

Tópicos Especiais em Inteligência Artificial

COS746

Vítor Santos Costa
COPPE/Sistemas

Universidade Federal do Rio de Janeiro



O Passo de Expectativa

- Agora podemos calcular a probabilidade de que o símbolo i tenha sido produzido pelo estado k , dado uma sequência x :

$$\begin{aligned} Pr(\pi_i|k, x) &= \frac{Pr(\pi_i|k)}{Pr(x)} \\ &= \frac{f_k(i)b_k(i)}{Pr(x)} \\ &= \frac{f_k(i)b_k(i)}{f_N(L)} \end{aligned}$$

O Passo de Expectativa

- A partir daqui podemos calcular o número esperado de vezes que a letra c é emitida pelo estado k .
- De notar que adicionamos o índice j para referir a uma sequência específica no conjunto de treino.

$$n_{k,c} = \sum_{x^j} \left[\frac{1}{Pr(x^j)} \sum_{\{i|x^j=c\}} f_k^j(i) b_k^j(i) \right]$$

- ★ Soma sobre todas as sequências x^j no conjunto de treino
- ★ Soma sobre todas as posições onde c aparece em x^j

O Passo de Expectativa

- e podemos calcular o número esperado de vezes que a transição de k para l é usada:

$$n_{k \rightarrow l} = \sum_{x^j} \frac{\sum_i f_k^j(i) a_{kl} e_l(x_{i+1}^j) b_l^j(i+1)}{Pr(x^j)}$$

- ou se l é um estado silencioso:

$$n_{k \rightarrow l} = \sum_{x^j} \frac{\sum_i f_k^j(i) a_{kl} b_l^j(i)}{Pr(x^j)}$$

O Passo de Maximização

- Seja $n_{k,c}$ o número esperado de emisões de c a partir do estado k para o conjunto de treino.
- Estime novos parâmetros de emissão por:

$$e_k(c) = \frac{n_{k,c}}{\sum_{c'} n_{k,c'}}$$

- Exactamente como no caso simples
- Mas habitualmente fazemos algum *amaciamento*, (ie, adicionar psuedocontagens).

O Passo de Maximização

- Deixe $n_{k \rightarrow l}$ ser o número esperado de transições desde o estado k para o estado l para o conjunto de treino
- estime novos parâmetros de transição como:


$$a_{kl} = \frac{n_{k \rightarrow l}}{\sum_m n_{k \rightarrow m}}$$

O Algoritmo de Baum-Welch

- inicializar os parâmetros do HMM
- itere até convergir:
 - ★ inicializar $n_{k,c}, n_{k \rightarrow l}$ com pseudo-contagens
 - ★ *Passo-E:* para cada sequência de treino $j = 1 \dots n$
 - * calcule $f_k(i)$ para a sequência j
 - * calcule $b_k(i)$ para a sequência j
 - * adicione a contribuição da sequência j a $n_{k,c}, n_{k \rightarrow l}$
 - ★ *Passo-M:* atualize os parâmetros do HMM usando $n_{k,c}, n_{k \rightarrow l}$

Exemplo do Algoritmo de Baum-Welch

- dado
 - ★ um HMM com os parâmetros inicializados como em baixo
 - ★ sequências de treino **TAG, ACG**



- vamos seguir uma iteração de Baum-Welch

Exemplo do Algoritmo de Baum-Welch

- determinando os valores de forward para TAG:

$$f_0(0) = 1$$

$$f_1(1) = e_1(T) \times a_{01} \times f_0(0) = 0.4 \times 1 = 0.4$$

$$f_1(2) = e_1(A) \times a_{11} \times f_1(1) = 0.4 \times 0.8 \times 0.4 = 0.128$$

$$f_2(2) = e_2(A) \times a_{12} \times f_1(1) = 0.1 \times 0.2 \times 0.4 = 0.008$$

$$\begin{aligned} f_2(3) &= e_2(G) \times (a_{12} \times f_1(2) + a_{22} \times f_2(2)) = \\ &0.4 \times (0.0008 + 0.0256) = 0.01056 \end{aligned}$$

$$f_3(3) = a_{23} \times f_2(3) = 0.9 \times 0.01056 = 0.009504$$

- computamos apenas valores que representam probabilidade não-zero
- da mesma forma podemos computar os valores de forward de ACG

