

## **Organizačné poznámky**

- DÚ1 bude zverejnená zajtra, odovzdávanie do stredy 8.11. 22:00

## **Journal club: skupiny**

- Zoznam skupín na stránke predmetu
- V Moodle skupina pre každý článok + diskusné fórum
- Fórum využite na komunikáciu v rámci skupiny
- Skupina 3 je anglicky hovoriaca

## **Journal club: stretnutie**

- Každý si najprv prečíta článok,  
potom sa koná stretnutie, kde o článku diskutujete, vysvetlíte si navzájom  
nejasnosti, plánujete písanie správy
- Prvé stretnutie skupiny najneskôr 22.11. osobne / online
- Dátum, čas a miesto oznámte aspoň 24 hodín vopred na Moodli
- Po stretnutí napíšte krátku správu zo stretnutia do diskusného fóra  
(kto sa zúčastnil, čo sa dohodlo, či sú nejaké problémy, stačí pári viet)
- Ak treba, dohodnite si s nami konzultácie

## **Správa zo journal clubu**

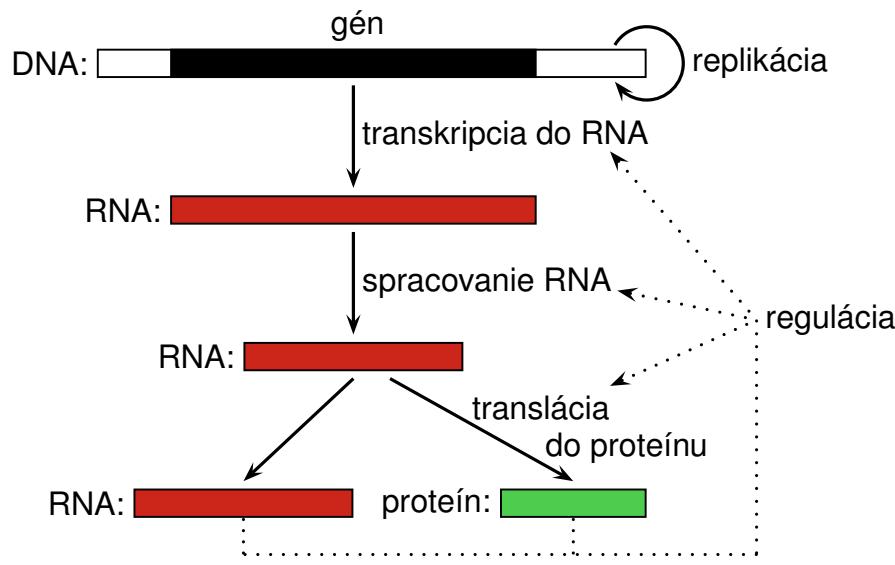
- Vlastnými slovami hlavné metódy a výsledky článku
- Pochopiteľná pre študentov tohto predmetu (inf aj bio), treba teda väčšinou pridať veľa vysvetľovania potrebných pojmov
- Netreba pokryť všetko a naopak, môžete využiť aj iné zdroje
- Skúste vložiť vlastný pohľad na tému
- Rozsah cca 1-2 strany na osobu, jeden ucelený text
- V správe vymenujte členov skupiny, ktorí sa podieľali na jej spísaní, dostanú rovnako bodov

# **Hľadanie génov**

**Broňa Brejová**

**19.10.2023**

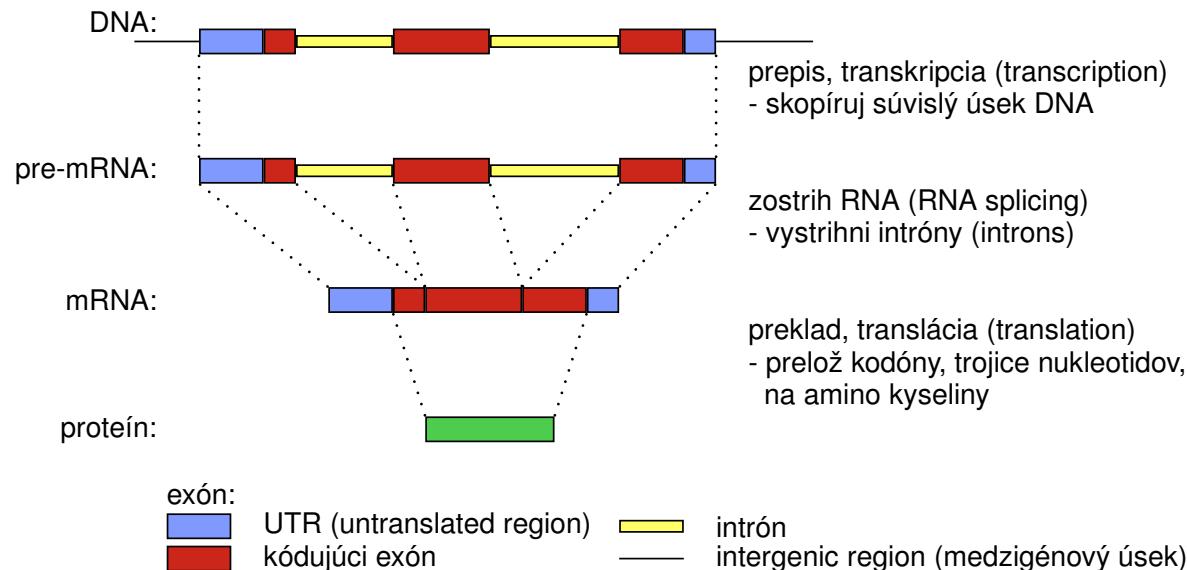
## Čo s osekvenovanými genómami?



