

Yapay Zekanın Doğuşu 1943 - 1956

Altın Çağ 1956 – 1974

Yapay Zeka Kışı 1974 – 1980

GPU Çağı 2012 - Günümüz

Bilgisayar ve Zeka

Alan Turing'in, düşünen makineler yaratma olasılığı hakkında düşüncelerini paylaştığı makalesi, bir dönüm noktası yarattı.

Yapay Zeka ve Oyun

Manchester Üniversitesi'nin Ferranti Mark 1 makinesini kullanan Christopher Strachey bir dama programı, Dietrich Prinz ise bir satranç programı yazdı.

Perceptron

Marvin Minsky

"Bir kuşak içinde 'yapay zeka' oluşturma problemi çözülmüş olacak."

Cylons

Orjinal "Savaş Yıldızı Galactica" bilim kurgu dizisi savaşçı robotlar Cylonları tanıttı.

Deep Blue ve Kasparov

IBM'in Deep Blue'su, Garry Kasparov ile girdiği satranç karşılaşmasını kazandı.

Watson ve Jeopardy!

IBM'in Watson bilgisayarı, televizyon yarışması "Jeopardy!" şampiyonları Rutter ve Jennings'i yendi.

Grafik İşlecileri (GPU) Çağı

GPU odaklı bir sistem, Imagenet'te en iyi hata oranını yarıya indirerek birinci oldu.

GAN

Ian Goodfellow tarafından Generative Adversarial Networks(Çekişmeli Üretici Ağlar) bulundu. Yapay zekanın gerçeğe benzer sahte üretimler yapabilmesinin ölü açıldı.

Asilomar

Asilomar Conference on Beneficial AI, Future of Life Institute tarafından, Kaliforniya'daki Asilomar Konferans Alanı'nda düzenlendi.

BERT

Google, dönüştürücü ağ tabanlı doğal dil işleme modeli BERT'i yayınladı.

GPT-3

175 milyar parametre



1950



I, Robot



1951



John McCarthy

1956'daki Dartmouth Konferansı için 1955 yılında isim babası olduğu Yapay Zeka ermini ortaya atmıştır.



1955




Unimation

İlk endüstriyel robot şirketi Unimation kuruldu.



1957



XOR Problemi

"Perceptrons: An Introduction to Computational Geometry" - Marvin Minsky & Seymour Papert



1962




Amerikan Yapay Zeka Derneği

İlk Ulusal Konferansı, Stanford'da düzenlendi.



1967



Deep Neural Network

Ruslan Salakhutdinov & Geoffrey Hinton



1969



Apple Siri



1978



Amazon Alexa



1980



AlphaGO

Google DeepMind'in AlphaGO'su, Lee Sedol ile karşılaştığı go maçıını 4-1 kazandı.



1997



Transformer Networks

Dönüştürücü ağlar adında yeni bir sinir ağı türü tanıtıldı.



2006



GPT-2

1.5 milyar parametrelili GPT-2, OpenAI tarafından yayımlandı.