Exemplo do Algoritmo de Baum-Welch

- determinando os valores de backward para TAG:

$$b_3(3) = 1$$

$$b_2(3) = 1_{23} \times b_3(3) = 0.9 \times 1 = 0.9$$

$$b_2(2) = a_{22} \times e_2(\text{G}) \times b_2(3) = 0.1 \times 0.4 \times 0.9 = 0.036$$

$$b_1(2) = a_{12} \times e_2(\text{G}) \times b_2(3) = 0.2 \times 0.4 \times 0.9 = 0.072$$

$$\begin{aligned} b_1(1) &= a_{11} \times e_1(\text{A}) \times b_1(2) + a_{12} \times e_2(\text{A}) \times b_2(2) = \\ &0.8 \times 0.4 \times 0.072 + 0.2 \times 0.1 \times 0.036 = 0.02376 \end{aligned}$$

$$b_0(0) = a_{01} \times e_1(\text{T}) \times b_1(1) = 1.0 \times 0.4 \times 0.02376 = 0.009504$$

- computamos apenas valores que representam probabilidade não-zero
- da mesma forma podemos computar os valores de backward de ACG

Exemplo do Algoritmo de Baum-Welch

- determinando o número esperado de contagens de emissões para o estado 1:

| contribuição de TAG | contribuição de ACG | pseudo contagem |
|------------------------|------------------------|--------------------|
|------------------------|------------------------|--------------------|

$$n_{1,A} = \frac{f_1(2)b_1(2)}{f_3(3)} + \frac{f_1(1)b_1(1)}{f_3(3)} + 1$$

$$n_{1,C} = \frac{f_1(2)b_1(2)}{f_3(3)} + 1$$

$$n_{1,G} = 1$$

$$n_{1,T} = \frac{f_1(1)b_1(1)}{f_3(3)} + 1$$

- note que os valores de forward/backward diferem entre as duas sequências.

Exemplo do Algoritmo de Baum-Welch

- determinando o número esperado de transições para o estado 1 (não usamos pseudo-contagens):

$$n_{1 \rightarrow 1} = \frac{\text{contribuição de TAG}}{\frac{f_1(1)a_{11}e_1(\text{A})b_1(2)}{f_3(3)}} + \frac{\text{contribuição de ACG}}{\frac{f_1(1)a_{11}e_1(\text{C})b_1(2)}{f_3(3)}}$$
$$n_{1 \rightarrow 2} = \frac{f_1(1)a_{12}e_2(\text{A})b_2(2) + f_1(2)a_{12}e_2(\text{G})b_2(3)}{f_3(3)} + \frac{f_1(1)a_{12}e_2(\text{C})b_2(2) + f_1(2)a_{12}e_2(\text{G})b_2(3)}{f_3(3)}$$

- da mesma forma, podemos determinar os números esperados de emissão e de transição para o estado 2.

Exemplo do Algoritmo de Baum-Welch

- Determinando as probabilidades para o estado 1:

$$e_1(A) = \frac{n_{1,A}}{n_{1,A} + n_{1,C} + n_{1,G} + n_{1,T}}$$

$$e_1(C) = \frac{n_{1,C}}{n_{1,A} + n_{1,C} + n_{1,G} + n_{1,T}}$$

...

$$a_{11} = \frac{n_{1 \rightarrow 1}}{n_{1 \rightarrow 1} + n_{1 \rightarrow 2}}$$

$$a_{12} = \frac{n_{1 \rightarrow 2}}{n_{1 \rightarrow 1} + n_{1 \rightarrow 2}}$$

