

BIOINFORMATIKA V PRAXI

CVIČENÍ 3 – DRUHÁ ČÁST

IDENTIFIKACE GENŮ, PROTEINŮ A JEJICH FUNKCE

STUDIJNÍ MATERIÁLY

Studijní materiály předmětu C2130 Úvod do chemoinformatiky a bioinformatiky, přednáška **Predikce genu, Sequence-evolution-function: Computational Approaches in Comparative Genomics**.

CHYBY PŘI PREDIKCI GENŮ

Velmi zjednodušený přístup k predikci prokaryotických genů (genem je nejdelší ORF) vede k chybám, ale jejich množství je poměrně malé. Chyby mohou také vznikat při sekvencování DNA. Přidání/odstranění startovního a/nebo stop kodonu může vést ke zkrácení, prodloužení nebo úplnému vynechání genu.

ÚKOL 1 – příklady chyb vzniklých při sekvenaci

Pomocí predikčního programu **GeneMark** (<http://exon.gatech.edu/GeneMark>) identifikujte geny v sekvenačních výstupech a porovnejte je s původní sekvencí z databáze (část genomu *E. coli*). Určete, k jaké chybě došlo. Pro porovnání rozdílně predikovaných genů využijte program EMBOSS Needle (http://www.ebi.ac.uk/Tools/psa/emboss_needle/nucleotide.html).

