

Bag of words: unordered collection of words {"John": 1, "likes": 7, "viagra": 3}  
Term Weighting:  $tf-idf \rightarrow$  How important a word is to a document.  $tf = \#$  in document  
 $idf(t, D) = \log \left[ \frac{|D|}{|\{d \in D : t \in d\}|} \right] \rightarrow D = \text{all docs} \Rightarrow tf-idf(t, d, D) = tf(t, d) \cdot idf(t, D)$  Stop-words  
Similarity of vectors:  $sim(q_k, d_j) = \sum_i (t_{ik} \cdot t_{ij})$ . Multinomial: events are independent...  
 Doc is multinom outcome of words.  $P(W_1 = n_1, \dots, W_k = n_k | N, \theta_1, \dots, \theta_k) = \frac{N!}{n_1! \dots n_k!} \cdot \theta_1^{n_1} \dots \theta_k^{n_k}$   
Classification: KNN: needs a distance metric. Determine  $k$ .  $\rightarrow$  Majority vote...  
 between the  $k$  nearest. Possible weighting:  $1/dist^2$ . All computation deferred until classification...  
 A popular label may dominate due to its quantity  $\rightarrow$  try to weight closest items to overcome.

Association Rule Mining: {Onions, Potatoes}  $\Rightarrow$  {burger}.  $I = \{i_1, \dots, i_n\}$  items (boolean)  
 $D = \{t_1, \dots, t_m\}$  transactions. Rule:  $X \Rightarrow Y$  where  $X, Y \in I$  and  $X \cap Y = \emptyset$ . MinSup, MinConf.  
Support  $Supp(X) =$  Proportion of transactions containing itemset  $X$ . Confidence  $Conf(X \Rightarrow Y) =$   
 $= Supp(X \cup Y) / Supp(X) = P(Y|X)$ . Lift  $Lift(X \Rightarrow Y) = Supp(X \cup Y) / (Supp(X) \cdot Supp(Y))$   
 $Lift > 1 = \text{positive correlation}$ ,  $Lift < 1 = \text{negative}$ ,  $Lift = 1 = \text{independent}$ . Apriori Principle: If an itemset is frequent,  
 then all of its subsets must also be frequent.  $\{A, B, C, D\}$   $Conf(ABC \Rightarrow D) \geq Conf(AB \Rightarrow CD) \geq \dots (A \Rightarrow B)$   
 $Lift(X \Rightarrow Y) = P(Y|X) / P(X)$   
 $\rightarrow D(A, B) \leq D(A, C) + D(C, B)$ . Manhattan  $(a, b) = \sum_i (a_i - b_i)$

Clustering: Distance Properties:  $D(A, B) = D(B, A)$ ;  $D(A, A) = 0$ ;  $D(A, B) = 0 \Rightarrow A = B$ ;  
Euclidean:  $d(x, y) = \sqrt{\sum_{n=1}^N (x_n - y_n)^2}$ ; Cosine Similarity:  $\alpha \cdot b = |\alpha| \cdot |b| \cdot \cos \theta$ . Given  $\vec{A}, \vec{B}$   
Similarity  $= \cos(\theta) = (\vec{A} \cdot \vec{B}) / (|\vec{A}| \cdot |\vec{B}|) = \frac{\sum_i A_i \cdot B_i}{\sqrt{\sum_i A_i^2} \cdot \sqrt{\sum_i B_i^2}}$  range:  $(-1, \dots, 1)$ .  
Jaccard Similarity:  $J(A, B) = |A \cap B| / |A \cup B|$ .  $dist = 1 - sim \dots \rightarrow A, B$  are groups.  
In Dendograms:  $sim =$  height of lowest shared internal node. Hierarchical Clustering:  
 results in a dendrogram. K-means clustering: aims to partition  $n$  observations  
 into  $k$  clusters. Given  $n$  observations  $(x_1, \dots, x_n)$  each  $x$  is  $d$  dimensional vector, partition to  $k$  sets  
 $S = \{S_1, \dots, S_k\}$  minimize the "within cluster sum of squares"  $\text{argmin} \sum_{j=1}^k \sum_{x \in S_j} |x_j - \mu_j|^2$ .  $\mu_j =$  mean of points in  $S_j$   
 The algorithm alternates between two steps until convergence: ① Assignment step:  
 $S_j^t = \{x_p : |x_p - m_j^t|^2 \leq |x_p - m_l^t|^2 \forall 1 \leq l \leq k\}$  ② Update step:  $m_j^{t+1} = \frac{1}{|S_j^t|} \cdot \sum_{x \in S_j^t} x_j$ . since the arithmetic  
 mean is a least-squares estimator, this also minimizes the  $\rightarrow$  WCSS objective.  
 assumes clusters are of similar sizes. for different sizes the EM is better (generalization of Kmeans)  
K-medoids: PAM  $\leftrightarrow$  Partitioning Around Medoids: Silhouette - tool for determining  $k$ .