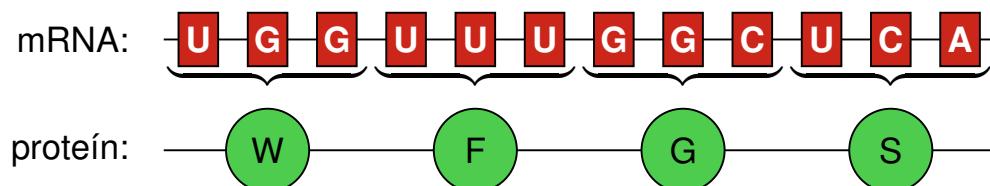
- gény kódujúce proteíny (dnešná prednáška)
- RNA gény
- signály pre reguláciu transkripcie, zostrihu, atď
- pseudogény (nefunkčné kópie génov)
- repetitívne sekvencie, opakovania (sequence repeats)

# Štruktúra eukaryotických génov

## Proces syntézy proteínov:



**Translácia:** tri bázy mRNA (kodón) → aminokyselina proteínu



## Ludský genóm

### Gény kódujúce proteíny

- cca 20 000, pokrývajú 40% genómu
- cca 10 exónov v géne
- exóny pokrývajú 2% genómu
- kódujúce exóny 1.2% genómu

### Repetitívne sekvencie

- pokrývajú 49% genómu

**Príklad:** gén IGF1R zaberá 315 569nt, z toho kóduje 4101nt v 21 exónoch



## Bioinformatický problém: hľadanie génov

**Ciel:** nájsť všetky gény kódujúce proteíny v genóme.

Tým získame katalóg všetkých proteínov.

### Zjednodušenia:

- neuvažujeme alternatívny zostrih, prekrývajúce sa gény
- nehľadáme neprekladané oblasti (UTRs) na začiatku a konci génu

## Bioinformatický problém: hľadanie génov

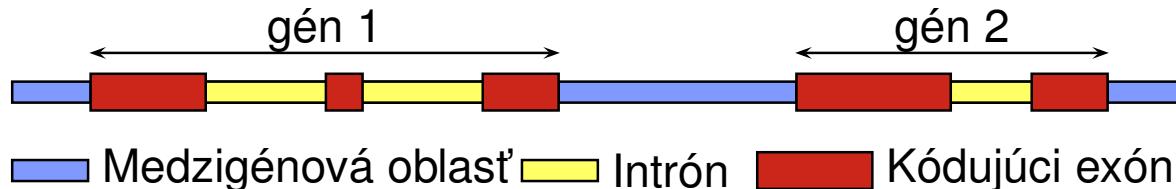
### Vstup: sekvencia DNA

```
cggtgaaactgcacgattttgtggcttaaagatagaccaatcagagtgtgtaacgtca  
tatttagcgttttatcatccaatcactgcactttacacactataaatagagcagctca  
tggcgtagttgcgttagtgtgggtgtccgtgtgtgtttccgtatggctcgca  
ctaagcaaactgctcggaaactctactggtgcaaggcgccacgcaaacagttggccacta  
aggcagccccaaaagcgctccggccaccggcggtgaaaaagccccaccgctaccggc  
cgggcaccgtggctctgcgcgagatccgcgttatcagaagtccactgaactgcttattc  
gttaaactaccccccagcgctgggtgcgcgagattgcgcaggactttaaacagacactgc  
gtttccagagctccgtgtatggctctgcaggaggcggtgcgaggcctacttggtaggc  
tatttgggacactaacctgtgcgccatccacgccaagcgcgactatcatgcccaagg  
acatccagctcgcccgccgatccgcggagagagggcggtgattactgtggtctctgac
```

## Bioinformatický problém: Hľadanie génov

**Ciel:** označ každú bázu ako intrón/exón/medzigénovú oblasť

```
cggtgaaactgcacgattgtgctggctaaagatagaccaatcagagtgtgtaacgtca  
tatttagcgttttatcatccaatcactgcactttacacactataaataagagcagctca  
tgggcgtattgcgttagtgtgggtgtccgctgtgtctgtttccgtcatggctcgca  
ctaagcaaactgctcggaaagtctactggtgcaaggcgccacgcaaacagttggccacta  
aggcagcccgcaaaagcgctccggccaccggcggcgtaaaaagccccaccgctaccggc  
cgggcaccgtggctctgcgcgagatccgcgttatcagaagtccactgaactgcttattc  
gttaaactaccccttcagcgccctgtgcgcgagattgcgcaggactttaaacagacctgc  
gtttccagagctccgtgtatggctctgcaggaggcgtgcgaggcctacttggtagggc  
tatttgaggacactaacctgtgcgccatccacgccaagcgcgtcactatcatgcccagg  
acatccagctcgccgcccgcattccgcggagagagggcgtgattactgtggtctctgac
```



## Bioinformatický problém: hľadanie génov

**Vstup:** sekvencia DNA

**Cieľ:** označ každú bázu ako intrón/exón/medzigénovú oblast' (anotácia)

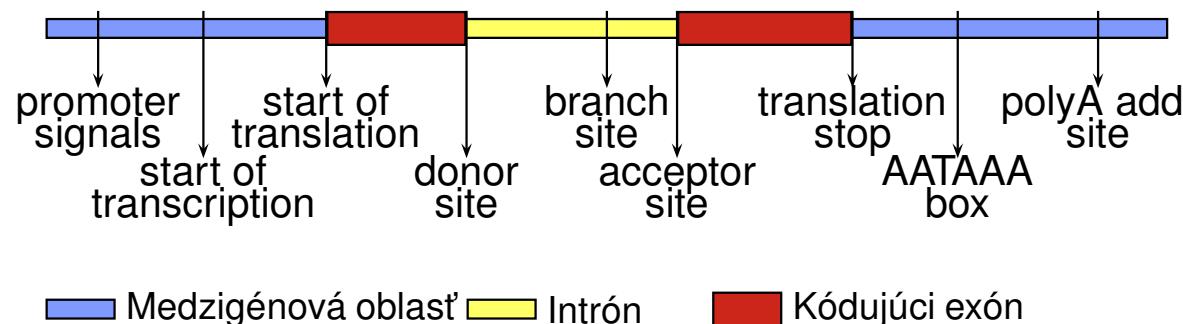
- Toto nie je dobre definovaný problém!

