

یادگیری ماشین (۰۱-۸۰۵-۱۱-۱۳)


معرفی



دانشگاه شهید بهشتی
دانشکده‌ی مهندسی برق و کامپیوتر
پاییز ۱۳۹۳
احمد محمودی ازناوه

فهرست مطالب

- چند تذکر
- منابع
- باره بندی
- سرفصل
- هوش مصنوعی
- یادگیری چیست؟
- - یادگیری ماشین
- چرا یادگیری؟
- کاربردهای یادگیری ماشین
- انواع شیوه‌های یادگیری



چند تذکر

- در صورتی که در رابطه با مطلبی، ایمیل می‌زنید، لطفاً در پایان ایمیل نام خود را هم بنویسید، به ویژه اگر از نام مستعار برای شناسه‌ی ایمیل خود استفاده می‌کنید.
- ابتدای موضوع (subject) ایمیل با **ML** شروع شود.
- یکی از مهمترین مواردی که رعایت آن بر عهده‌ی ماست، رعایت «**اخلاق آکادمیک**» است. کپی کردن تکالیف، استفاده از مطلبی بدون ذکر منبع و هم‌فکری در امتحان از موارد بارز تخلف محسوب می‌شود.
- از نوشتن به صورت **فینگیلیش** پرهیزید.

از همکاری شما پیشاپیش سپاسگزارم!

گروه درس

sbu-ml-93-1@googlegroups.com


صفحه درس:

http://faculties.sbu.ac.ir/~a_mahmoudi/ML_93_1.htm




دستیاران (TAs):

آقای محمد پیوه‌زندی

d.pivezhandi@Y!




**Introduction to Machine Learning,
Second Edition**
Ethem Alpaydin




Machine Learning: A Probabilistic Perspective
Kevin Murphy

سایر منابع




Pattern Recognition and Machine Learning
Christopher Bishop



Pattern classification

Richard O. Duda, Peter E. Hart and David G. Stork



Machine Learning

Tom Mitchell

در تهیهی اسلایدهای این درس از منابع online نظیر اسلایدهای سایر دانشگاه استفاده شده است که در صورت استفاده لینک آن ذکر خواهد شد.



بارمبندی

- پروژه و فعالیت‌های پژوهشی ۲۵-۲۰٪
- تکالیف ۳۰-۱۵٪
- نمره‌ی کتبی ۶۰-۵۰٪
- فعالیت کلاسی ۵٪

• عدم تحویل تکالیف منجر به دریافت **نمره منفی** خواهد شد!


• در طول ترم، در مورد مباحث مطرح شده، ارائه‌ی کاربرد یا یک نمونه‌ی بهبود یافته به صورت مختصر به عنوان فعالیت پژوهشی مورد نظر است.

• در مورد موضوع پروژه، توصیه می‌شود با توجه به زمینه‌ی کاری موضوع خود را انتخاب کنید.

• ارائه‌ها از **ماه آبان (چهارم)**، شروع خواهد شد.


• مهلت تکمیل فرم پیشنهاد موضوع ارائه‌ی شفاهی **بیست و چهارم مهر** است.

• پروژه‌ی نهایی به صورت کتبی تحویل داده و پس از آن در زمان تعیین شده به صورت شفاهی هم ارائه خواهد شد.




پیش‌نیازها

- آشنایی با جبرخطی و آمار و احتمال
- آشنایی با برنامه‌نویسی (Matlab)




- 1 Introduction
- 2 Supervised learning
- 3 Bayesian Decision Theory
- 4 Parametric Methods
- 5 Multivariate Methods
- 6 Dimensionality Reduction
- 7 Nonparametric method
- 8 Decision Tree
- 9 Linear Discrimination
- 10 Support Vector Machine
- 11 Neural Networks
- 12 Hidden Markov Model
- 13 Assessing Classification Algorithm
- 14 Combining Multiple Learner
- 15 Reinforcement Learning




پایگاه داده‌های در دسترس

- UCI Repository:
<http://www.ics.uci.edu/~mlearn/MLRepository.html>
- UCI KDD Archive:
<http://kdd.ics.uci.edu/summary.data.application.html>
- Statlib: <http://lib.stat.cmu.edu/>
- Delve: <http://www.cs.utoronto.ca/~delve/>




مجلات مرتبہ

- Journal of Machine Learning Research www.jmlr.org
- Machine Learning
- Neural Computation
- Neural Networks
- IEEE Transactions on Neural Networks
- IEEE Transactions on Pattern Analysis and Machine Intelligence
- Annals of Statistics
- Journal of the American Statistical Association
- ...