SEKVENCE *E. COLI*

```
TTAAGAAATTCGGTATCAACTTCGAGGCCCTTTCAGGTCACCGTTGGCGTATTTTCGGGGCGATAGATTTGTATTTGTAGCCGCAACTG
CGATCGCCCCCGGCGAAAAACGCAGATCCGGCGGTACTTTGTGAAATCACCGTTTCAATCCAGCCAGCGTGCCGCGTGAACGAAACGAT
GGCGATCGTACAGTGTGCGGATCCAGACGTTTTCGCGCTGGAACCGGAGAAATCGACATCTGAGCCCCAGGCGGTGGAGTAGTCGATAGA
GTAGCGTTGCGAGTCGCCCTGGTTGGCATCAGGCCACCACGAGAACCGGTGCGGCTAATCATACCCCAGGATAAAACAGCATCGTGGTGTG
GTAATTTACCCCTGAGTAAAGTGGTCGAGACTCCAGCGCAGGTTAATGGCAGCGTGCCAGCCGCTGGAGAGATCCAGTAGCGAGAAGCCACCA
CGGTAGTGGAGTCAGATTCGGTATCGTTTCAGGTCAGTGCCTTAAACCCGCCCTGCACCAAATAATATTGTTCCAGTGGATTCTTCAGCAGCGG
CATTTTTATAGCTGAAGTCGAGGGTCTGTTCCGGCGCGAAATACTGGTACTGGTGGTCAGACTGTGACCATAAGAGTTTCCACGGCTTTTTT
CAGTAGCTTTACGCGCGGTCCACGTCGGTAGAGTAACCGACCCCGGTTTCGATGGTGTTCAGTTCGCGCGGAAACCACGCCCGTCAAGG
GTAATACTTTTCGTTTCGCGCGCTTTATCAAATTTGGAGCCACTACGACCGAGTTAAACCAGCCGGTAGCAGAAAGTCGACGGTTAAGTTCCGC
CAGATCTTTCGATTCGATCATCGCCCTTTTAAACGGCACCAGATTTGACAGTATTTCATCGCGGATTTGTGATCCTTCAAAGGTCACATGC
CCAAAGCGGTAACGTTCCGCACTGTTATAATCAATATCCAGAAGGCTTTATGCAGGCCGAGCGCAATGCCAGCTGCGCTTTGGTAAATTCGC
TATCGAAATAACCTTTAGCAACGCAATGCTGGTTAAGGACTTTTTGAAATTTTCATAATCGCCCTGGTTCAGTACCGTGCCAATAGCCGGGCG
AGTATCGAGCAATTTCAAATAGTCTTTATCGGTCGCGCGCGCCGCGCAATACCACATCGGTGCCGCCAATTAACACCGGCACGCCCTGGCGTG
ACTTTGGCGGATCAATACCTGCCGCCCTTTCTTTGGCGGTGGACGGAGATCAAATTCATGGTCGGTGGTAATAACCCAGCGCTTCAGACCTT
CGCGGATGGCATCATCGACGCTGCGCGAAAGCGACGGTCTGGCGTCACTTTCATCACTTTCAATCGTAGAAAGTGCAGCAGAACGTTCTTTTC
CAGCTGTCCCATAACCCCTCGACTGTAGACGGACGTTTCGCGCGGACGGCAGATCCGTTAAGCAGAGTAAGCTTACACAGCATAACTGTCCG
ATATAGCGCATATTTCTCCTGAATATCCTTTTTCTCCTGCCCTTGAACCGGTTAAACAAATCCAGTAATATGGATTAATAAAG
CAGACTAAACCCAAATATTTCTATGTTTTACTTTAGACCTATTCACGGTGGTATTGTTGTGCAAATACGCCCTTGTGTACAACCTTAACCCC
AATGACCGAATTTTCGGGAGAGCGACACCATGAGTTTATTTGATAAAAAGCATCTGGTTTTCCCGCCGATGCCCTGGCAGTAAACACCCCG
ATGCCCGTAGCCAGCTGCATGCGGTCAACGGTCACTCAATGACCAATGTACCTGACGGAATGGAGATTGCCATTTTGGGATGGGTTGTTTCT
GGGGTGTGGAGCGTCTGTTCTGGCAGTTACCCGCGCTTTACAGCACCGCCGACGGCTATACCGCGGCTATACGCCAAATCCGACTTATCGGGA
AGTGTGCTCCGGTATGATCGGTCATGCCGAAGCGGTACGCATTGTTTACGATCCTTCTGTATCAGTATGAGCAGTATGATCAGGATTTTTGG
GAGAATACAGATCCCGCCAGGGAATGCGTCAGGGCAATGACCGCAATGACCGCATCGATTCGTTACGCGATTATCCGCTGACCCGAAACAGGATG
CCGCGACTCGCGCAGTCTGAAACGTTTTCAGGCGCGATGCTTCCGCCGATGACGATCGTCACATCACCCGAAATCGTAAACGCCACACC
GTTTTATATGCGGAAGATGACCACCAGCAATATCTGCATAAAAACCCGATATGGTTACTGTGGAATTGGCGGAATTGGCGTCTGTGCCACCG
GAAGCATAGCGTTACGGGTACAAATGTAGATTGTTGATAAAGTGCCTTTGTTTATGCCGAATGCAGCGTGAATGCCTTACCAGCCCTACAAA
TCGTCCAATATCAATATATGCGAGGACTGCGTAGGCCCTGATCGGCATACGGCATAGGCAATTTGCAATTTATCGAGTATGCAATTTAAC
CTCTGGCGACTTTACAGTACCTTACGCTATAC TAGCCACTGAAAATGCCGGATCACTTTCTTCGAATCGGCTTTCAATGTGATTTACACAAA
TTAATCAACTTCCCTTCCGAGGATCTGGCCTGAAAGTTCGGATAAGATATGTTAAACAGTATTTTAGTCATACTCTGCTTGATCGCTGTAAGT
CGCTTCTTCGATGCTGAGATCTCACTTGCCTCCTCAGCAAAATCAAATTAACCTGCTGGCTGATGAAGCAATATAAATGCCCAACCGG
TTCGAAATATGCAAGAAAATCCCGCATGTTCTTACGGTGGTCCAAATCGGTCGATGAAACGAGTTCGATTTCCGCGGATTCGTCGGTATGC
GGCATTCTCCAGCTTTTACAGCCTGTTCTCCGCTATATGTCGGCAGAACCTCTGAGCAACTGAGCTTTATCTCTCTTTCTCGTTAGTG
ACTGGCATGTTTATCCTGTTTGGGATTTAACCCGAAACGCATCGGTATGATTGCGCCAGAAGCGGTGGCTTTGCGTATCATCAACCCGATGC
GCTTTCGCTGTACGTTGCAACCCCGCTGGTGTGGTCTTCAACGGCTGGCGAACATGATCTCCGATTTTCAAACCTGCCAATGGTACGTAA
AGATGACATCACTCTGATGACATCTACCGGATAGTGAAGCCGCTGCGCTGAGCGGCTGTTACGTAACAGGAACACGAGATGATGAAAC
GTCTTTGAGCTGGAATCCCGTACCGTCCGCTTCAATGACACCGCTGAAAACGTGATTTGGTTTGTATCTCCACGAGATGAGCAAAGCCTGA
AGAATAAGGTGGCGGAACATCCGCACTTAAGTTCCCTCGTCTGTAATGAAGATATTGACCACATCATCGGTTATGTGATTTCAAAGACCTGCT
```