Algorithm: ① Initialize: randomly select  $k$  of the  $n$  data-points as the medoids  
 ② Associate each data-point to the closest medoid. ③ for each medoid  $m$ :  
 ③.① For each non-medoid data point  $o$  ③.①.① Swap  $m$  and  $o$  and compute the  
 total cost of the configuration. ④ Select the configuration with the lowest cost.  
 ⑤ Repeat steps 2-4 until there is no change in the medoid. \*  $Cost = \sum_{i \in S} \sum_{j \in S} d(i, j)$   
Silhouette (Clustering): How well each object lies within its cluster.  $\alpha(i)$  is average  
 distance of object  $i$  with all other objects within its own cluster.  $b(i)$  is lowest  
 average distance of  $i$  to all other clusters. the cluster with distance  $b(i)$  is the  
 neighboring cluster: (best fit after current cluster)  $\rightarrow S(i) = [b(i) - \alpha(i)] / \max\{\alpha(i), b(i)\}$   
 $-1 \leq S(i) \leq 1$ . 1 is great,  $(-1)$  is worst, 0 point is on the kiss-border between the neighboring clusters

Agglomerative hierarchical Clustering: in beginning each element is a cluster of its own.  $(x \in X, y \in Y)$   
Single-linkage:  $D(x, y) = \min d(x, y)$ . Complete linkage:  $D(x, y) = \max d(x, y)$ . Average:  $\frac{1}{|X| \cdot |Y|} \cdot \sum_{x \in X} \sum_{y \in Y} d(x, y)$   
 $-P(\text{yes}) \log_2 P(\text{yes}) - P(\text{no}) \log_2 P(\text{no})$   $\rightarrow$  ה' מופיע' עם' נקבעת' האנרגיה' הנכונה' השרי' האנרגיה' הנכונה' השרי' האנרגיה' הנכונה' השרי'  
Decision Tree Learning: Data comes in records of form  $(X, Y) = (x_1, x_2, x_3, \dots, x_k, Y)$

Work top-down by choosing a variable at each step that best splits the set of items. Gini Impurity:  
 is a measure of how often a randomly chosen element from the set would be incorrectly labeled if it were  
 randomly labeled according to the distribution of labels in the subset. suppose  $s$  takes on values  $\{1, 2, \dots, m\}$  and  
 let  $f_i$  be the fraction of items labeled with value  $i$  in the set.  $I_G(f) = \sum_i f_i \cdot (1 - f_i) = \sum_i (f_i - f_i^2) =$   
 $= \sum_i f_i - \sum_i f_i^2 = 1 - \sum_i f_i^2$ . Information Gain:  $I_E(f) = -\sum_i f_i \cdot \log_2(f_i)$  האנרגיה' הנכונה' השרי'  
Entropy:  $E(S)$  is the measure of the amount of uncertainty in the set  $S$ . מרחק' קרוב' מרחוק'  
 $E(S) = -P(\text{yes} | \text{big}) \log_2 P(\text{yes} | \text{big}) - P(\text{no} | \text{big}) \cdot \log_2 P(\text{no} | \text{big}) \rightarrow$  האנרגיה' הנכונה' השרי'  
 $I_G(r, \text{size}) = E(r) - \frac{|S_{\text{big}}|}{|M|} \cdot E(S_{\text{big}}) - \frac{|S_{\text{small}}|}{|M|} \cdot E(S_{\text{small}})$  Information Gain: How much uncertainty in  $S$  was reduced  
האנרגיה' הנכונה' השרי'

K-Medoids: Medoid - אחד מן הנקודות באופן חופשי. האנרגיה' הנכונה' השרי'  
 כמות, מרחקים, האנרגיה, שנתקופקו את סכום האנרגיה של  $K$  הנקודות. האנרגיה' הנכונה' השרי'  
 כל האנרגיה שמתקופקו את הנקודות שבו הנקודות האם הניבוע כפול. האנרגיה' הנכונה' השרי'  
האנרגיה' הנכונה' השרי' האנרגיה' הנכונה' השרי' האנרגיה' הנכונה' השרי'