کنفرانس‌های مرتب

- International Conference on Machine Learning (ICML)
- European Conference on Machine Learning (ECML)
- Neural Information Processing Systems (NIPS)
- Uncertainty in Artificial Intelligence (UAI)
- Computational Learning Theory (COLT)
- International Conference on Artificial Neural Networks (ICANN)
- International Conference on AI & Statistics (AISTATS)
- International Conference on Pattern Recognition (ICPR)
- ...



هوش مصنوعی

- آیا امکان تحقق کامل اهداف هوش مصنوعی وجود دارد؟

It has long been believed, especially by older members of the scientific community, that for machines to be as intelligent as us, that is, for artificial intelligence to be a reality, our current knowledge in general, or computer science in particular, is not sufficient. People largely are of the opinion that we need a new technology, a new type of material, a new type of computational mechanism or a new programming methodology, and that, until then, we can only “simulate” some aspects of human intelligence and only in a limited way but can never fully attain it.

I believe that we will soon prove them wrong.


Ethem Alpaydin

مقدمه‌ی چاپ دوم کتاب

ناشر
بهرین

دیباچه

- علوه مختلف از روش‌های مطرح شده در «یادگیری ماشین» استفاده می‌کنند.
- نقش «یادگیری ماشین» در زندگی تا چه حد است؟
- کاربردهای یادگیری ماشین در زندگی روزمره راه یافته است:
 - تشخیص دست‌نوشته
 - خودرو بدون راننده
 - جداسازی سیگنال‌ها مخلوط شده (BSS)



یادگیری چیست؟

- «یادگیری» عبارتست از تخریب نسبتاً پایدار در احساس، تفکر و رفتار فرد که بر اساس تجربه ایجاد شده باشد.

به نقل از ویکی‌پدیا

Learning is the act of acquiring new, or modifying and reinforcing existing knowledge, behaviors, skills, values, or preferences.

The ability to learn is possessed by humans, animals and some machines.




Machine Learning یادگیری ماشین چیست؟


- «یادگیری ماشین» برنامه‌نویسی برای بهینه‌سازی یک عملکرد با استفاده از داده‌ها و تجربیات گذشته است.

Machine learning is programming computers to optimize a performance criterion using example data or past experience.

- «یادگیری ماشین» در پی راهی برای ایجاد برنامه‌ای است که عملکرد را به صورت خودکار و با توجه به تجربیات ارتقا دهد. (Tom. M. Mitchell).




Field of study that gives computers the ability to learn without being explicitly programmed.



Arthur Samuel (1959)

Well-posed Learning Problem: A computer program is said to learn from experience **E** with respect to some task **T** and some performance measure **P**, if its performance on **T**, as measured by **P**, improves with experience **E**.

Tom Mitchell (1998)





سایر تعاریف - مثال

- به عنوان مثال یک برنامه‌ی **تشخیص هرزنامه** را در نظر بگیرید که با توجه به ایمیل‌هایی که کاربر به عنوان spam اعلام می‌کند، سعی در بهبود کارایی خود دارد.
- در این صورت

- **T** عمل طبقه‌بندی ایمیل‌ها به دو گروه spam/not spam


- **E** پی‌گیری ایمیل‌های کاربر به عنوان spam اعلام می‌کند.

- **P** تعداد ایمیل‌هایی که به درستی به عنوان spam طبقه‌بندی شده‌اند.



چرا یادگیری؟


- برای حل یک مسأله بر روی کامپیوتر به یک «الگوریتم» احتیاج داریم.
- برای برخی مسائل نمی‌توان یک الگوریتم نوشت، مانند تشخیص هرزنامه‌ها. حتی ممکن است برخی از ایمیل‌ها بسته به کاربر هرزنامه تلقی شوند یا نه، اما نمونه‌های زیادی از داده در اختیار داریم.
- در جاهایی که نمی‌توانیم مستقیماً برنامه‌ی مورد نظر را بنویسیم، به یادگیری احتیاج داریم، که با کمک یک سری **داده‌ی آموزشی یا تجربیات** صورت می‌پذیرد.
- به عنوان مثال برای محاسبه‌ی حقوق پرسنل نیازی به یادگیری وجود ندارد.