Ako spoznáme, čo je gén?

# Ako spoznáme gény?

## **Signály na hraniciach exónov:**

krátke reťazce, kde sa viažu komplexy zúčastňujúce sa na expresii génu



## Príklad signálu: miesto zostrihu



## Ako spoznáme gény?

### Zloženie sekvencie:

- iná frekvencia  $k$ -tic báz v kódujúcich a nekódujúcich oblastiach,
- kódujúce oblasti sú 3-periodické,
- stop kodóny (TAA, TGA, TAG) len na konci posledného kódujúceho exónu.

**Príklad:** ak uvažujeme len jednotlivé bázy, exóny majú viac C a G (ľudský genóm)

	a	c	g	t	
kódujúci exón	0	0.26	0.26	0.32	0.16
	1	0.30	0.24	0.20	0.26
	2	0.17	0.32	0.31	0.20
intrón		0.26	0.22	0.22	0.30
medzig.		0.27	0.23	0.23	0.27

## Bioinformatický problém: hľadanie génov

**Vstup:** sekvencia DNA

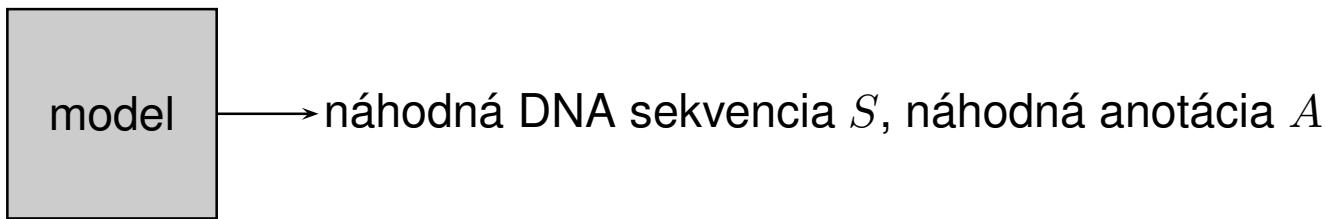
**Cieľ:** označ každú bázu ako intrón/exón/medzigénovú oblasť (anotácia)

- Toto nie je dobre definovaný problém!  
Ako spoznáme, čo je gén?
- Žiadna informácia nám neumožňuje jednoznačne určiť, čo je gén.
- Chceme **skórovací systém**, ktorý povie, ako dobre potenciálna anotácia zodpovedá našim znalostiam.
- Potom hľadáme anotáciu (alebo: segmentáciu pôvodnej sekvencie na neprekryvajúce sa regióny, ktoré reprezentujú intróny, exóny a medzigénové úseky) **s maximálnym skóre**.
- Na definíciu skórovacieho systému použijeme **pravdepodobnostné modely**.

## Pravdepodobnostný model génov

Žiadna informácia nám neumožňuje jednoznačne určiť, čo je gén.

Skombinujeme dostupnú informáciu pravdepodobnostným modelom.

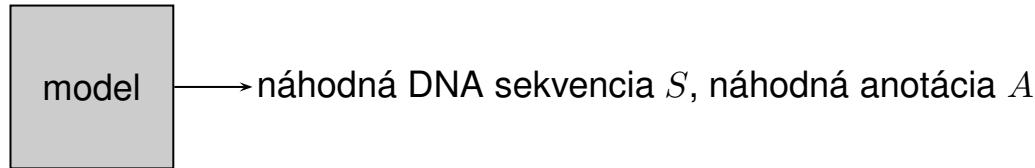


$\Pr(S, A)$  – pravdepodobnosť, že model vygeneruje páár  $(S, A)$ .

Model zostavíme tak, aby páry s vlastnosťami podobnými skutočným génom mali veľkú pravdepodobnosť.

**Použitie:** pre novú sekvenciu  $S$  nájdi najpravdepodobnejšiu anotáciu  
$$A = \arg \max_A \Pr(A|S)$$

## Pravdepodobnostný model génov



**Použitie:** pre sekvenciu  $S$  nájdi najpravdepodobnejšiu anotáciu  $A$

**Hračkársky príklad modelu:** sekvencie dĺžky 2

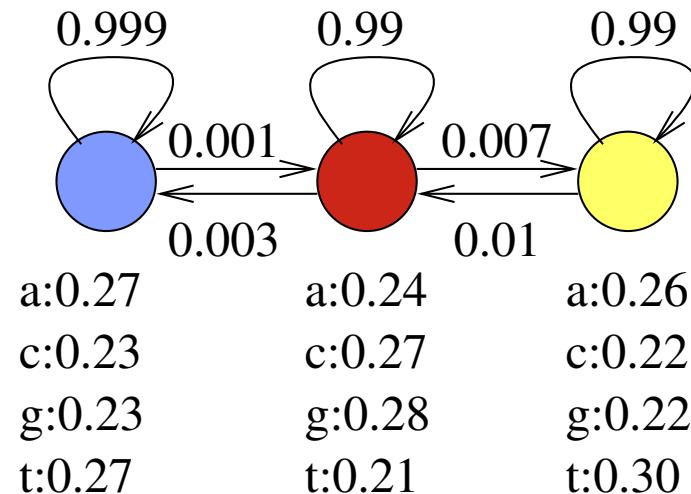
Tabuľka pravdepodobností pre 16 sekvencií, 9 anotácií (súčet 1)