2011

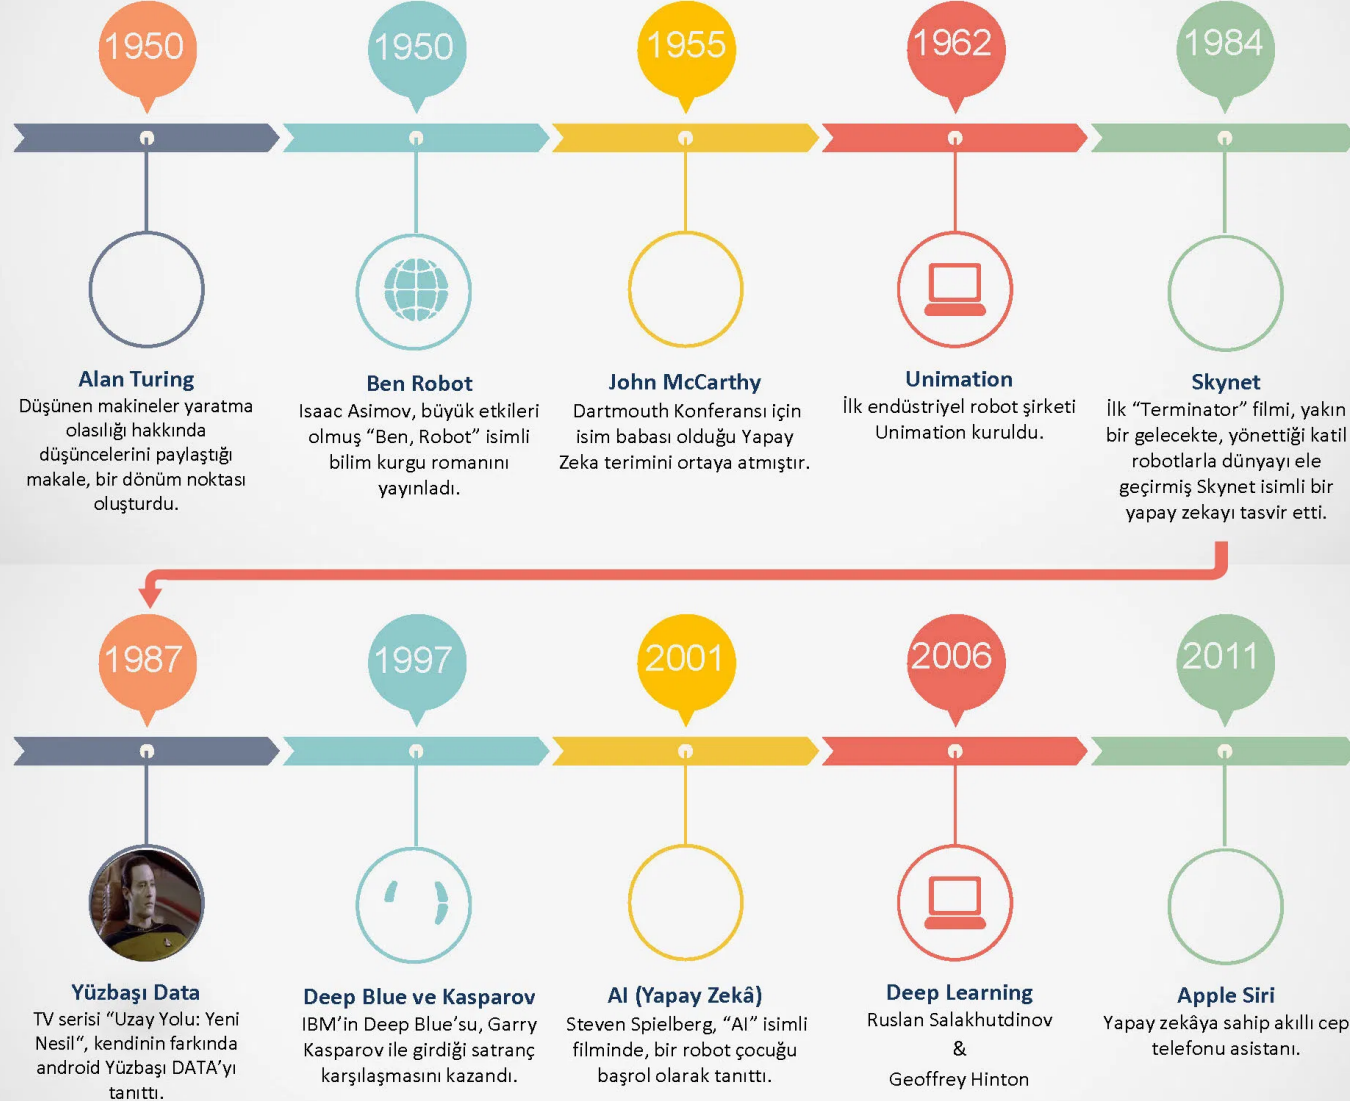


DALL-E

Yazıyla tarif edilen resimleri üretebilme yeteneği olan DALL-E adlı çalışma OpenAI tarafından yayımlandı.