منظور از یادگیری


- یادگیری ← استخراج یک مدل کلی از روی داده‌های
- بیشتر داده‌های اخذ شده توسط وسایل مختلف به صورت دیجیتال هستند.
- در واقع با حجم انبوهی از داده‌ها مواجه هستیم که ارزان به دست می‌آیند، با این حال دانش در خصوص آن‌ها به سادگی و با هزینه‌ی پایین حاصل نمی‌شود.

We are drowning in information and starving for knowledge. John Naisbitt.




منظور از یادگیری (ادامه...)

- در موارد زیر به یادگیری امتیاج داریم:
 - در مواردی که انسان فبره در دسترس نیست،
 - زمانی که انسان قادر به توضیح مهارت خود نیست، مانند تشخیص صوت
 - زمانی که مساله‌ی مورد نظر در طول زمان تغییر می‌کند؛ به شرایط محیط وابسته است، مانند مسیریابی در شبکه‌های کامپیوتری
 - حالاتی که به حل مساله به تطبیق با شرایط خاصی وابسته است، تشخیص هویت با استفاده از خصیصه‌های زیستی



منظور از یادگیری (ادامه...)

- خرده‌فروشی: به عنوان مثال استخراج مدل کلی رفتار مشتری‌ها از روی تراکنش‌های مربوط به آن‌ها مثلاً کسی که از یک فروشگاه online یک محصول را خریداری می‌کند، با توجه به سابقه‌ی خریدهای مشابه می‌توان خریدهای بعدی او را حدس زد.
- هرچند ممکن است قادر به ارائه‌ی یک مدل دقیق نباشیم، اما می‌توان یک **تقریب خوب و مفید** به دست آورد.
- مدل به دست آمده می‌تواند برای پیش‌بینی مورد استفاده قرار گیرد (**predictive**) و یا به منظور استخراج دانش از داده‌ها به کار آید (**descriptive**).
- در ادامه کاربردهای یادگیری ماشین مطرح می‌شود.




Knowledge Discovery in Database (KDD)

- کاربرد روش‌های یادگیری ماشین در مواجهه با پایگاه‌داده‌های بزرگ، **داده‌کاوی** نامیده می‌شود.
- خرده‌فروشی: تحلیل سبد خرید، مدیریت ارتباط با مشتری (CRM)
- کاربردهای مالی: رده‌بندی اعتبار مشتریان، تشخیص سوءاستفاده از کارت‌های اعتباری، بررسی بازار سهام
- کاربردهای صنعتی: عیب‌یابی، رباتیک و کنترل
- کاربردهای پزشکی: تشخیص بیماری
- ارتباطات: تشخیص هرزنامه، تشخیص نفوذ (intrusion detection)
- وب‌کاوی (موتورهای جستجو) و بیوانفورماتیک



هوش مصنوعی

- **یادگیری ماشین**، یکی از مهم‌ترین بخش‌های **هوش مصنوعی** است. برای هوشمند بودن، یک سیستم که در محیطی با شرایط متغیر قرار دارد، باید توانایی آموختن داشته باشد. در چنین حالتی طراحان نیازی به پیش‌بینی همه‌ی حالات ممکن نخواهند داشت.
- برای حل بسیاری از مسائل در بینایی ماشین، تشخیص صوت، الگوریتم‌های یادگیری به کار می‌آیند.
- شناسایی هویت با کمک چهره یکی از این زمینه‌هاست که در «**بازشناسی الگو**» مطرح می‌شود.




- آنالیز سبد خرید: احتمال این که شخصی که کالای X را خریده، کالای Y را هم خریداری کند.


- $P(Y | X)$

Association Rule

- $P(\text{chips} | \text{beer}) = 0.7$




• ارزیابی اعتبار (credit scoring)




Discriminant

**Discriminant: IF $income > \theta_1$ AND $savings > \theta_2$
THEN low-risk ELSE high-risk**



طبقه‌بندی (ادامه...)

- «بازشناسی الگو» هم نامیده می‌شود.
- تشخیص کاراکتر (OCR)
 - تشخیص کاراکترهای دستنویس
 - یک کلمه دنباله‌ای از کاراکترهاست
 - t?e
- تشخیص هویت با استفاده از دست‌خط




طبقه‌بندی (ادامه...)

- تشخیص چهره

– شرایط نوری متفاوت،
پوشش و آرایش‌های مختلف


Training examples of a person



Test images




ORL dataset,
AT&T Laboratories, Cambridge UK



طبقه‌بندی (ادامه...)