GGCGCGCCTGTTCCACGATGATTATCGGCACCCTGCCGGTGGTCATTCTGTCTTTGCCAATCTGCTTTATAGCCAGCGACGGCAAACCTCG
CGTGGGGAAAACCTCGCCCGGCACTGATTTGTATTGGCATCGGCTGGCGAGTGTGAATATTGCTGAGTTAAACCACGGACTCCCCGATTTTTGA
CTGGGCACGTTTACTCTGGCATCGTGTACGGTTAGTTTCCGTGGTCTGCTGGCATGGTATGCCCCTGGCCACGCCCCTGGCTGCGGGAA
AATCCCGACAAACATCCGATGATGTGGGCGACGGCGCAGGCGCTGGTCACGCTGCCGGTTTCTCTCATCGGCTATCTCGTCGCCCTGTACTGGC
TGAATATACAAACGCGCGACTTCTCCTTACCTTTTGGCCCCCGTCCGCTGGTGTATTATTAGTCTGATGGTTGCGATAGCCGTGCTTTGCTCATG
GGTTGGCGCACTCTGCTGGAACGTCGCCAGCCAGCGATTACCGACAGTATTCTCGGGCCGCTGATTGTTTTCGAAACGCTGGCAGGTTTGTCTG
TACACCTTTTTACTCCGCCAGCAAATGCCCGCGCTAATGACGCTGAGCGGTATCGCGCTGTAGTGATTGGCGTGGTCATTGCGGTCAGAGCAA
AACCAGAAAAACCTTTAACTGAATCTGTCTCAGAAAGTTGACACGCTGGCAGTGGTAAATAAGCCTCTGCTACGTAAGGGTTATAGCTTTTG
CCTTAAAGATGCATTTAAATACATCTTATCTTATTAAGAATGAGGTATCAGCTATGGCTTATCGCGACCAACCTTTAGTGAACTGGCGCTCT
CTATCCCTCGCGCTTCGGCTCTGTTTCGTAAATATGATATGGATTACTGCTGTGGCGGTAAGCAGACGCTGGCGCGCGGGCGGCACGTAAGA
ACTGGATGTTGAGGTCATTGAAGCTGAACTGGCAAAGCTTGTGAACAACCGATTGAGAAAGACTGGCGTAGCAGCCCGCTGGCAGAAATCATT
GACCATATCATCTGCGCTAC

PREDIKCE GENŮ U EUKARYOT

Genomy **jednobuněčných** eukaryot se navzájem výrazně liší (frekvence intronů, jak velká část genomu je tvořena geny kódujícími proteiny). Pro některá jednobuněčná eukaryota (s nízkou frekvencí intronů) je možné použít stejné postupy jako pro prokaryota.

ÚKOL 2

Charakterizujte část genomu *Candida albicans* (kvasinka) pomocí programu **GeneMark** (<http://exon.gatech.edu/GeneMark>), verze pro nižší eukaryota. U identifikovaných genů určete možnou funkci.

