸	شنبه
۱۱	۲۹	یکشنبه
۱۲	۳۰	دوشنبه
۱۳	۳۱	سه شنبه

فروردین

ربیع الاول - ربیع الثانی ۱۳۲۹
Mar. - Apr. 2008

۱۲	۱	پنج شنبه
۱۳	۲	جمعه
۱۴	۳	شنبه
۱۵	۴	یکشنبه
۱۶	۵	دوشنبه
۱۷	۶	سه شنبه
۱۸	۷	چهارشنبه
۱۹	۸	پنج شنبه
۲۰	۹	جمعه
۲۱	۱۰	شنبه
۲۲	۱۱	یکشنبه
۲۳	۱۲	دوشنبه
۲۴	۱۳	سه شنبه
۲۵	۱۴	چهارشنبه
۲۶	۱۵	پنج شنبه
۲۷	۱۶	جمعه
۲۸	۱۷	شنبه
۲۹	۱۸	یکشنبه
۳۰	۱۹	دوشنبه
۱	۲۰	سه شنبه
۲	۲۱	چهارشنبه
۳	۲۲	پنج شنبه
۴	۲۳	جمعه
۵	۲۴	شنبه
۶	۲۵	یکشنبه
۷	۲۶	دوشنبه
۸	۲۷	سه شنبه
۹	۲۸	چهارشنبه
۱۰	۲۹	پنج شنبه
۱۱	۳۰	جمعه
۱۲	۳۱	شنبه

سال ۸۷ در یک نگاه

اسفند
مهر - ربيع الاول ۱۴۳۰
Feb. - Mar. 2009

بهمن
محرم - صفر ۱۴۳۰
Jan. - Feb. 2009

دی
ذی الحجه ۱۴۲۹ - محرم ۱۴۳۰
Dec. 2008 - Jan. 2009

آذر
ذی القعدة - ذی الحجه ۱۴۲۹
Nov. - Dec. 2008

آبان
شوال - ذی القعدة ۱۴۲۹
Oct. - Nov. 2008

مهر
رمضان - شوال ۱۴۲۹
Sep. - Oct. 2008

۲۳	۱	پنج شنبه
۲۴	۲	جمعه
۲۵	۳	شنبه
۲۶	۴	یکشنبه
۲۷	۵	دوشنبه
۲۸	۶	سه شنبه
۲۹	۷	چهارشنبه
۳۰	۸	پنج شنبه
۱	۹	جمعه
۲	۱۰	شنبه
۳	۱۱	یکشنبه
۴	۱۲	دوشنبه
۵	۱۳	سه شنبه
۶	۱۴	چهارشنبه
۷	۱۵	پنج شنبه
۸	۱۶	جمعه
۹	۱۷	شنبه
۱۰	۱۸	یکشنبه
۱۱	۱۹	دوشنبه
۱۲	۲۰	سه شنبه
۱۳	۲۱	چهارشنبه
۱۴	۲۲	پنج شنبه
۱۵	۲۳	جمعه
۱۶	۲۴	شنبه
۱۷	۲۵	یکشنبه
۱۸	۲۶	دوشنبه
۱۹	۲۷	سه شنبه
۲۰	۲۸	چهارشنبه
۲۱	۲۹	پنج شنبه
۲۲	۳۰	جمعه

۲۳	۱	سه شنبه
۲۴	۲	چهارشنبه
۲۵	۳	پنج شنبه
۲۶	۴	جمعه
۲۷	۵	شنبه
۲۸	۶	یکشنبه
۲۹	۷	دوشنبه
۳۰	۸	سه شنبه
۱	۹	چهارشنبه
۲	۱۰	پنج شنبه
۳	۱۱	جمعه
۴	۱۲	شنبه
۵	۱۳	یکشنبه
۶	۱۴	دوشنبه
۷	۱۵	سه شنبه
۸	۱۶	چهارشنبه
۹	۱۷	پنج شنبه
۱۰	۱۸	جمعه
۱۱	۱۹	شنبه
۱۲	۲۰	یکشنبه
۱۳	۲۱	دوشنبه
۱۴	۲۲	سه شنبه
۱۵	۲۳	چهارشنبه
۱۶	۲۴	پنج شنبه
۱۷	۲۵	جمعه
۱۸	۲۶	شنبه
۱۹	۲۷	یکشنبه
۲۰	۲۸	دوشنبه
۲۱	۲۹	سه شنبه
۲۲	۳۰	چهارشنبه