Najpravdepodobnejšia anotácia pre  $S = aa$  je **a**a****.

aa	0.008	ac	0.009	ag	0.0085	...
aa	0	ac	0			...
aa	0.011					...
aa	0					
aa	0.009					
aa	0					
aa	0.007					
aa	0					
aa	0.010					

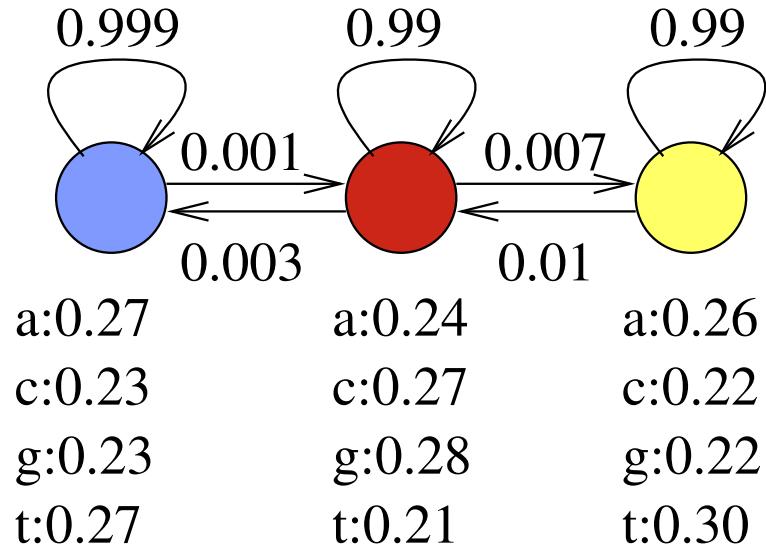
## Skrytý Markovov model, hidden Markov model (HMM)

Spôsob, ako zadefinovať model pre dlhšie sekvencie.



- Konečný automat, stavy napr. exón, intrón, medzigénová oblasť
- Sekvenciu aj anotáciu generuje bázu po báze
- V každom kroku je v jednom stave a náhodne vygeneruje jednu bázu podľa tabuľky v stave
- Potom sa presunie do ďalšieho stavu podľa pravdepodobností na hranách

## Skrytý Markovov model (HMM)



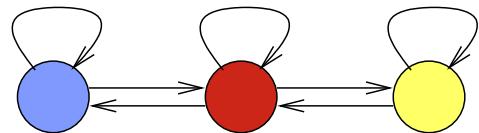
Predpokladajme, že model vždy začína v modrom stave.

**Príklad:**

$$\Pr(\text{aca}) = 0.27 \cdot 0.001 \cdot 0.27 \cdot 0.99 \cdot 0.24 = 0.000017$$

$$\Pr(\text{aca}) = 0.27 \cdot 0.999 \cdot 0.23 \cdot 0.999 \cdot 0.27 = 0.017$$

## Matematické označenie



Sekvencia  $S_1, \dots, S_n$

Anotácia  $A_1, \dots, A_n$

### Parametre modelu:

Prechodová pravdepodobnosť  $a(u, v) = \Pr(A_{i+1} = v | A_i = u)$ ,

Emisná pravdepodobnosť  $e(u, x) = \Pr(S_i = x | A_i = u)$ ,

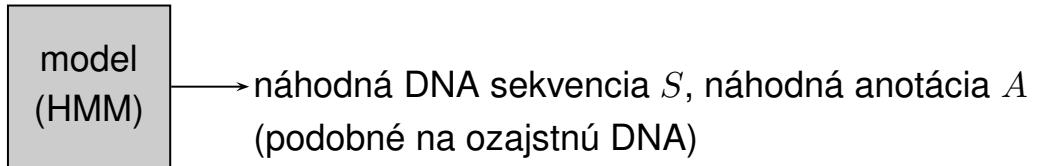
Počiatočná pravdepodobnosť  $\pi(u) = \Pr(A_1 = u)$ .

$a$			
	0.99	0.007	0.003
	0.01	0.99	0
	0.001	0	0.999

$e$	a	c	g	t
	0.24	0.27	0.28	0.21
	0.26	0.22	0.22	0.30
	0.27	0.23	0.23	0.27

**Výsledná pravdepodobnosť:**  $\Pr(A_1, \dots, A_n, S_1, \dots, S_n) = \pi(A_1)e(A_1, S_1) \prod_{i=2}^n a(A_{i-1}, A_i)e(A_i, S_i)$

## Hľadanie génov s HMM

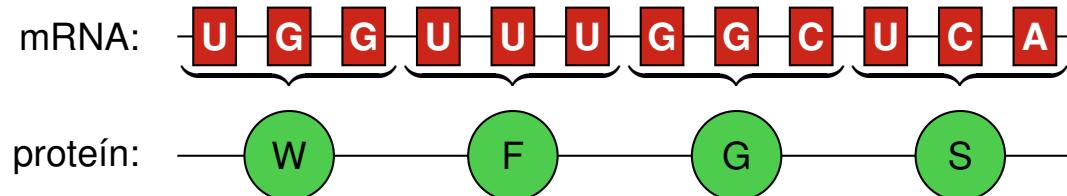


$\Pr(S, A)$  – pravdepodobnosť, že model vygeneruje páár  $(S, A)$ .