Bayesian Inference: Bayes rule:  $P(H|E) = \frac{P(E|H) \cdot P(H)}{P(E)}$  Evidence

There are competing hypotheses from which one chooses the most probable. Naive Bayes Classifier: assumes that the presence or absence of a particular feature is unrelated to any other feature, given the class variable. The probability model for a classifier is conditional:  $P(C|F_1, \dots, F_n) \leftarrow$  Class; Feature. Posterior =  $\frac{\text{Prior} \cdot \text{likelihood}}{\text{evidence}}$

$P(C|F_1, \dots, F_n) = P(C) \cdot P(F_1, \dots, F_n|C) / P(F_1, \dots, F_n)$  Denom is Const.  
 $P(C|F_1, \dots, F_n) = \text{const} \cdot P(C) \cdot \prod_i P(F_i|C)$  Naive assumption. All model parameters (class priors and feature probability distributions) can be approximated with relative frequencies from the training set. Class prior  $\rightarrow$  ①  $\frac{1}{\#C}$  equally for all or ②  $\frac{\#C_i}{\#C} \leftrightarrow$  Relative Frequency of  $C_i$

For discrete features  $\rightarrow$  Multinomial and Bernoulli distributions are popular to assume. Bernoulli  $\leftrightarrow X \sim \text{Ber}(p) \leftrightarrow P(X=1) = p$ . Multinomial  $\leftrightarrow P(x_1, \dots, x_k; n, p_1, \dots, p_k) = \frac{n!}{x_1! \dots x_k!} \cdot p_1^{x_1} \dots p_k^{x_k}$

For continuous features  $\leftrightarrow$  Gaussian dist. assumed.  $P(X=v|C) = \frac{1}{\sqrt{2\pi}\sigma_c} \cdot \exp(-\frac{(v-\mu_c)^2}{2\sigma_c^2})$  MAP  
Sample-correction is needed when one of the freqs is 0 in training set. Maximum A posteriori Decision Rule  
Classify  $(f_1, \dots, f_n) = \text{argmax}_c P(C=c) \cdot \prod_i P(F_i=f_i|C=c)$ .  $\mu = \frac{1}{n} \sum X_i$ ;  $\sigma^2 = \frac{1}{n} \sum (X_i - \mu)^2$

Document Classification:  $P(D|C) = \prod_i P(w_i|C)$ .  $P(D|C) = P(D|C)/P(C)$ .  $P(C|D) = P(D|C)/P(C) \Rightarrow P(C|D) = \frac{P(C)}{P(D)} \cdot P(D|C)$   
Spam or  $\neg$  Spam:  $P(S|D) = \frac{P(S)}{P(D)} \cdot \prod_i P(w_i|S)$ . Same for  $\neg S$ .  $P(S|D)/P(\neg S|D) = \frac{P(S)}{P(\neg S)} \cdot \prod_i \frac{P(w_i|S)}{P(w_i|\neg S)}$

$\ln [P(S|D)/P(\neg S|D)] = \ln \frac{P(S)}{P(\neg S)} + \sum_i \ln [P(w_i|S)/P(w_i|\neg S)]$ . Spam if  $P(S|D) > P(\neg S|D) \Rightarrow \Rightarrow$  when  $\ln [P(S|D)/P(\neg S|D)] > 0$ . LDA-Linear discriminant analysis: find a linear combination of features which characterizes or separates two or more classes of objects. Fundamental assumption: the independent variables are normally distributed.

For 2 classes: Assumes  $P(\vec{x}|y=0)$  and  $P(\vec{x}|y=1)$  are both normally distributed with mean and covariance  $(\vec{\mu}_0, \Sigma_{y=0})$  and  $(\vec{\mu}_1, \Sigma_{y=1})$ . Under this assumption, the Bayes optimal solution is to predict  $y=1$  if the lg of the likelihood ratios is below some threshold  $J$ :  $(\vec{x} - \vec{\mu}_0)^T \Sigma_{y=0}^{-1} (\vec{x} - \vec{\mu}_0) + \ln(\Sigma_{y=0}) - (\vec{x} - \vec{\mu}_1)^T \Sigma_{y=1}^{-1} (\vec{x} - \vec{\mu}_1) - \ln(\Sigma_{y=1}) < J$