Yapay Zekâ

ZAMAN ÇİZELGESİ



YAPAY ZEKA

Algılayan, sonuç çıkaran, aksiyon alan ve adapte olan bir program

MAKİNE ÖĞRENİMİ

Daha fazla veriye ulaştığında algoritmaların performansının artması

DERİN ÖĞRENME

Çok miktarda veri kullanarak kendi kendine öğrenen çok katmanlı yapay sinir ağlarından oluşan bir grup makine öğrenmesi

Yapay Zeka, Makine Öğrenimi, Derin Öğrenme İlişkisi

Yapay zekâ, makine öğrenimi ve derin öğrenme tıpkı insan gibidir. İnsan vücudunda birçok organ bulunmakta bu organlardan birinin hasar görmesi veya olmaması çoğunlukla ölümle sonuçlanmaktadır. Aslına bakarsanız anlatılmak istenen bu üç kavramın ayrı şekilde çalışmasının çok zor olduğu ifade edilmektedir.

Derin Öğrenme

- Hem yapay zekânın hem de makine öğreniminin temelini oluşturan yapı taşı olarak adlandırabiliriz.
- Kendine ait mantıksal bir yapısı bulunmaktadır.


Makine Öğrenimi

- Kendisine sağlanan verileri işleyerek en gerçekçi sonuçları üretmesini sağlayan mantıksal yapıdır.
- Ham bilgiler makine içerisine yazılım olarak yüklenmektedir.


Yapay Zeka

- Tüm bu teknolojik alt yapılar yapay zekâyı ortaya çıkarmaktadır.
- Ses tanıma, görüntü işleme ve muhakeme yeteneğini makinalara kazandırmıştır.