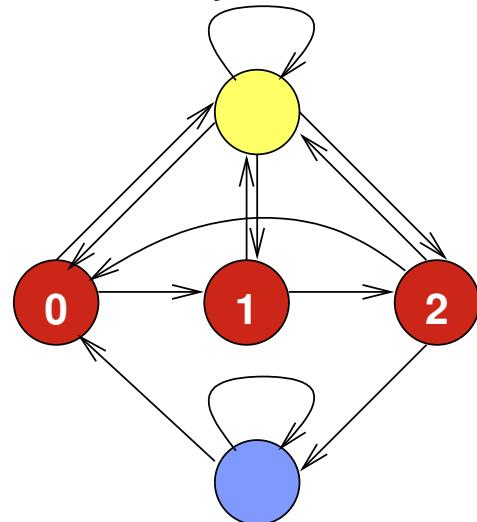
- **Určenie stavov a prechodov v modeli:** ručne, na základe poznatkov o štruktúre génu.
- **Trénovanie parametrov:** emisné a prechodové pravdepodobnosti určíme na základe sekvenčí so známymi génnimi (**trénovacia množina**).
- **Použitie:** pre novú sekvenciu  $S$  nájdi najpravdepodobnejšiu anotáciu
$$A = \arg \max_A \Pr(A|S)$$
Viterbiho algoritmus v čase  $O(nm^2)$  (dynamické programovanie)

## HMM na hľadanie génov: 3-periodické exóny

Kodón (trojica báz) → jedna aminokyselina

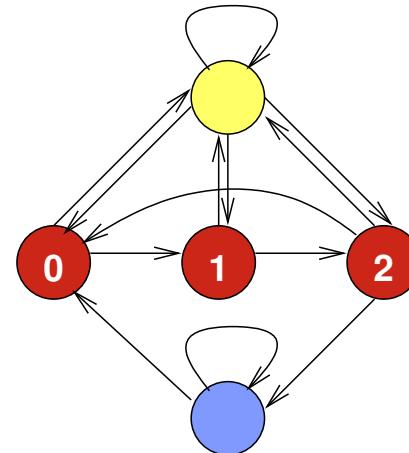
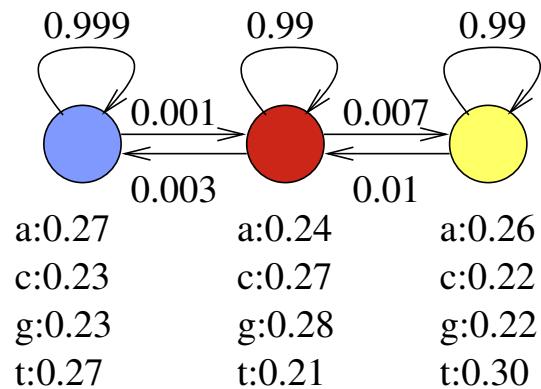


Namiesto jedného stavu pre exón použijeme tri stavy v cykle.



$a$	0	1	2		
0	0	0	0		0
1	0	0			0
2		0	0		
				0	
				Pr( $A_i   A_{i-1}$ )	

## Nové stavy majú odlišné emisné pravdepodobnosti

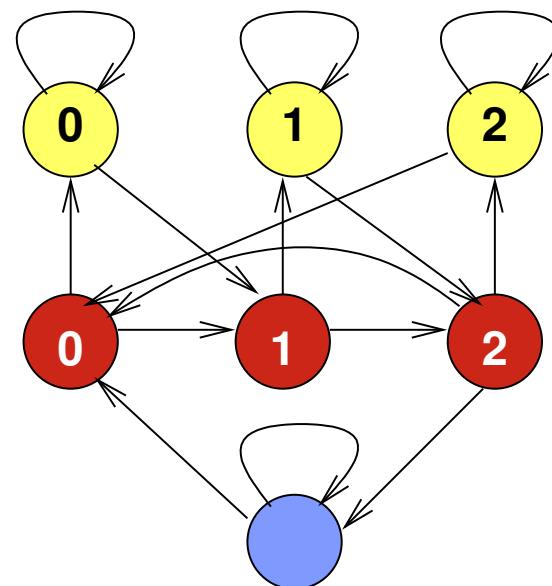
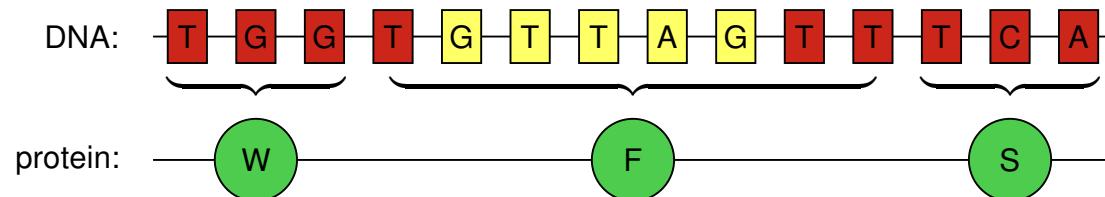


