

Redes de Informação/Ciências da Informação



Pós-doc - Iara Del Pilar Solar Diaz/
Genética e Melhoramento Animal/UFBA



Democratização
do
conhecimento?

Tipos de dados
coletados

Dados
Compartilhados
x privatizados

Integração das
informações


Estatística +
Ferramentas
Computacionais

Gerenciamento
dos
Dados




A Era do "Big Data"

A lei de Moore



Cost per Genome




Data Science – Ciência dos dados


Por que do aumento na popularidade?

- Crescimento na disponibilidade de dados;
- Maior potência computacional (modelos não-lineares);
- Novas ferramentas de programação;
- Demanda de pessoas aptas para a ciência de dados;
- Grande aplicabilidade prática;

Data Science – Ciência dos dados



DATA SCIENCE



Business/Domain



Mathematics



Comp Sci



Communication



mathematics, statistics, computer science, domain
knowledge and information science

Interdisciplinary Field


Uses scientific methods, processes,
algorithms and systems

Extract knowledge and insights

from many structural
and unstructured data.

Data science is a "concept to
unify statistics, data analysis and their
related methods"

understand and analyze actual
phenomena



SUSTAINABILITY

Environmental
footprint



Animal
Welfare



Economic
Viability



Rural
Communities



Human
Health




Integração de Dados/centralizado/distribuído/icloud SQL Data-bases


			id	title	body	user_id	
<input type="checkbox"/>	 Edit	 Copy	 Delete	1	post one	hello from post one	1
<input type="checkbox"/>	 Edit	 Copy	 Delete	2	this is post two	hello from post two	1
<input type="checkbox"/>	 Edit	 Copy	 Delete	3	this is post three	hello from post three	2
<input type="checkbox"/>	 Edit	 Copy	 Delete	4	this is post four	hello from post four	2
<input type="checkbox"/>	 Edit	 Copy	 Delete	5	this is post five	hello from post five	2
<input type="checkbox"/>	 Edit	 Copy	 Delete	6	this is post six	hello from post six	3
<input type="checkbox"/>	 Edit	 Copy	 Delete	7	this is post seven	hello from post seven	3
<input type="checkbox"/>	 Edit	 Copy	 Delete	8	this is post eight	hello from post eight	1

Data Integration

Comparison of Approaches for Farm Data Linkage (Entity Matching)



Data Analytics vs Data Analysis



- **Data analysis é o procedimento que envolve investigar, limpar, transformar e treinar os dados com o objetivo de encontrar alguma informação útil, recomendar conclusões e ajudar na tomada de decisões;**
- **Data analytics envolve utilizar os dados, machine learning, análises estatísticas e ajustes de modelos computacionais a fim de obter uma melhor visão e melhores decisões a partir dos dados.**
- **“É o processo de transformar os dados em ações através de análises e discernimento no contexto de tomada de decisões e solução de problemas”.**

O que é Machine Learning?

- Machine Learning (aprendizado de máquina) é um método de análise de dados que automatiza a construção de um modelo analítico;
- Usa algoritmos que iterativamente aprendem dos dados;
- Machine learning permite que os computadores encontrem padrões nos dados sem explicitamente programar onde procurar esses padrões.

Gareth James

[Home](#)

[Bio](#)

[Research](#)

[Teaching](#)

[CV](#)

[Personal](#)

*"Data is the sword of the 21st century, those who wield it well, the Samurai."**



Gareth James

Deputy Dean of the USC Marshall School of Business
E. Morgan Stanley Chair in Business Administration,
Professor of Data Sciences and Operations
Marshall School of Business
University of Southern California.

Education

BSc/BCom University of Auckland, New Zealand.
Ph.D. in Statistics, Stanford University, California.

Research Areas

Functional Data Analysis
High Dimensional Regression
Statistical Problems in Marketing

Contact Information

101 Bridge Hall
Data Sciences and Operations Department
University of Southern California.
Los Angeles, California 90089-0809
Phone: (213) 740 9696
email: gareth at usc dot edu

<http://faculty.marshall.usc.edu/gareth-james/>

Google: ISLR

Springer Texts in Statistics

Gareth James
Daniela Witten
Trevor Hastie
Robert Tibshirani

An Introduction
to Statistical
Learning

with Applications in R

STATISTICAL LEARNING = MACHINE LEARNING

“mathematical word”

- **Interesse apenas na teoria Matemática;**
- **Interesse apenas em esclarecer algo da teoria, porém aprofundando as aplicações no software R;**
 - **Capítulo 1 e 2**

Competitions

Grow your data science skills by competing in our exciting competitions. Find help in the [Documentation](#) or learn about [InClass competitions](#).