Without further assumptions, the above is QDA. LDA assumes  $\Sigma_{y=0} = \Sigma_{y=1} = \Sigma$  in this case several terms cancel and the above becomes  $\vec{w} \cdot \vec{x} > C$  for some threshold constant  $C$ , where  $\vec{w} \propto \Sigma^{-1} (\vec{\mu}_1 - \vec{\mu}_0) \Rightarrow$  Criterion of an input  $\vec{x}$  being of class  $y$  is purely a function of this linear combination of the known observations. In geometrical terms we project a <sup>multidimensional</sup> space point  $\vec{x}$  onto vector  $\vec{w}$  (thus we only consider its direction) in other words, the observation belongs to  $y$  if corresponding  $\vec{x}$  is located on a certain side of a hyperplane perpendicular to  $\vec{w}$ . The location of the plane is defined by the threshold  $C$ . Fisher's linear discriminant: Suppose 2 classes of observations have means  $\vec{\mu}_{y=0}, \vec{\mu}_{y=1}$  and covariances  $\Sigma_{y=0}, \Sigma_{y=1}$  then the linear combination of features  $\vec{w} \cdot \vec{x}$  will have means  $\vec{w} \cdot \vec{\mu}_{y=i}$  and variances  $\vec{w}^T \Sigma_{y=i} \vec{w}$  for  $i=0,1$

Fisher defines the separation as the ratio of the variance between the classes to the variance within the classes:  $S = \sigma_{\text{between}}^2 / \sigma_{\text{within}}^2 = \frac{[\vec{w} \cdot \vec{\mu}_{y=1} - \vec{w} \cdot \vec{\mu}_{y=0}]^2}{[\vec{w}^T \Sigma_{y=1} \vec{w} + \vec{w}^T \Sigma_{y=0} \vec{w}]}$   
 $= \frac{[\vec{w} (\vec{\mu}_{y=1} - \vec{\mu}_{y=0})]^2}{[\vec{w}^T (\Sigma_{y=0} + \Sigma_{y=1}) \vec{w}]}$  optimal when  $\vec{w} \propto (\Sigma_{y=0} + \Sigma_{y=1})^{-1} (\vec{\mu}_{y=1} - \vec{\mu}_{y=0})$

$\vec{w}$  is normal to the discriminant hyperplane. If projections of points from both classes have approx same distr, a good choice of  $C$  will be a hyperplane between the two means:  $C = \vec{w} \cdot \frac{1}{2} (\vec{\mu}_{y=0} + \vec{\mu}_{y=1}) = \frac{1}{2} \vec{\mu}_{y=1}^T \Sigma^{-1} \vec{\mu}_{y=1} - \frac{1}{2} \vec{\mu}_{y=0}^T \Sigma^{-1} \vec{\mu}_{y=0}$

Logistic Regression: measures the relationship between a categorical dependant variable and one or more independent variables (usually continuous), by using probability score as the predicted values of the dependent variable. Logistic regression is used to predict the odds of result success based on the values of the independent variables (predictors). The odds are defined as the probability that a particular outcome is success divided by the probability that its failure. Logistic Function:  $F(t) = e^t / (e^t + 1) = 1 / (1 + e^{-t}) \in [0, 1]$  where  $t$  is a linear function of an explanatory variable  $x$ . It can be written as:  $\pi(x) = \exp(\beta_0 + \beta_1 x) / [\exp(\beta_0 + \beta_1 x) + 1] \leftarrow$  Probability for success.

The inverse of the logistic function:  $g(x) = \ln[\pi(x) / (1 - \pi(x))] = \beta_0 + \beta_1 x$   
מאפיינים של ברטריים: עבור Soft Margin SVM נעזרים  $C$  נעזרים את "מחיר הטעות הקטנה ביותר" ונבחר  $C$  קטן יותר. עבור SVM קשה יותר לנתח את ההשפעה של  $C$  על התוצאה. ברטריים פועלים על ידי חישוב  $d$  וטוריקי את ההטייה  $R_e = \int_{R_{no}} P(x|yes) \cdot P(yes) dx + \int P(x|no) \cdot P(no) dx$  סטימה לשיעור עם החסות טאיות: Bayes