$e$	a	c	g	t
0	0.24	0.27	0.28	0.21
1	0.26	0.22	0.22	0.30
2	0.27	0.23	0.23	0.27

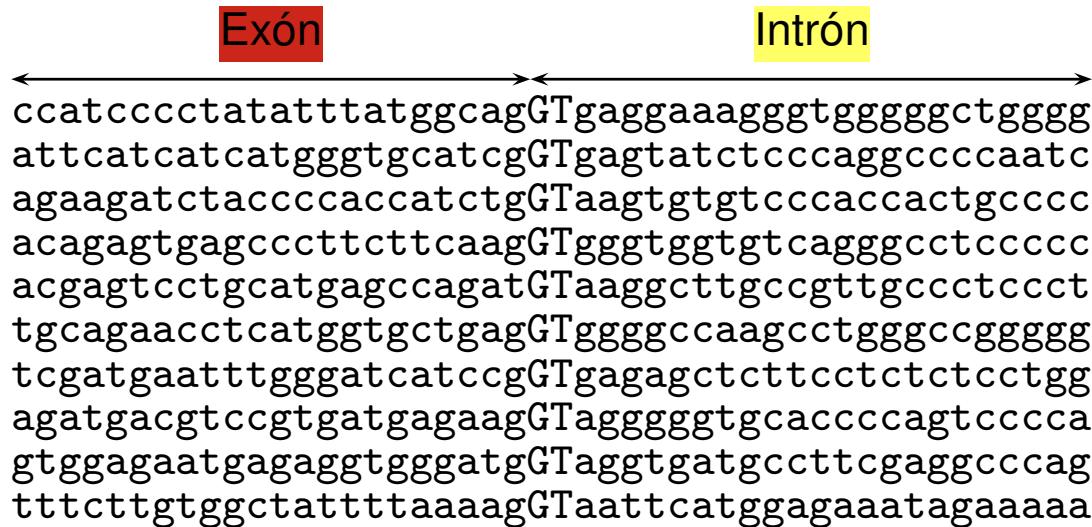
$e$	a	c	g	t
0	0.26	0.26	0.32	0.16
1	0.30	0.24	0.20	0.26
2	0.17	0.32	0.31	0.20
3	0.26	0.22	0.22	0.30
4	0.27	0.23	0.23	0.27

## HMM na hľadanie génov: konzistentné kodóny

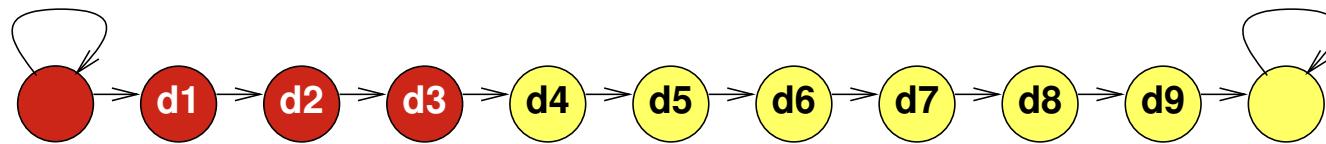
Intrón môže prerušiť kodón uprostred, chceme pokračovať, kde sme prestali.