New to Kaggle? Start here!

Our Titanic Competition is a great first challenge to get started.



Titanic - Machine Learning from Disaster

Start here! Predict survival on the Titanic and get familiar with ML basics
Getting Started • Ongoing • 16999 Teams

Knowledge

All Competitions

Active Completed InClass

All Categories ▾ Default Sort ▾



Jane Street Market Prediction

Test your model against future real market data
Featured • 5 days to go • Code Competition • 4002 Teams

\$100,000



HuBMAP - Hacking the Kidney

Identify glomeruli in human kidney tissue images
Research • a month to go • Code Competition • 1016 Teams

\$60,000



RANZCR CLiP - Catheter and Line Position Challenge

Classify the presence and correct placement of tubes on chest x-rays to save lives
Featured • a month to go • Code Competition • 815 Teams

\$50,000



VinBigData Chest X-ray Abnormalities Detection


Automatically localize and classify thoracic abnormalities from chest radiographs

\$50,000

Onde é utilizado?

Detecção de Fraudes	Segmentação de clientes
Resultado para pesquisa na Web	Reconhecimento de padrões de imagens
Propagandas na páginas da Web	Filtro de email e lixo eletrônico
Pontuação de créditos e próximas ofertas	Modelagem financeira
Predição das falhas de equipamentos	Genética e melhoramento Animal com dados de toda a cadeia
Modelos para nova precificação	
Detecção de intrusos na rede	

Processo geral



Training data

Formas de aprendizado/ Algoritmos

Supervised learning	Unsupervised Learning
Observações das variáveis e histórico dessas observações	Dados sem histórico/ se observam as variáveis de entrada.
Se deseja prever um resultado ou inferir sobre as variáveis	O algoritmo precisa descobrir o que está sendo mostrado.
Para cada observação da variável existe uma variável resposta	Para cada observação da variável não existe uma variável resposta associada
Classificação, Regressão, GAMs (generalized additive models), boosting	Agrupamento K-means; Decomposição singular, componentes principais, mapas de auto organização.
Ajuste sobre modelos de regressão linear	Não é possível o ajuste sobre modelos com regressão linear
Utilizado em aplicações onde dados históricos predizem prováveis eventos futuros.	Encontrar padrões de comportamento;
Exemplo: Prediz o preço de uma casa, baseado em diferentes características de diversas casas que possuem dados antigos; Dados de pesos de animais	Exemplo: Encontra principais atributos que separam segmentos de consumidores; Diversidade genética


Reinforcement learning /Neural Network

- O algoritmo descobre, através de tentativa e erro, quais ações levam ao melhor resultado (prêmio).
- Robótica, jogos, navegação e caminhos de expressão gênica (ciências ômicas).
- Possui três componentes: o agente (o aprendiz ou tomador de decisões), o ambiente (tudo que interage com o agente) e ações (o que o agente pode ter).

ML no Melhoramento Genético Animal


- ML e MGA compartilham importantes objetivos tais como predição e muitas técnicas já são aplicadas em predição genômica;
- MGA utiliza de “Big Data” e métodos estatísticos – que entram dentro do escopo do ML, então o MGA é também machine learning; ou pelo menos uma parte da área de ML;

Tipo de informação – Bioinformação/Heterogeneidade




Mas o quanto é o “Big” Data?

CONCEITO RELATIVO



Classificação do que seria “aceitável” como base de dados



Temos uma definição “concreta”?

What is Big Data?

“Big data is like teenage sex: everyone talks about it, nobody really knows how to do it, everyone thinks everyone else is doing it, so everyone claims they are doing it...”