ANN - Artificial Neural Networks: Perceptrons: output  $\in \{-1, 1\}$   
 $O(x_1, \dots, x_n) = 1$  if  $w_0 + w_1 x_1 + w_2 x_2 + \dots + w_n x_n > 0$  and  $(-1)$  otherwise.  $(w_0 \cdot 1)$  is the threshold. We imagine  $x_0 = 1 \Rightarrow O(x_1, \dots, x_n) = 1$  if  $\sum_i w_i x_i > 0 \Rightarrow O(\vec{x}) = \text{sgn}(\vec{w} \cdot \vec{x})$ . Perceptron training rule:  $w_j \leftarrow w_j + \Delta w_j$  where  $\Delta w_j = \eta (t - o) x_j$   $t$  = target;  $o$  = output;  $\eta$  = learning rate - must be small! (step)

$W \leftarrow \bar{W} + \Delta W$ , where  $\Delta W = -\eta \nabla E(\bar{W})$ .  $\Delta w_{ij} = -\eta \cdot \frac{\partial E}{\partial w_{ij}}$ ;  $\frac{\partial E}{\partial w_{ij}} = \sum_k (t_{kd} - O_{kd}) \cdot (x_{jd})$   
 When we need to ensure a differentiable threshold unit:  $o = \sigma(\bar{w} \cdot \bar{x})$  ded where  $\sigma(y) = 1/(1 + \exp(-y))$

Back-Propagation: Multilayer-Network. We redefine  $E$  to sum the errors over all of the network output units:  $E(\bar{w}) \equiv \frac{1}{2} \sum_{k \in \text{output}} \sum_{i \in \text{input}} (t_{ki} - O_{ki})^2$ . input/weight from  $i$  to  $j$  is denoted as  $x_{ji}$ ,  $w_{ji}$ .  $\Rightarrow$  for each  $\langle \bar{x}, \bar{t} \rangle$  in training examples Do: ① input the instance  $\bar{x}$  to the network and compute the output  $O_k$  for every unit  $u$  in the network. ② Propagate the errors back through the network by: For each network output unit  $k$ , calculate its error term  $\delta_k \leftarrow O_k(1 - O_k)(t_k - O_k)$  ③ For each hidden unit  $h$ , calculate its error term  $\delta_h \leftarrow O_h(1 - O_h) \sum_{k \in \text{output}} w_{kh} \delta_k$  ④ Update each network weight  $w_{ji} \leftarrow w_{ji} + \Delta w_{ji}$  where  $\Delta w_{ji} = \eta \delta_j x_{ji}$ .

The EM Algorithm is used when only a subset of the relevant instance features are observable. Example: finding the means  $\mu_1, \mu_2$  of  $K=2$  Gaussians where  $\sigma_j^2$  are known... The task is to output hypothesis  $h = \langle \mu_1, \dots, \mu_K \rangle$  We want  $h$  that maximizes  $P(D|h)$ . We can think of the full description of each instance as  $\langle X_i, z_{i1}, z_{i2} \rangle$  where  $X_i$  is the observed value and  $z_i$  are indicators of where  $X_i$  came from (which gaussian)  $z_i$  are hidden variables. EM algorithm searches for a maximum likelihood hypothesis by repeatedly re-estimating the expected values of the hidden variables  $z_{ij}$  given the current hypothesis  $\langle \mu_1, \dots, \mu_K \rangle$  then recalculating the ML-hypothesis using these expected values for the hidden variables. First set  $h = \langle \mu_1, \mu_2 \rangle$  arbitrarily. Then, iteratively re-estimate  $h$  by repeating 2-steps until convergence. Step 1: Calculate expected value  $E[z_{ij}]$  for each hidden variable  $z_{ij}$  assuming  $h = \langle \mu_1, \mu_2 \rangle$ . Step 2: Calculate a new ML-hypo  $h' = \langle \mu_1', \mu_2' \rangle$  assuming value taken by each hidden variable  $z_{ij}$  is  $E[z_{ij}]$  calculated in step 1, then replace  $h$  with  $h'$  and iterate. In our example,  $E[z_{ij}]$  is just the probability that instance  $X_i$  was generated by the  $j$ th Gaussian:  $E[z_{ij}] = P(X_i | \mu_j / \sigma_j^2)$

$= \exp(-\frac{1}{2\sigma_j^2} \cdot (X_i - \mu_j)^2) / \sum_{n=1}^2 \exp(-\frac{1}{2\sigma_n^2} (X_i - \mu_n)^2)$   
 Step 2:  $\mu_j \leftarrow \frac{1}{m} \sum_{i=1}^m E[z_{ij}] \cdot X_i$ . Converges to a local maximum likelihood hypothesis for  $\mu_1, \mu_2$