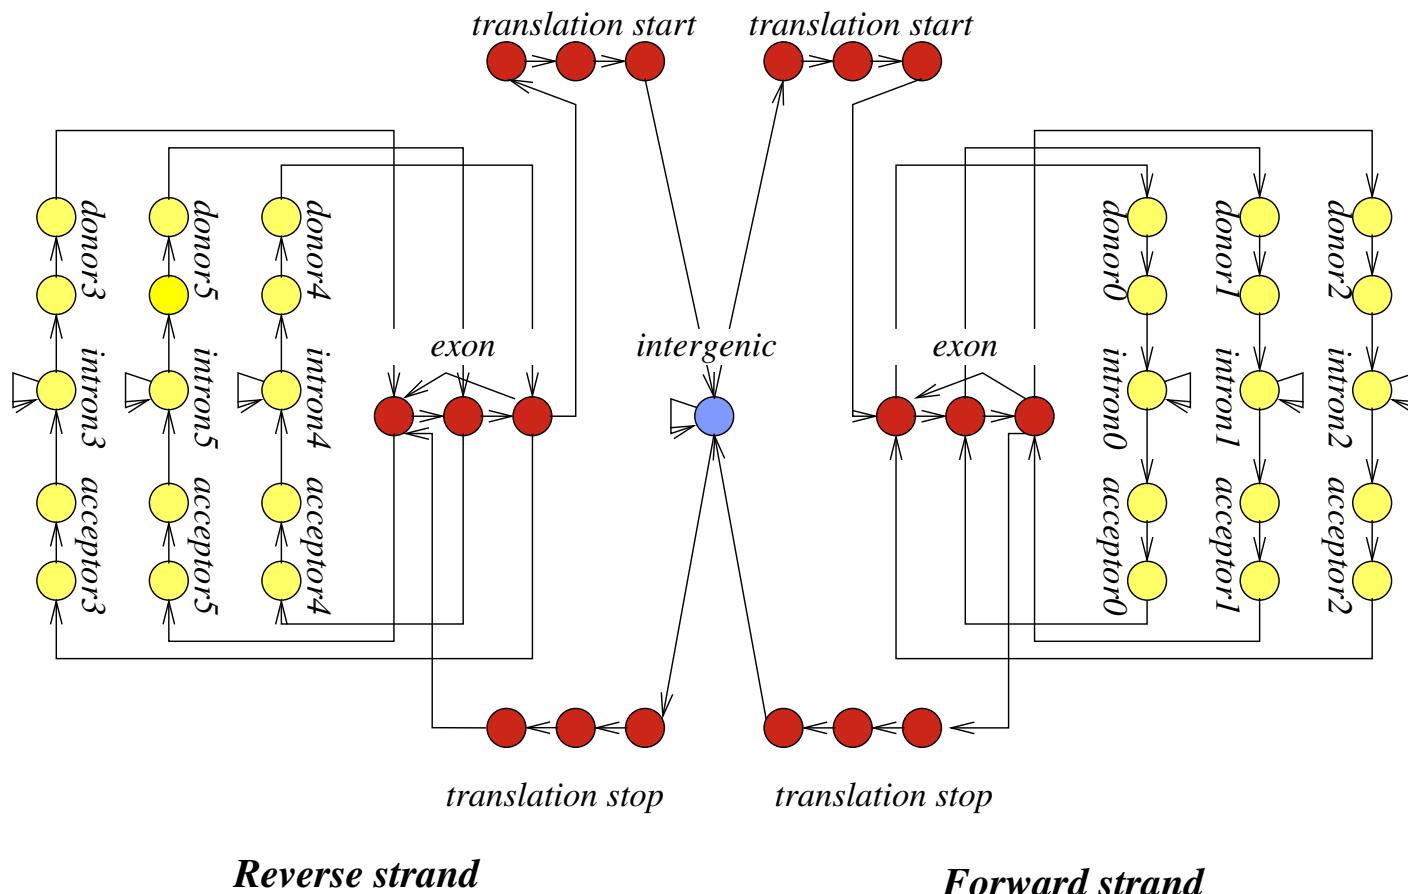
## HMM na hľadanie génov: signály



Pridaj sériu stavov medzi exón a intrón:



## HMM na hľadanie génov: celkový model



## Stavy vyšších rádov

**Rád 0:** emisná tabuľka  $e$  určuje  $\Pr(S_i | A_i)$

**Rád 1:**  $e$  určuje  $\Pr(S_i | A_i, S_{i-1})$

$A_i$	$S_{i-1}$	a	c	g	t
	a	0.24	0.23	0.34	0.19
	c	0.30	0.31	0.13	0.26
█	g	0.27	0.28	0.28	0.17
	t	0.13	0.28	0.38	0.21
	a	0.30	0.18	0.27	0.25
	c	0.32	0.28	0.06	0.35
█	g	0.27	0.22	0.27	0.24
	t	0.20	0.21	0.26	0.33

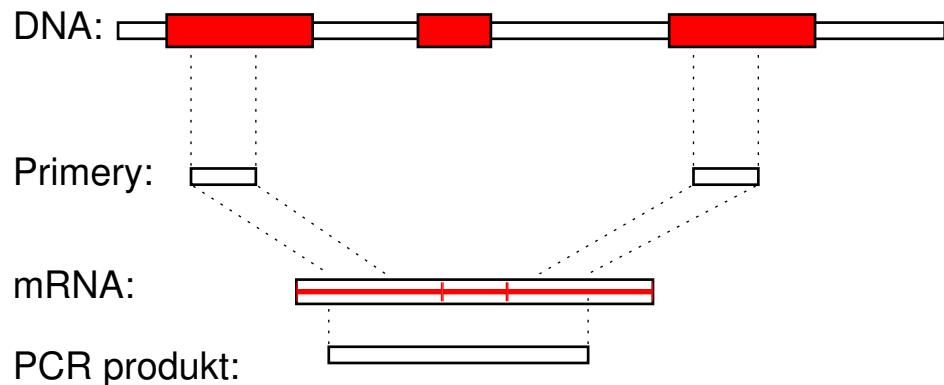
...

Na charakterizovanie exónov, intrónov atď používame rád 4-5.

## Experimentálne overovanie génov

### Overenie transkripcie a zostrihu

- **RNA-Seq:** sekvenovanie častí mRNA extrahovaných z bunky. Nie je cielené na konkrétny gén.
- **RT PCR:** cielene over konkrétny predpovedaný gén pomocou špecifických primerov.



**Problémy:** Ťažko nájsť gény s expresiou iba za zvláštnych podmienok (napr. v embryu), kontaminácia genómovou DNA, nejednoznačné namapovanie na genóm.

## **Experimentálne overovanie génov**

### **Overenie translácie, prítomnosti proteínu**

- Hmotnostná spektrometria (mass spectrometry) dokáže detegovať prítomnosť proteínu izolovaného napr. z 2D gélu.
- Metódy založené na protilátkach (antibody), prípadne špecifické techniky podľa typu proteínu.

## **Príklady programov na hľadanie génov**

### **Len na základe sekvencie DNA:**

HMMGene [Krogh 1997] (autor je priekopníkom HMM v bioinf.),  
Genscan [Burge a Karlin 1997] (po mnohé roky štandard),  
GeneZilla [Majoros a kol. 2004], ExonHunter [Brejová a kol. 2005], Augustus  
[Stanke a Waack 2003] (novšie programy založené na zovšeobecnených HMM).  
CONTRAST [Gross 2007], CONRAD [DeCaprio 2007] (programy založené na  
conditional random fields, obmena HMM)

### **Prokaryotické genómy:**

GeneMark [Lukashin a Borodovsky 1998], Glimmer [Delcher a kol. 1999] a ďalšie.

## Vybrané programy na hľadanie génov

### Porovnávaním viacerých sekvencií:

Twinscan [Korf a kol. 2001]

(prvý úspešný gene finder s dvoma genómami),

Exoniphy [Siepel a Haussler 2004]

(viacero genómov, nehľadá celé gény),

N-SCAN [Gross a Brent 2006]

(rozšírenie Twinscanu na viacero genómov).

**Iná informácia:** (napr. RNA-seq, príbuzné proteíny a pod.)

ExonHunter [Brejová a kol. 2005], Augustus [Stanke a kol. 2006],

Jigsaw [Allen a Salzberg 2005], Fgenesh++ [Solovyev 2006].