- تشخیص صوت
 - وابستگی زمانی
 - Sensor fusion
- تشخیص بیماری
 - در نظر گرفتن ریسک تصمیم‌گیری
- تشخیص موارد نامتعارف (outlier detection)
 - Intrusion Detection Systems



رگرسیون

- طبقه‌بندی و رگرسیون هر دو از نمونه‌های یادگیری با نظارت (supervised) هستند.

- مثال: قیمت اتومبیل دسته‌دو


- x : car attributes

y : price

$$y = g(x | \theta)$$

$g()$ model,


θ parameters



$$y = wx + w_0$$

یا

$$y = w_2x^2 + w_1x + w_0$$




کاربردهای رگرسیون


- راهبری یک ربات، ورودی مشخصات اخذ شده از مسگرها خروجی زاویه‌ی چرخش
- یکی از کاربردهای رگرسیون بهینه‌سازی یک تابع است.

Response surface design

- یافتن بهترین پارامترها برای بو دادن قهوه
- به دست آوردن تابعی برای ارزیابی کیفیت یک تصویر



From Live Image quality database



شیوه‌های یادگیری

Supervised learning


Unsupervised learning

Semi-supervised learning


Active learning

Reinforcement learning

- یادگیری با نظارت
- یادگیری بدون نظارت
- یادگیری نیمه‌نظارتی
- یادگیری فعال
- یادگیری تقویتی



- در این شیوه همراه با نمونه‌های آموزشی، پاسخ مطلوب هم وجود دارد.
 - پیش‌بینی نمونه‌های جدید
 - استخراج دانش
 - فشردن سازی
 - تشخیص نمونه‌های غیرنرمال؛ تشخیص تقلب و سوءاستفاده



- در این حالت تنها داده‌های ورودی وجود دارند، بدون این که ناظر مقدار مطلوب را مشخص کند.
- هدف پیدا کردن «نظم» (regularity) موجود در داده است، آنچه معمول و طبیعی است.



Density estimation

- خوشه‌بندی (clustering): گروه‌بندی نمونه‌های مشابه

- مدیریت ارتباط با مشتری
- فشرده‌سازی تصویر (چندی‌سازی رنگ)
- بیوانفورماتیک (Learning motifs)




جداسازی کور سیگنال (BSS)



کاربرد یادگیری بی نظارت




Image Segmentation




کاربرد یادگیری بی نظارت (ادامه...)



Organize computing clusters




Social network analysis




Market segmentation





Astronomical data analysis




- تنها بخشی از داده‌ها برچسب خورده‌اند، و حجم زیادی از آن بدون برچسب هستند.
- برچسب زدن داده‌ها کار پرهزینه‌ای است.
- از طرفی، داده‌های برچسب نخورده‌ی زیادی در اختیار داریم.



یادگیری با نظارت



یادگیری نیمه نظارتی



- در برخی موارد فروبی یک سیستم، دنباله‌ای از «کنش»‌هاست. به گونه‌ای که یک حرکت اهمیت ندارد، بلکه سیاستی است که باعث می‌شود مجموع حرکات، به هدف مناسب برسند.
- یک عمل مناسب است در صورتی که در مجموع و در کنار سایر اعمال مناسب باشد. در این حالت الگوریتم یادگیری باید قادر به انتخاب سیاست مناسب باشد.

Game playing


Robot in a maze

Multiple agents, partial observability, ...



ارزیابی الگوریتم‌های یادگیری

- بسته به کاربرد، برای ارزیابی الگوریتم‌های یادگیری، دقت طبقه‌بندی، حجم محاسبات و حافظه‌ی مورد نیاز در نظر گرفته می‌شود.
- الگوریتم‌های یادگیری متفاوتی وجود دارند؛ بسته به شرایط کاربرد مورد نظر، الگوریتم‌های متفاوتی را می‌توان مورد استفاده قرار داد.
- حجم مورد نیاز داده‌های آموزشی، پیچیدگی الگوریتم‌های مورد استفاده و قابلیت تعمیم مسائلی است که باید مورد بررسی قرار گیرند.



موضوعات پیشنهادی

- شناسایی هویت با استفاده از خصیصه‌های زیستی
- یادگیری نیمه‌نظارتی
- روش‌های یادگیری فعال
- روش‌های یادگیری مبتنی بر کرنل
- تشخیص کیفیت تصویر و ویدئو
- تشخیص آلات موسیقی
- بخش‌بندی تصاویر رنگ
- سیستم‌های تشخیص دست‌رسی غیرمجاز