Convergência em Baum-Welch

- Alguns critérios de convergência:
 - ★ “likelihood” da sequência de treino não muda muito
 - ★ número máximo de iterações
- habitualmente converge num número pequeno de iterações
- converge para máximo *local* (na likelihood dos dados dado o modelo)

$$\log Pr(\text{sequências}|\theta) = \sum_{x^j} \log Pr(x^j|\theta)$$

Complexidade Computacional dos Algoritmos HMM

- Dado um HMM com S estados e uma sequência de comprimento L , a complexidade dos algoritmos Forward, Backward e de Viterbi é de:

$$O(S^2 L)$$


- Isto assume que os estados são densamente interligados
- Dadas M sequências de comprimento L , a complexidade de Baum-Welch em *cada iteração* é:

$$O(MS^2 L)$$

Uma Aplicação de Aprendizagem com Baum-Welch em HMMs

- Modelando famílias de proteínas usando *profile HMMs*
- *profile HMMs* podem ser usados para:
 - ★ determinar uma sequência múltipla de alinhamento para um conjunto de proteínas
 - ★ detectar novo membros de uma família de proteínas
- Aplicação mais importante de HMMs em BioComputação:
 - ★ HMMER: <http://hmmer.wustl.edu/>
 - ★ [http://www.cse.ucsc.edu/research/compbio/ismb99.tutorial.html](http://www.cse.ucsc.edu/research/compbio/ismb99/tutorial.html)
 - ★ <http://www.people.virginia.edu/~wrp/csh198/>

Um Profile HMM treinado para o Domínio SH3




A Estrutura de um Profile HMM

- *Estados de Emparelhamento:* representam posições essencialmente conservadas na família de sequências
- *Estados de Inserção:* representam subsequências que foram inseridas em alguns membros da família
- *Estados de Remoção:* representam subsequências que foram removidas em alguns membros da família

Alinhamento Múltiplo no Domínio SH3

| | | | | | | | | | | | | | | | | | | | | | |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| G | G | W | W | R | G | d | y | . | g | g | k | k | q | L | W | F | P | S | N | Y | V |
| I | G | W | L | N | G | y | n | e | t | t | g | e | r | G | D | F | P | G | T | Y | V |
| P | N | W | W | E | G | q | l | . | . | n | n | r | r | G | I | F | P | S | N | Y | V |
| D | E | W | W | Q | A | r | r | . | . | d | e | q | i | G | I | V | P | S | K | - | - |
| G | E | W | W | K | A | q | r | . | . | t | g | q | e | G | F | I | P | F | N | F | V |
| G | D | W | W | L | A | r | s | . | . | s | g | q | t | G | Y | I | P | S | N | Y | V |
| G | D | W | W | D | A | e | l | . | . | k | g | r | r | G | K | V | P | D | N | Y | L |
| - | D | W | W | E | A | r | s | l | s | s | g | h | r | G | Y | V | P | S | N | Y | V |
| G | D | W | W | Y | A | r | s | l | i | t | n | s | e | G | Y | I | P | S | T | Y | V |
| G | E | W | W | K | A | r | s | l | a | t | r | k | e | G | Y | I | P | S | N | Y | V |
| G | D | W | W | L | A | r | s | l | v | t | g | r | e | G | Y | V | P | S | N | F | V |
| G | E | W | W | K | A | q | t | . | k | n | g | q | . | G | W | V | P | S | N | Y | I |
| S | D | W | W | R | V | v | n | l | t | t | r | q | e | G | L | I | P | L | N | F | V |
| L | P | W | W | R | A | r | d | . | k | n | g | q | e | G | Y | I | P | S | N | Y | I |
| R | D | W | W | E | F | r | s | k | t | v | y | t | p | G | Y | Y | E | S | G | Y | V |
| E | H | W | W | K | V | k | d | . | q | l | g | n | v | G | Y | I | P | S | N | Y | V |
| I | H | W | W | R | V | q | d | . | r | n | g | h | e | G | Y | V | O | S | S | Y | L |
| K | D | W | W | K | V | e | v | . | . | n | d | r | q | G | F | V | P | A | A | Y | V |
| V | G | W | M | P | G | l | n | e | r | t | r | q | r | G | D | F | P | G | T | Y | V |
| P | D | W | W | E | G | e | l | . | . | n | g | q | r | G | V | F | P | A | S | Y | V |
| E | N | W | W | N | G | e | i | . | . | g | n | r | k | G | I | F | P | A | T | Y | V |
| E | E | W | L | E | G | e | c | . | . | k | g | k | v | G | I | F | P | K | V | F | V |
| G | G | W | W | K | G | d | y | . | g | t | r | i | q | Q | Y | F | P | S | N | Y | V |
| D | G | W | W | R | G | s | y | . | . | n | g | q | v | G | W | F | P | S | N | Y | V |
| Q | G | W | W | R | G | e | i | . | . | y | g | r | v | G | W | F | P | A | N | Y | V |
| G | R | W | W | K | A | r | r | . | a | n | g | e | t | G | I | I | P | S | N | Y | V |
| G | G | W | T | Q | G | e | l | . | k | s | g | q | k | G | W | A | P | T | N | Y | L |
| G | D | W | W | E | A | r | s | n | . | t | g | e | n | G | Y | I | P | S | N | Y | V |
| N | D | W | W | T | G | r | t | . | n | q | k | e | G | I | F | P | A | N | Y | V | |