Machine Learning




Deep Learning



YAPAY ZEKA

Erken yapay zeka heyecan
uyandırıyor



MAKİNE ÖĞRENME

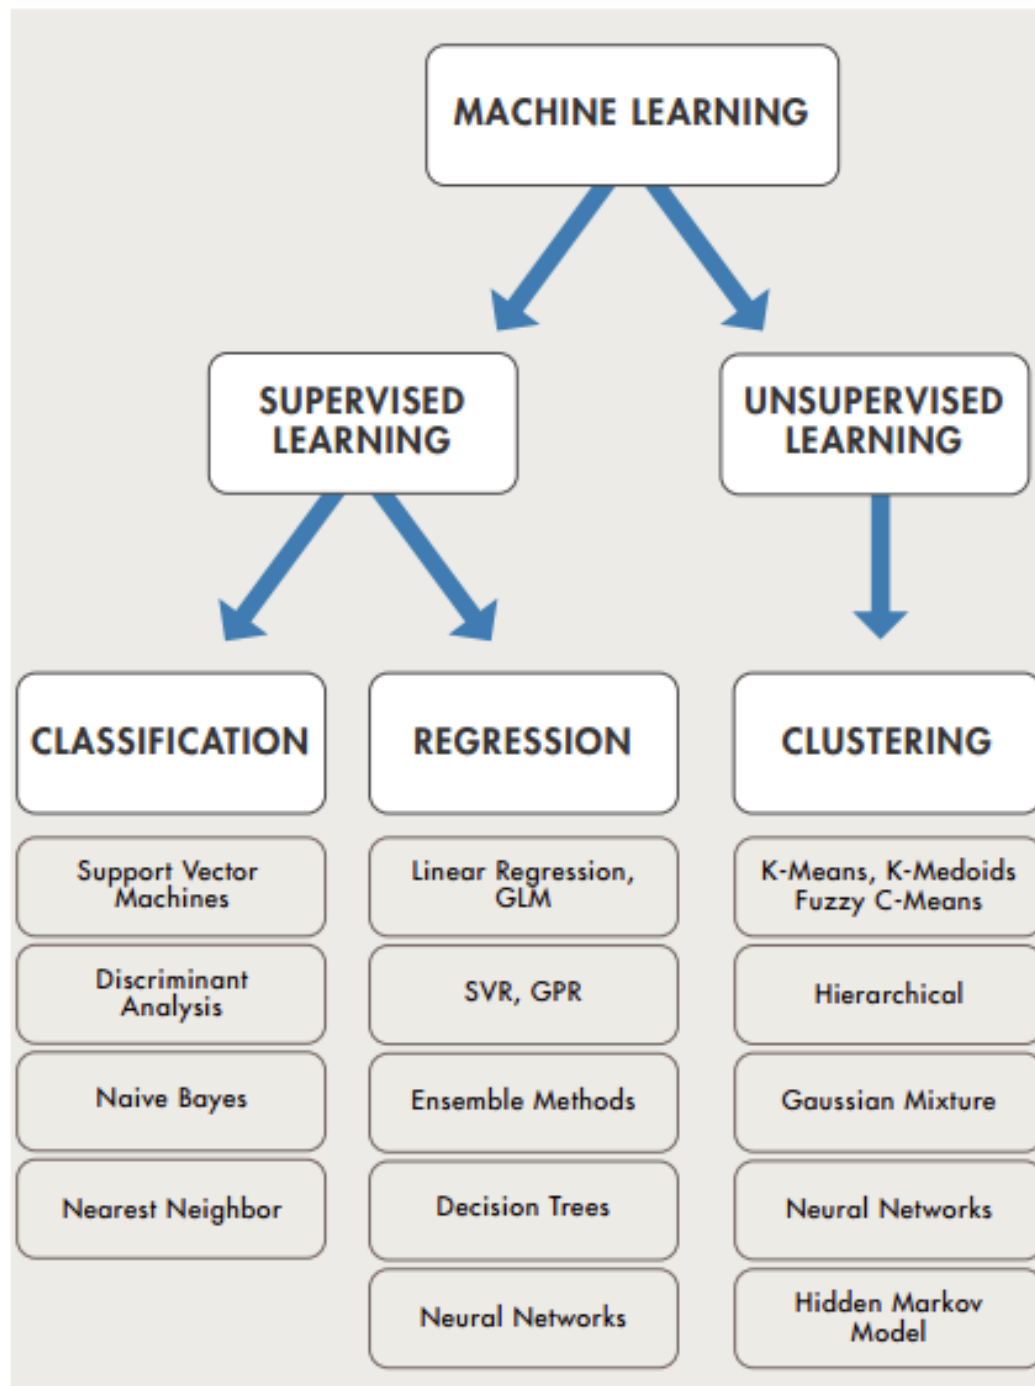