In general case:  $X = \{X_1, \dots, X_m\}$  observed,  $Z = \{z_1, \dots, z_m\}$  unobserved,  $Y = X \cup Z$ .  $h$  current  $h'$  revised. EM searches for ML-hypo  $h'$  by seeking  $h'$  that maximizes  $E[\ln P(Y|h)']$ . We define a function  $Q(h|h) = E[\ln P(Y|h) | h, X]$ . Step 1: Estimation (E) step: Calculate  $Q(h|h)$  using the current hypo  $h$  and observed data  $X$  to estimate prob-dist over  $Y$ .  $Q(h|h) \leftarrow E[\ln P(Y|h) | h, X]$  Step 2: Maximization (M) step: replace  $h$  with  $h'$  that maximizes this  $Q$  function  $h \leftarrow \arg \max_h Q(h|h)$

Unsupervised EM הסברות EM ללא מיון

אנחנו מחפשים את הממונים של המופים שמוקד הממונים.

אנחנו מחפשים את הממונים של המופים שמוקד הממונים.  $N(x|\mu, \Sigma) = \frac{1}{(2\pi)^{1/2} |\Sigma|^{1/2}} \cdot \exp(-\frac{1}{2}(x-\mu)^T \Sigma^{-1}(x-\mu))$

אנחנו מחפשים את הממונים של המופים שמוקד הממונים.  $P(X_i) = \sum_k P(X_i, r_{ik}) = \sum_k P(r_{ik}) \cdot P(X_i | r_{ik}) = \sum_k \pi_k N(X_i | \mu_k, \Sigma_k)$ .  $\sigma(r_{ik}) = P(r_{ik} = 1 | X_i) = \frac{P(r_{ik}) \cdot P(X_i | r_{ik})}{\sum_{j=1}^K P(r_{ij}) \cdot P(X_i | r_{ij})} = \frac{\pi_k N(X_i | \mu_k, \Sigma_k)}{\sum_{j=1}^K \pi_j N(X_i | \mu_j, \Sigma_j)}$

אנחנו מחפשים את הממונים של המופים שמוקד הממונים.  $K = \arg \max_k \sigma(r_{ik})$ : מקיימים  $K$ -ה cluster-ים.  $\ln P(X|\pi, \mu, \Sigma) = \sum_{i=1}^N \ln \left\{ \sum_{k=1}^K \pi_k N(X_i | \mu_k, \Sigma_k) \right\}$

אנחנו מחפשים את הממונים של המופים שמוקד הממונים.  $\pi_k = \frac{N_k}{N}$   $\mu_k^{new} = \frac{1}{N_k} \sum_{i=1}^N \sigma(r_{ik}) X_i$   $\Sigma_k^{new} = \frac{1}{N_k} \sum_{i=1}^N \sigma(r_{ik}) (X_i - \mu_k^{new})(X_i - \mu_k^{new})^T$

אנחנו מחפשים את הממונים של המופים שמוקד הממונים.  $\Sigma_k^{new} = \frac{1}{N_k} \sum_{i=1}^N \sigma(r_{ik}) (X_i - \mu_k^{new})(X_i - \mu_k^{new})^T$

Decision Trees הסברות Decision Trees

$N$ -Number of observations,  $K$ -Number of classes,  $N_t$ -Number of observations at node  $t$ ,  $N_t^k$ -Number of observations from class  $k$  at node  $t$ ,  $\hat{p}(k|t)$ -proportion of observations from class  $k$  at node  $t$ .  $\hat{p}(k|t) = N_t^k / N_t$ .  $Y(t)$ -class assigned to the terminal node  $t$ . Entropy( $t$ ) =  $-\sum_{k=1}^K \hat{p}(k|t) \log_2(\hat{p}(k|t))$ , Gini Index( $t$ ) =  $1 - \sum_{k=1}^K \hat{p}^2(k|t)$  Misclassification error( $t$ ) =  $1 - \max_{k \in \dots, k} \{\hat{p}(k|t)\}$ , IG( $s, A$ ) = Entropy( $s$ ) -  $\sum_{v \in \text{child}(A)} \frac{|S_v|}{|S|} \text{Entropy}(S_v)$ .