Como é que os Profile HMMs Representam Famílias de Proteínas




| | | | | | | |
|----|----|----|----|----|----|----|
| a1 | a2 | A3 | - | A4 | . | A5 |
| . | . | B1 | B2 | B3 | b4 | B5 |

Classificando Sequências: Três Métodos

- escolha um limite sobre $Pr(x)$ que permita boa discriminação entre casos positivos e casos negativos:
 - ★ depende do comprimento de x
- construa um *modelo nulo*; rode uma sequência x pelos dois para ver quem obtém um $Pr(x)$ maior
- construa um conjunto de modelos para famílias disjuntas; rode a sequência de interrogação x por todos os modelos para ver quem obtém o maior $Pr(x)$

Acuracia de Profile HMM



- classificando 2447 proteínas em 33 famílias
- o eixo dos x representa a mediana das sequências negativas que têm scores tão altos como uma sequência positiva para um dado modelo de família

Seleção de Modelo para Profile HMMs

- assumimos que recebemos um modelo de comprimento especificado; como determinar o comprimento?
- heurísticas:
 - ★ escolha um comprimento inicial; aprenda parâmetros
 - ★ se mais do que $x - del\%$ dos caminhos de Viterbi, vão por posições de remoção na posição k , remova essa posição do modelo
 - ★ se mais do que $x - ins\%$ vão por inserções na posição k , adicione novas posição ao modelo.
 - ★ itere

Comentários sobre Modelos de Markov

- Tém muitas aplicações bem-sucedidas em biologia computacional
 - ★ reconhecimento de genes e tarefas associadas
 - ★ modelagem de famílias de proteínas
 - ★ modelagem de motivos
 - ★ e mais
- Existem muitas variantes dos modelos que consideramos aqui:
 - ★ modelos de motivos de tamanho fixo
 - ★ modelos de semi-markov
 - ★ gramáticas estocásticas de contexto livre
 - ★ amostragem de Gibbs para aprender parâmetros


Redes Bayesianas: Mais Tutoriais

- <http://www.ai.mit.edu/~murphyk/Bayes/bayes.html>
- Dynamic Bayes Nets com uma aplicação: <http://www.cs.wisc.edu/~dpage/cs731.html>
- Tutoriais de Andrew Moore sobre Statistical Data Mining: <http://www-2.cs.cmu.edu/~awm/tutorials/>
- PRMs e POMDPs: www.stanford.edu/~grenager
- Estatistica Bayesiana: <http://www.stat.cmu.edu/~minka/dynamic.html>


Árvores Filogenéticas

- *Árvore Filogenética*: diagrama mostrando a linha evolucionária de espécies ou de genes
- Porquê usar árvores:
 - ★ para entender a ascendência de várias espécies
 - ★ para compreender como várias funções evoluíram
 - ★ para informar sobre alinhamentos múltiplos