Makine öğrenimi
gelişmeye başlıyor



DERİN ÖĞRENME

Derin öğrenme atılımları yapay
zeka patlamasını teşvik ediyor





YAPAY ZEKA

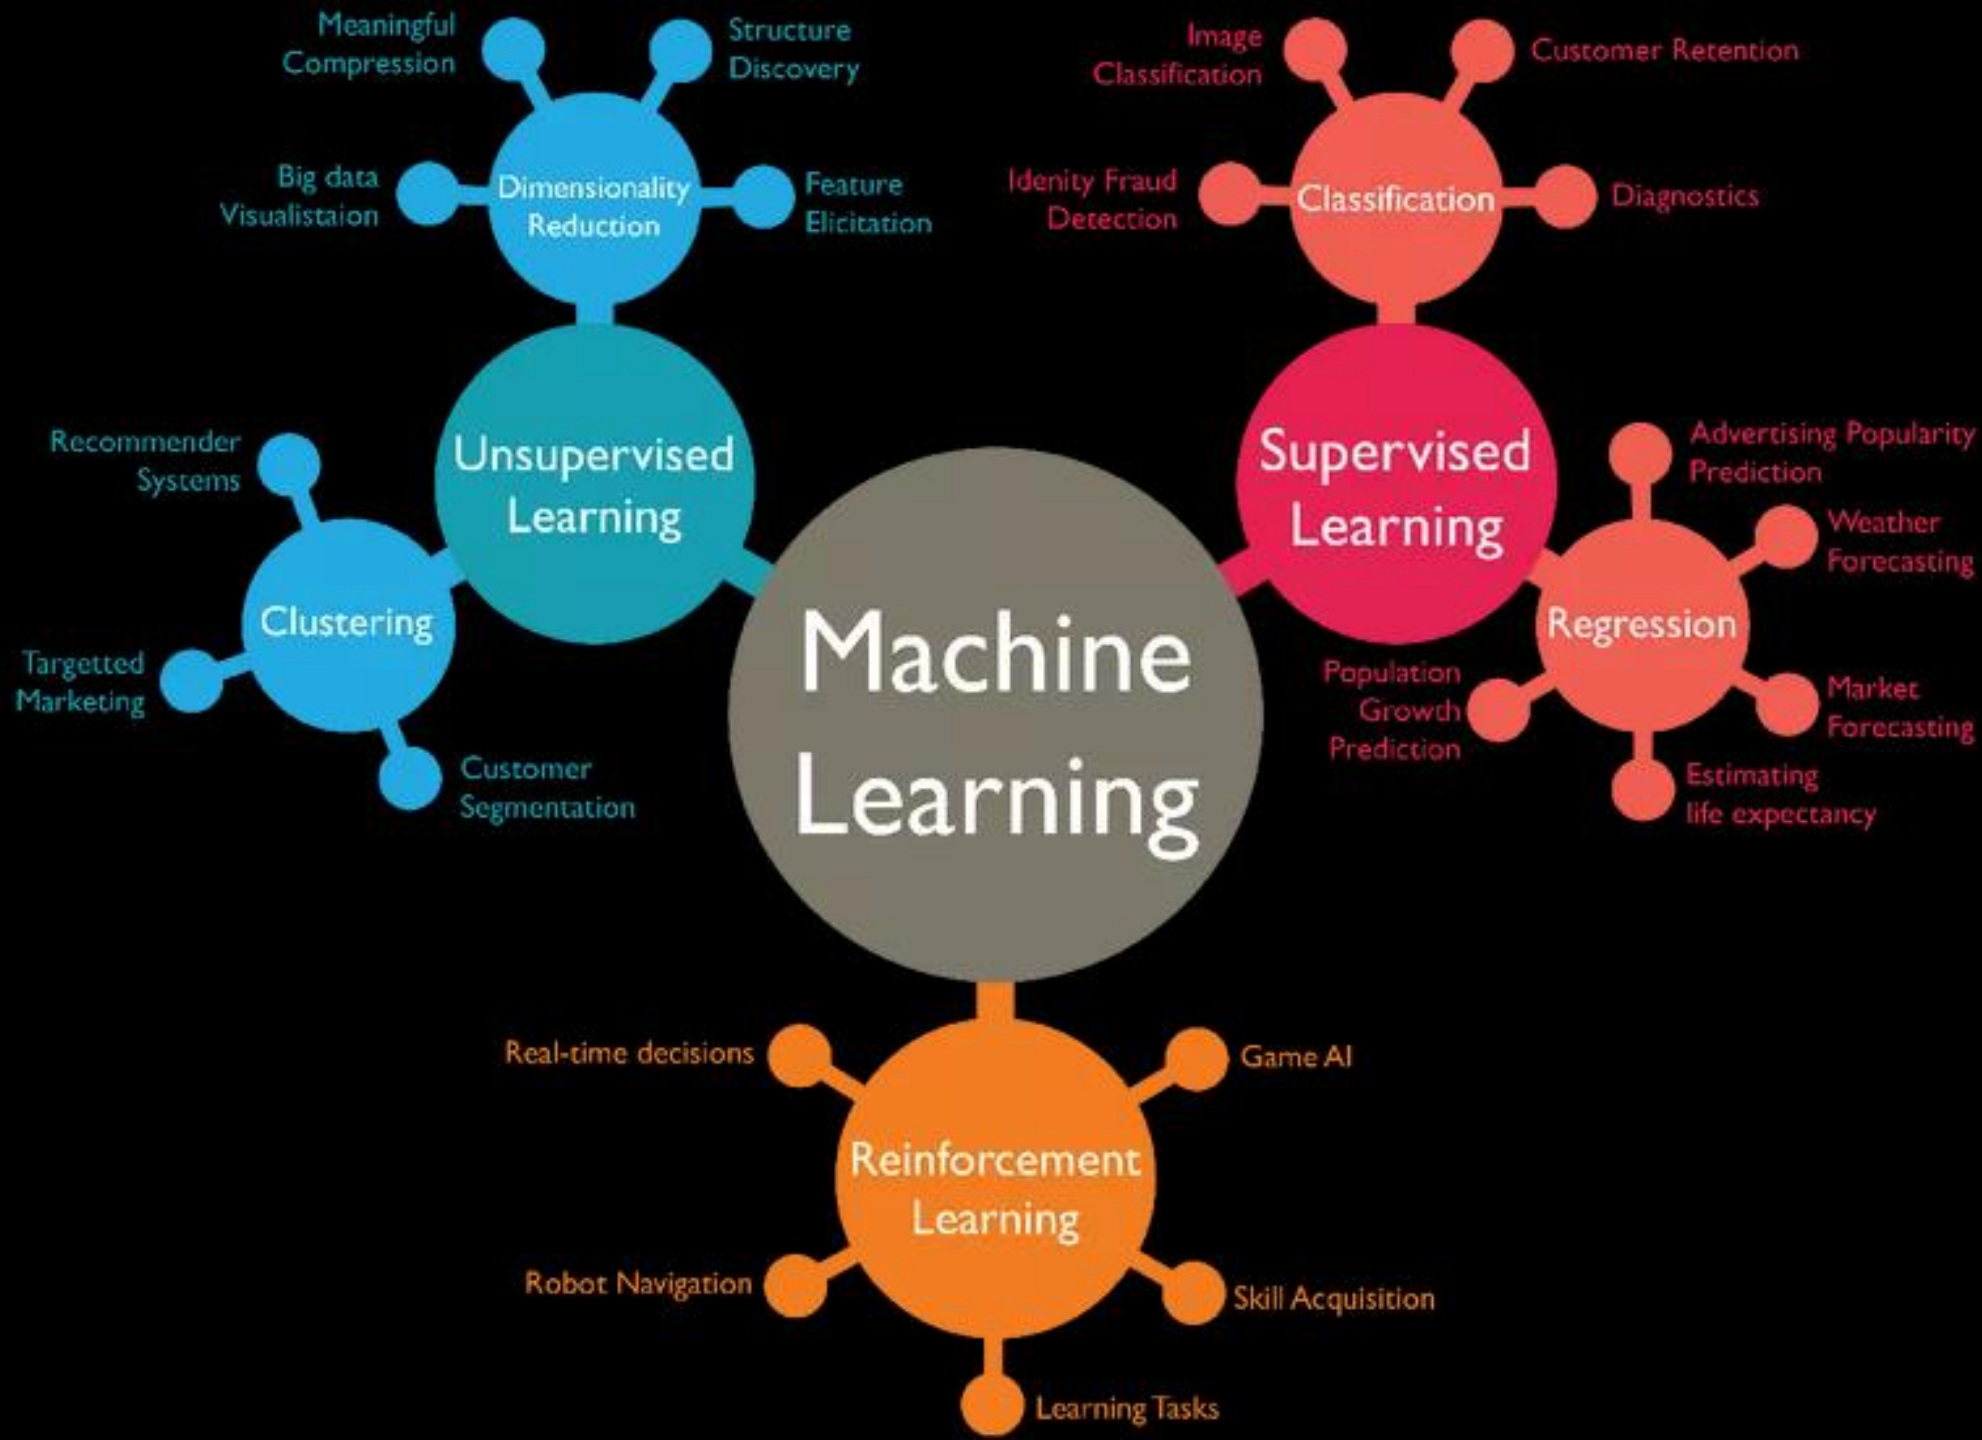
Algılayabilen, akılda tutan, hareket eden ve uyum saęlayan bir program.