הסברות האינפורמטיות: מרכיבות עולה-ימנה עולה. Overfitting עולה-ימנה עולה. אנחנו מחפשים את הממונים של המופים שמוקד הממונים. האינפורמטיות אנחנו מחפשים את הממונים של המופים שמוקד הממונים.

$P(Y=1|X=\alpha) = h(W^T \alpha) = \frac{1}{1 + e^{-W^T \alpha}}$  (כאן  $W^T \alpha$ ) : מודלים ליניאריים וסדרות אחרות  
 $P(Y=1|X) / P(Y=0|X) \geq 1 \Rightarrow \log \left[ \frac{P(Y=1|X)}{P(Y=0|X)} \right] \geq 0$  כעבור סף  $\log \left[ \frac{P(Y=1|X)}{P(Y=0|X)} \right] \geq 0$  אם  $P(Y=1|X) \geq P(Y=0|X)$   
 We determine  $\hat{w}$  with MLE  $L(w) = \log \prod_{i=1}^n P(Y=1|X_i, w)^{y_i} P(Y=0|X_i, w)^{1-y_i}$   
 שם למציאת פרמטרים של פונקציה  $\frac{f'(x)}{f(x)}$   $x_{n+1} = x_n - \frac{f'(x)}{f(x)}$  : מאזן ביניהם המודלים יש עקבות של אופטימליזציה עקבית  
 $P(Y=1|X) = h(W^T X) \geq \tau$   $P(Y=1|X) = 1 - P(Y=0|X)$  גבולות אחרים הם  $\tau$  -  $1 - \tau$   
 Sensitivity & Specificity :  $\text{Sensitivity} = \frac{\text{True positive}}{\text{True positive} + \text{false negative}}$  for the  $\tau$   
 $\text{Specificity} = \frac{\text{True negative}}{\text{True negative} + \text{false positive}}$

הצרות והארכות :  $K$ -medoids - לעבור מודל מרחיקים לבי אורכים, כמעט שכל המרחקים הם זהים  
 מאיפה מופנים הים הכי קרובה. פרמטרים הם קובי' אחר הצלעות שלה. MBA - יחס הקשר "חבט" אינו ארוטטיבי  
 פיצוטה כי ה-Support אינו ארוטטיבי. וואג - כאשר יש למצוא מודל מיוון וישנה בעיות אחרות כמו אופטימליזציה  
 יש להשתמש בהם המצוינות ועם רק העקרון. Gaussian Mixture ובאופן כללי Soft limit Clust - ההשמה היא הסטטיסטיקה  
 ולכן אם את המרחקים שלו מושפעים עם אלטר' עבר קודם המצוינות המצוינות עשויים לקבל סימול' עונה. Hierarch-Clustering  
 יעילי בול' עומק יסוד' עמית' למצוא מודל מיוון ולכן רק במאה מיוון' העובים. גז'י התעלה - האנארוסיה עשית שמורה'ים  
 לפצע כה פשוט סכום האנארוסיות של ערכי הפעול'  $F(yes) + F(no)$  בהם צומת המעלה התכנה של האנארוסיה  
 הוב' כמעט ערכי  $\tau$  יש עבור הצב' המצוי' של ה-Attr המצב' לפיצוטה כמעט  $\tau$  קיי'ים (כיון אם יש או סוף) עקבית  
 $\text{size} = \text{big} \dots$  והעונה הוב' כמעט ערכי  $\tau$  מצוי'ים יש לאפוזיה המצב' לפיצוטה כמעט המצב'  $Y = \text{yes}$  קיי'ות עבור  $\text{size} = \text{big}$ .  
 עבור Attr הנהם ערכים רציפים - מיי'ים את מודל המיוון עשית' המצב' והארכים את ה' המצב' (ע'י ממוצע) קיון  
 2 ערכים שמעבר' משהם הערך של  $\tau$ . לפיצוטה מפרדי' עי'נארכי עוקב' אה יוטר' הסיו' מוצ' ע'פוטמה' :  $\frac{1}{1 + e^{-x}}$