Globin evolution and expression



Exemplo de Filogenia: Babuínos



Exemplo de Filogenia: Ichthyosaurus





Árvores Filogenéticas: Ideias Básicas

- Folhas representam coisas (genes, indivíduos/famílias, espécies) sendo comparadas
 - ★ o termo *taxon* é usado para referir a esses elementos quando representam espécies e classificações mais amplas de organismos
 - ★ vamos chamá-las de sequências
- nós internos são hipotéticos antepassados
- numa árvore enraizada, um caminho desde a raiz até a um nó representa um caminho evolucionário
- uma árvore não-enraizada representa relações entre coisas, mas não caminhos evolucionários

Dados para Construir Árvores

- Árvores podem ser construídas de vários tipos de dados:
 - ★ *baseados em distâncias*: medidas de distâncias entre espécies/genes
 - ★ *baseados em caracteres*: traços morfológicos (eg, pernas), sequências de DNA/proteínas
 - ★ *ordem de genes*: ordem linear de genes ortológicos encontrados em genomas dados

Árvores Enraizadas e Não-Enraizadas



Número de Árvores Possíveis

- dadas n sequências, existem $\prod_{i=3}^n (2i - 5)$ árvores não-enraizadas possíveis
- e $(2n - 3) \prod_{i=3}^n (2i - 5)$ árvores enraizadas

Número de Árvores Possíveis

| # sequências (n) | # árvores não-enraizadas | # árvores enraizadas |
|------------------|-----------------------------|-------------------------|
| 4 | 3 | 15 |
| 5 | 15 | 105 |
| 6 | 105 | 945 |
| 8 | 10,395 | 135,135 |
| 10 | 2,027,025 | 34,459,425 |



Construção de Árvores Filogenéticas

- Três tipos de métodos gerais:
 - ★ *distância*: encontrar uma árvore que explique as distâncias evolucionárias estimadas
 - ★ *parsimónia*: encontrar a árvore que requere o número mínimo de alterações para explicar os dados
 - ★ *maximum likelihood*: encontrar uma árvore que maximize a likelihood dos dados

Métodos Baseados em Distância

- **Dados:** uma matriz $n \times n M$ onde M_{ij} é a distância entre os objectos i e j
- **faça:** construa uma árvore pesada nas arestas tal que a distância entre as folhas i e j corresponda a M_{ij}

| | A | B | C | D | E |
|---|---|---|---|---|---|
| A | 0 | 8 | 8 | 5 | 3 |
| B | | 0 | 3 | 8 | 8 |
| C | | | 0 | 8 | 8 |
| D | | | | 0 | 5 |
| E | | | | | 0 |



O Método UPGMA

- Unweighted Pair Group Method using Arithmetic Averages
- Ideia básica:
 - ★ Iterativamente tirar duas sequências/clusters e agragá-los
 - ★ criar novo nó na árvore para o cluster agregado
- a distância d_{ij} entre os clusters C_i e C_j de sequências é definida como:

$$d_{ij} = \frac{1}{|C_i||C_j|} \sum_{p \in C_i, q \in C_j} d_{pq}$$

ou distância média entre pares de sequências de cada cluster

Algoritmo UPGA

- Dar a cada sequência o seu próprio cluster
- definir uma folha para cada sequência e colocar na altura 0
- enquanto há mais de 2 clusters:
 - ★ determinar dois clusters i, j com o menor d_{ij}
 - ★ defina um novo cluster $C_k = C_i \cup C_j$
 - ★ defina um nó k com filhos i e j , coloque-o na altura $d_{ij}/2$
 - ★ substitua os clusters i e j com k
- junte os últimos dois clusters, i e j , pela raíz na altura $d_{ij}/2$

UPGMA

- dado um novo cluster C_k formado pela agregação de C_i e de C_j
- podemos calcular a distância entre C_k e qualquer outro cluster C_l como segue:


$$d_{kl} = \frac{d_{il}|C_i| + d_{jl}|C_j|}{|C_i| + |C_j|}$$

A Premissa do Relógio Molecular e Dados Ultraméricos

- A *premissa do relógio molecular*: divergência das sequências é assumida ocorrer à mesma velocidade em todos os pontos da árvore
- esta premissa não é verdade em geral: pressões evolucionárias variam de acordo com o tempo, organismos, genes num organismo e regiões num gene
- se não podemos assumir esta premissa, os dados são chamados de *ultramericos*

A Premissa do Relógio Molecular e Dados Ultraméricos

- Dados ultraméricos: para qualquer tripla de sequências i, j, k as distâncias ou são todas iguais, ou duas são iguais e a restante é mais pequena.