Augustus patrí dodnes medzi často používané programy.

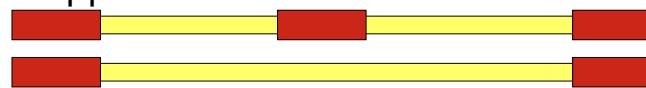
## Obmedzenia hľadačov génov

- Alternatívny zostrih (alternative splicing): jeden gén môže vyprodukovať viacero mRNA molekúl. Programy väčšinou hľadajú iba jednu.

Retained intron:



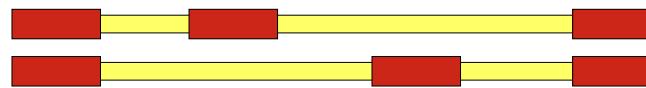
Skipped exon:



Alternative donor or acceptor:



Mutually exclusive exons:



- Pretínajúce sa gény, resp. gény v intrónoch.
- Netypické gény (neobvyklé signály, veľmi krátke alebo dlhé exóny alebo intróny atď.).
- Hľadanie UTR a začiatku/konca transkripcie.

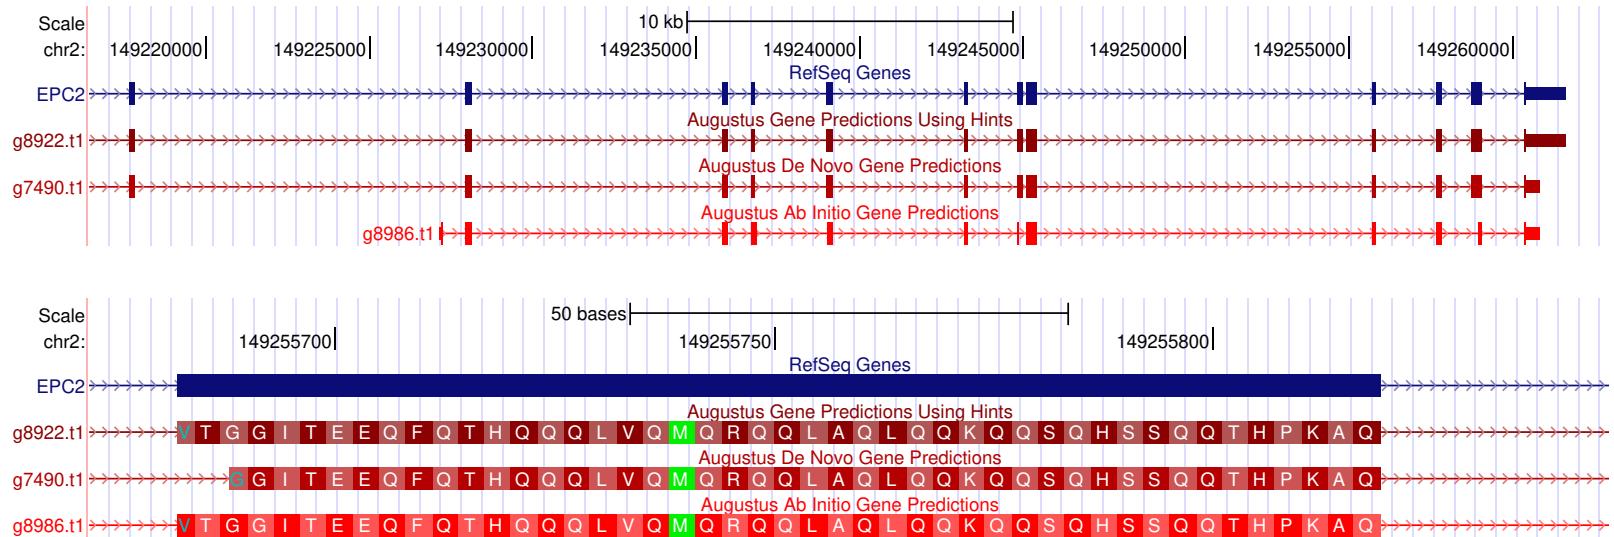
## Hľadače génov robia často chyby

Najlepšie metódy v 2005 na ľudskom genóme: [Guigo et al 2006]

20% génov, 60% exónov správne iba na základe DNA

35% génov, 65% exónov správne komparatívne

70% génov, 85% exónov správne s ďalšou informáciou



## Koľko génov má človek?

**Do 2001:** Rôzne odhady: **50 000–140 000** génov

**2001:** predbežná verzia ľudského genómu: **30 000–40 000** génov

**2004:** sekvencia ľudského genómu: **20 000–25 000** génov

**2007:** v katalógoch Ensembl, RefSeq a VEGA spolu **24 500** génov

[Clamp a kol. 2007] tvrdia, že iba **20 500** z nich je správnych

Ale sú gény, o ktorých ešte nevieme?

**2010:** RefSeq má **22 333** génov

Stále neistota  $\pm 1000$  [Pertea, Salzberg 2010]

Rôzni ľudia sa môžu lísiť v desiatkach génov

**2012:** Projekt ENCODE odhaduje **20 687** génov kódujúcich proteíny,  
v priemere 6 alternatívnych transkriptov na gén,  
plus 8 800 krátkych a 9 600 dlhých RNA génov

## Zhrnutie

- Novo osekvenované genómy treba anotovať:  
určovať funkcie jednotlivým oblastiam sekvencie
- Príkladom anotácie je hľadanie génov kódujúcich proteíny
- Na hľadanie génov sa hodia skryté Markovove modely
- Modely robia veľa chýb, ale dajú nám základnú predstavu o polohe a počte  
génov, môžeme študovať ich funkciu