Bayes Classifier - כמעט הים אופטימלי' במקרה של מרחיקים קטנות עם חילוי'  $\frac{P(Y=1|X)}{P(Y=0|X)}$  הוא עשוי'  $1 - \delta$   $P(Y=1|X) > \frac{\delta}{1-\delta}$   
 ובה מקוד' עשוי' למתקנה  $\alpha \cdot P(Y=1|X) > \beta \cdot P(Y=0|X)$  Naive Bayes - קוד' פשוט הפרובורציה של המצב'  $P$   
 במודל' המיוון. צריק' לחשב את כל המצב'  $P(Y=1|X)$   $P(Y=0|X)$  עכ' המצב' האפטי'ים של  $X$  ו-  $Y$  ולכסוף  
 לחשב את המודל' הפוסט' ולבחור את המקסימלי' :  $f(x, y) = \prod_{i=1}^n P(x_i, y_i)$ . יש אם יש עם איוס' מודל' איוון' עשית' מופע  
 הסטטיסטיקה ולכן מיי' ומה' ש'יאה בעת' מוצ' : אם עם כל המצב' יעיל' מופע' ע'י' ע'פוטמה' מודל' המצב' המצב' המצב'

ML/MAP -  $P(\text{Data} | \text{Model})$  ועצומות MAP מקסי'  $P(\text{Model} | \text{Data})$  ID3 - עמק' ה-IG יש הטייה למצב'  $P$   
 עשוקות המודל' מרחיקים ערכים לפיצוטה האנא' של ID3 הוב' אם אהם כה פיצוטה מיו' (אופטימלי') כמעט שמספר המצב' קטן יותר  
 כן מופע' המצב' פשוט יותר המצב' המצב' והשונות' הקטן. באגסיה ע'פוטמה :  $\tau$  מושפק' לקיצו'  $Y$  :  $\tau > 1 - \tau$   
 יחס הסיכוי' הוב'  $\frac{P(Y=1|X)}{P(Y=0|X)} = \frac{1 + e^{-W^T X}}{1 + e^{-W^T X}}$  ולכן אם נשפיע את  $W$  ו-  $2$  יחידות  
 (המצב' כמעט) השי' יהיה :  $e^{2W^T X} = e^{W^T X}$  היחס יעפע' בי'  $W^T X$  כפי' למצוא את ערכ' ה-  $\tau$  האופטימלי'

נבט' את הסיכוי' האנארכים העכ'ים :  $\frac{P(\text{Pred} = 1 | \text{True} = 1)}{P(\text{Pred} = 1 | \text{True} = 0)}$   $\text{Sensitivity} = \frac{a}{a+c}$  ;  $\text{Specificity} = \frac{d}{b+d}$   
 עקומת ROC הצב'  $Y$  :  $\text{Sensitivity} = \frac{a}{a+c}$   $\text{Specificity} = \frac{d}{b+d}$   $1 - \text{Specificity} = \frac{c}{a+c}$  עבור כמעט ערכ' של  $\tau$  ועכ'ה  
 את ה-  $\tau$  שתי' למעלה ומעלה. מבול' : SVM - מפרדי' עי'נארכי (יש עם קרנה, עשית' עי'נארכי) המצב'  $\tau$   
 תב'  $W^T X + b = 0$  - PCA - לנהם עם מודל' אהם ש'יה ע'פוטמה' המודל' המודל' ע"י' הופק' מיו' ומק' מורה' מקס'  
 עם הפיצו' המקורי' עשית' לערכ' שחור'. LDA - רוצים קו ושר' שמתצביות ומעלה עשית' הן המצב' באופן ברור'.  
מקסום - LDA המקסי'  $L(X|Y)$  ואחר'  $L(Y|X)$ . הביאגסיה ע'פוטמה' המקסי'  $L(Y|X)$ .  
פונקציות נרמות : המצב' המצב' מיוון. כפי' למצוא MLE הבי' או עוקח'ים  $\log$  ואנארכים או ה'  $\log$ .  
תכונות : ה-  $\log$  מוט' אוקט'ים הני' מופע'. ש'את' מוט' באסון' : משמשים בה' עקרים שרשי פונקציה.  
 (7) מנחים נק' המעלה באופן אוקט'  $\alpha = \alpha_1$  ואם לנהם עם מודל' אהם ש'יה ע'פוטמה' המודל' המודל' ע"י' הופק' מיו' ומק' מורה' מקס'  
 עשית' המצב'  $f'(x) = x_1 + x_2 - f(x_1) / f'(x_2)$  עשית' עם מודל' אהם ש'יה ע'פוטמה' המודל' המודל' ע"י' הופק' מיו' ומק' מורה' מקס'  
 כמעט עם מודל' אהם ש'יה ע'פוטמה' המודל' המודל' ע"י' הופק' מיו' ומק' מורה' מקס'.