Junção de Vizinhos

- com em UPGMA, construimos uma árvore juntando iterativamente sub-árvores
- diferente de UPGMA:
 - ★ não assumimos o relógio molecular
 - ★ produz árvore não enraizada
- assume *aditividade*: a distância entre dois pares de folhas é a soma dos comprimentos dos vértices que fazem a ligação.

Distâncias em Junção de Vizinhos

- dado um novo nó interno k , a distância para outro nó m é dada por:


$$d_{km} = \frac{1}{2}(d_{im} + d_{jm} - d_{ij})$$



Distâncias em Junção de Vizinhos

- Podemos calcular a distância de uma folha para o nó pai na seguinte forma:

$$d_{ik} = \frac{1}{2}(d_{ij} + d_{im} - d_{jm})$$



$$d_{jk} = d_{ij} - d_{ik}$$

Distâncias em Junção de Vizinhos

- Podemos generalizar esta regra de forma a tomar em conta a distância para todas as outras folhas:

$$d_{ik} = \frac{1}{2}(d_{ij} + r_i - r_j)$$

onde


$$r_i = \frac{1}{|L|-2} \sum_{m \in L} d_{im}$$

e L é o conjunto das folhas

- isto é mais robusto se os dados não forem estritamente aditivos

Juntar que Nós?

- Em cada passo escolhemos um par de nós para juntar. Devemos escolher os nós com o menor d_{ij} ?
- Suponhamos que a árvore verdadeira parece como isto e que estamos a escolher os primeiros nós para juntar:



$$d_{AB} = 0.3$$
$$d_{AC} = 0.5$$

- Decisão errada em juntar A e B: precisamos de considerar distância do par até outras folhas.

Juntar que Nós?

- Para evitar o problema escolha o par de nós baseado nas distâncias baseado em D_{ij} :

$$D_{ij} = d_{ij} - (r_i + r_j)$$

$$r_i = \frac{1}{|L|-2} \sum_{k \in L} d_{ik}$$

Algoritmo de Junção de Vizinhos

- defina a árvore T como o conjunto de nós folhas
- $L = T$
- enquanto há mais que duas sub-árvores em T :
 - ★ escolha o par i, j em L com D_{ij} mínimo
 - ★ adicione a T um novo nó agregando i e j
 - ★ determine novas distâncias:

$$d_{ik} = \frac{1}{2}(d_{ij} + r_i - r_j)$$





$$d_{jk} = d_{ij} - dik$$

$$d_{km} = \frac{1}{2}(d_{im} + d_{jm} - d_{ij}) \text{ para todos os outros } m \in L$$

- ★ remova i e j de L e insira k (processe-o como se uma folha)
- junte as duas árvores restantes, i e j com um vértice de comprimento d_{ij}

Testando Aditividade

- Para qualquer conjunto de qualquer folhas i, j, k, l duas das distâncias $d_{ij} + d_{kl}$, $d_{ik} + d_{jl}$ e $d_{il} + d_{jk}$ devem ser iguais e maiores que a terceira distância



Escolhendo Raízes

- Escolher uma raiz para árvores não-enraizadas é muitas vezes feita usando um “out-group”
- *Outgroup* é uma espécie que se sabe ser mais diferentes das outras espécies do que elas são entre elas.
- o ponto onde o outgroup se junta ao resto da árvore é o melhor candidato para a raiz.

Comentários Sobre Métodos Baseados em Distância

- Se os dados de distância são ultraméricos (e as distâncias são distâncias genuínas), então UPGMA encontra a árvore certa
- Se os dados são aditivos (e as distâncias são distâncias genuínas), então junção de vizinhos identifica a árvore correcta
- senão, os métodos podem não recuperar a árvore correcta, mas são boas heurísticas