۲۲	۱	یکشنبه
۲۳	۲	دوشنبه
۲۴	۳	سه شنبه
۲۵	۴	چهارشنبه
۲۶	۵	پنج شنبه
۲۷	۶	جمعه
۲۸	۷	شنبه
۲۹	۸	یکشنبه
۳۰	۹	دوشنبه
۱	۱۰	سه شنبه
۲	۱۱	چهارشنبه
۳	۱۲	پنج شنبه
۴	۱۳	جمعه
۵	۱۴	شنبه
۶	۱۵	یکشنبه
۷	۱۶	دوشنبه
۸	۱۷	سه شنبه
۹	۱۸	چهارشنبه
۱۰	۱۹	پنج شنبه
۱۱	۲۰	جمعه
۱۲	۲۱	شنبه
۱۳	۲۲	یکشنبه
۱۴	۲۳	دوشنبه
۱۵	۲۴	سه شنبه
۱۶	۲۵	چهارشنبه
۱۷	۲۶	پنج شنبه
۱۸	۲۷	جمعه
۱۹	۲۸	شنبه
۲۰	۲۹	یکشنبه
۲۱	۳۰	دوشنبه

۲۲	۱	جمعه
۲۳	۲	شنبه
۲۴	۳	یکشنبه
۲۵	۴	دوشنبه
۲۶	۵	سه شنبه
۲۷	۶	چهارشنبه
۲۸	۷	پنج شنبه
۲۹	۸	جمعه
۳۰	۹	شنبه
۱	۱۰	یکشنبه
۲	۱۱	دوشنبه
۳	۱۲	سه شنبه
۴	۱۳	چهارشنبه
۵	۱۴	پنج شنبه
۶	۱۵	جمعه
۷	۱۶	شنبه
۸	۱۷	یکشنبه
۹	۱۸	دوشنبه
۱۰	۱۹	سه شنبه
۱۱	۲۰	چهارشنبه
۱۲	۲۱	پنج شنبه
۱۳	۲۲	جمعه
۱۴	۲۳	شنبه
۱۵	۲۴	یکشنبه
۱۶	۲۵	دوشنبه
۱۷	۲۶	سه شنبه
۱۸	۲۷	چهارشنبه
۱۹	۲۸	پنج شنبه
۲۰	۲۹	جمعه
۲۱	۳۰	شنبه

۲۲	۱	چهارشنبه
۲۳	۲	پنج شنبه
۲۴	۳	جمعه
۲۵	۴	شنبه
۲۶	۵	یکشنبه
۲۷	۶	دوشنبه
۲۸	۷	سه شنبه
۲۹	۸	چهارشنبه
۳۰	۹	پنج شنبه
۱	۱۰	جمعه
۲	۱۱	شنبه
۳	۱۲	یکشنبه
۴	۱۳	دوشنبه
۵	۱۴	سه شنبه
۶	۱۵	چهارشنبه
۷	۱۶	پنج شنبه
۸	۱۷	جمعه
۹	۱۸	شنبه
۱۰	۱۹	یکشنبه
۱۱	۲۰	دوشنبه
۱۲	۲۱	سه شنبه
۱۳	۲۲	چهارشنبه
۱۴	۲۳	پنج شنبه
۱۵	۲۴	جمعه
۱۶	۲۵	شنبه
۱۷	۲۶	یکشنبه
۱۸	۲۷	دوشنبه
۱۹	۲۸	سه شنبه
۲۰	۲۹	چهارشنبه
۲۱	۳۰	پنج شنبه

۲۱	۱	دوشنبه
۲۲	۲	سه شنبه
۲۳	۳	چهارشنبه
۲۴	۴	پنج شنبه
۲۵	۵	جمعه
۲۶	۶	شنبه
۲۷	۷	یکشنبه
۲۸	۸	دوشنبه
۲۹	۹	سه شنبه
۳۰	۱۰	چهارشنبه
۱	۱۱	پنج شنبه
۲	۱۲	جمعه
۳	۱۳	شنبه
۴	۱۴	یکشنبه
۵	۱۵	دوشنبه
۶	۱۶	سه شنبه
۷	۱۷	چهارشنبه
۸	۱۸	پنج شنبه
۹	۱۹	جمعه
۱۰	۲۰	شنبه
۱۱	۲۱	یکشنبه
۱۲	۲۲	دوشنبه
۱۳	۲۳	سه شنبه
۱۴	۲۴	چهارشنبه
۱۵	۲۵	پنج شنبه
۱۶	۲۶	جمعه
۱۷	۲۷	شنبه
۱۸	۲۸	یکشنبه
۱۹	۲۹	دوشنبه
۲۰	۳۰	سه شنبه