MAKİNE ÖĞRENMESİ

Daha fazla veriye maruz kaldıklarında performansları artan algoritmalar.

DERİN ÖĞRENME


Çok katmanlı sinir aęlarının çok büyük miktarda veriden öğrendiđi makine öğrenmesi alt kümesi.



What it Does

Sample Use Cases


Linear regression



Numerical prediction

Forecasting sales revenues


Logistic regression



Binary classification

Customer response modeling

K-means



Clustering

Customer segmentation

Machine Learning Overview

MACHINE LEARNING IN EMOJI

Becoming Human.AI

SUPERVISED

human builds model based on input / output

UNSUPERVISED

human input, machine output
human utilizes if satisfactory

REINFORCEMENT

human input, machine output
human reward/punish, cycle continues

BASIC REGRESSION

LINEAR

`linear_model.LinearRegression()`

Lots of numerical data



LOGISTIC

`linear_model.LogisticRegression()`

Target variable is categorical



CLUSTER ANALYSIS

K-MEANS

`cluster.KMeans()`

Similar datum into groups based on centroids



ANOMALY DETECTION

`covariance.EllipticalEnvelope()`

Finding outliers through grouping



CLASSIFICATION

NEURAL NET

`neural_network.MLPClassifier()`

Complex relationships. Prone to overfitting
Basically magic.



K-NN

`neighbors.KNeighborsClassifier()`

Group membership based on proximity



DECISION TREE

`tree.DecisionTreeClassifier()`

If/then/else. Non-contiguous data.
Can also be regression.



RANDOM FOREST

`ensemble.RandomForestClassifier()`

Find best split randomly
Can also be regression



SVM

`svm.SVC()` `svm.LinearSVC()`

Maximum margin classifier. Fundamental
Data Science algorithm



NAIVE BAYES

`GaussianNB()` `MultinomialNB()` `BernoulliNB()`

Updating knowledge step by step
with new info



FEATURE REDUCTION

T-DISTRIBUTION STOCHASTIC NEIGHBOR EMBEDDING

`manifold.TSNE()`

Visual high dimensional data. Convert similarity to joint probabilities



PRINCIPLE COMPONENT ANALYSIS

`decomposition.PCA()`

Distill feature space into components that describe greatest variance



CANONICAL CORRELATION ANALYSIS

`decomposition.CCA()`

Making sense of cross-correlation matrices



LINEAR DISCRIMINANT ANALYSIS

`lda.LDA()`

Linear combination of features that separates classes



OTHER IMPORTANT CONCEPTS

BIAS VARIANCE TRADEOFF

UNDERFITTING / OVERFITTING

INERTIA

ACCURACY FUNCTION

$(TP+TN) / (P+N)$

PRECISION FUNCTION

`manifold.TSNE()`

SPECIFICITY FUNCTION

$TN / (FP+TN)$

SENSITIVITY FUNCTION

$TP / (TP+FN)$