Dan Ariely

Inferência e Predição

$$\begin{aligned} E(Y - \hat{Y})^2 &= E[f(X) + \epsilon - \hat{f}(X)]^2 \\ &= \underbrace{[f(X) - \hat{f}(X)]^2}_{\text{Reducible}} + \underbrace{\text{Var}(\epsilon)}_{\text{Irreducible}}, \end{aligned}$$



- Estimar \mathbf{f} considerando a relação linear ou não-linear;
- Utilizar dados de treinamento “training data” para encontrar \mathbf{f} ;
- Encontrar um método de aprendizagem estatístico paramétrico ou não paramétrico

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{f}(x_i))^2, \quad \text{Training MSE}$$



Test MSE $E \left(y_0 - \hat{f}(x_0) \right)^2 = \text{Var}(\hat{f}(x_0)) + [\text{Bias}(\hat{f}(x_0))]^2 + \text{Var}(\epsilon).$

bias-variance trade-off



Critérios

- A escolha do adequado nível de flexibilização é um ponto crítico para o sucesso de qualquer método de aprendizado de máquina a ser escolhido.
- O Trade-off bias-variance e a resultante curva em forma de U no MSE, tornam a tarefa bastante complicada.

ML no Melhoramento Genético Animal

- ML pode ser utilizada para “aprender” a ponderar o efeito de cada SNP (prioris) e então utilizar esse aprendizado no método escolhido de predição genômica.
- Combinar dados estruturados com não - estruturados; (alto custo)
- Modelo considerado no MGA – modelo linear;
- Classification and regression trees, random forests, kernel-based methods e assim por diante.

ML no Melhoramento Genético Animal


- MGA utiliza métodos condicionados ao modelo;
- ML procura encontrar o mais eficiente algoritmo e pouca importância a noção do modelo. (“model free”) – Hiperparametrização;
- Resultados difíceis de interpretar em ML;
- Entretanto, superestimando os sinais genéticos $p > n$;

ML no Melhoramento Genético

Animal

- Pérez-Enciso M. **Animal Breeding learning from machine learning**. J Anim Breed Genet. 2017 Apr;134(2):85-86. doi: 10.1111/jbg.12263. PMID: 28297136;
- Long N, Gianola D, Rosa GJM, Weigel KA, Avendano S. **Machine learning classification procedure for selecting SNPs in genomic selection: application to early mortality in broilers**. Dev Biol (Basel). 2008;132:373-376. doi: 10.1159/000317279. PMID: 18817329.;
- Long N, Gianola D, Rosa GJ, Weigel KA, Avendaño S. **Comparison of classification methods for detecting associations between SNPs and chick mortality**. Genet Sel Evol. 2009 Jan 23;41(1):18. doi: 10.1186/1297-9686-41-18. PMID: 19284707; PMCID: PMC3225888.;
- SANT'ANNA, Isabela de Castro et al . **Subset selection of markers for the genome-enabled prediction of genetic values using radial basis function neural networks**. Acta Sci., Agron., Maringá , v. 43, e46307, 2021 . Available from <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1807-86212021000102006&lng=en&nrm=iso>. access on 18 Feb. 2021. Epub Sep 11, 2020. <http://dx.doi.org/10.4025/actasciagron.v43i1.46307>.
- Cominotte, Alexandre & Araujo Fernandes, Arthur Francisco & Dorea, Joao & Rosa, Guilherme & Ladeira, Márcio & Cleef, Eric & Pereira, G.L. & Baldassini, Welder & Machado Neto, Otavio. (2019). **Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases**. Livestock Science. 232. 103904. 10.1016/j.livsci.2019.103904.
- Vera Cardoso Ferreira Aiken, João Ricardo Rebouças Dórea, Juliano Sabella Acedo, Fernando Gonçalves de Sousa, Fábio Guerra Dias, Guilherme Jordão de Magalhães Rosa,. **Record linkage for farm-level data analytics: Comparison of deterministic, stochastic and machine learning methods**, Computers and Electronics in Agriculture, 2019, <https://doi.org/10.1016/j.compag.2019.104857>.

Então, o que podemos fazer?




Exemplo prático

- Dados.csv – Machine learning project.pdf

INFERÊNCIA CAUSAL

Os piratas
desapareceram
nos últimos
séculos

hmmm...



Ao mesmo tempo, o
aquecimento global
aumentou
drasticamente

hmmm...



Então, quer dizer que a
falta de piratas causou
o aquecimento global
!!!!

huh...O QUE?