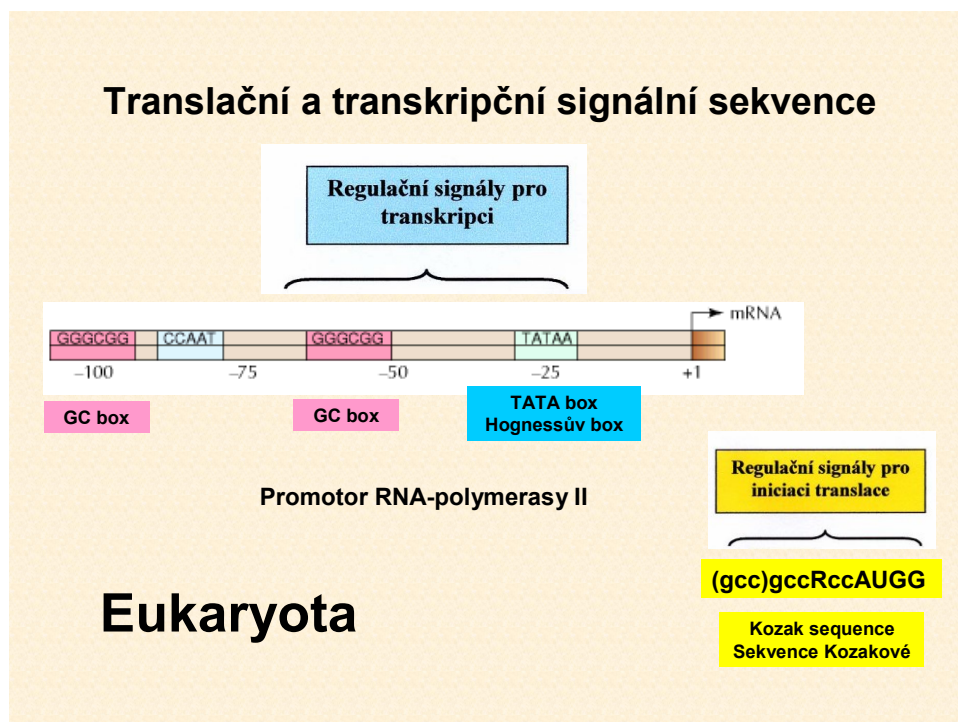
TCAATGCTTTGTGATTAATCTTCGGACATATGCAATTTTGAATATTAATATTGTTTCATATCAACATCACGAGCTTGGAACTGAATATTGAGT
AATCACGATATTGCACCGACTCAACCTTGATTTAAATCTGCTAGTGTACTAATTTGTGACCTTTCTATTAGATCATTATCTTTCTTAAATGTGT
TGAAATCACGAGAAATTTAAATACTACTAAGCCTGTATATTCAACACAGAAATACATCATAGATGTTTTTTTTTCTTATTATTGTGTGCAAT
TAACTGTCTCCCTCTCCTTTGAACAATCAATTAGTACTTTACAACCTCACAATTTGTAACCCCTGTCCGGATACACATTTTATTTCAAATTACC
GTGAGTGCATGTAATAATCAACTGCTGTCGTTTCATTTCAAGGTCAACGCAATAGTCTAATAAGTATGTCGTTTCGAGAAGCTTACTGTCAA
TCTCTCGTGTAAAGAAGTATTTTTTTTTTGGTCCAGTTTTCGAACAAATATACTTTAAATCTCATAGAATGTTTATTTTCAATTTACTACAGA
CCTTACAAAATCCTAACCAGACTAGATGCTATCTATGGAGCATCAGTACATTTCCCAATCTGTTGGTTTATAAGCATCAGGTTGATCAATAGCC
TTAATTTCTTCAATAGTCAATTTCAAATCATCAACAGAAAGATTTCCCTTAAATCGAGATGGAGTTTTTGTTTTTTGGTAAATGGTATATAACCTT
TTTGAATGAAACAAATTTAATCAATTTTGAAGCACTGATTTATATACTTTGGTGGATAAATTTCTTGAATTCAGTATGTTGGGTAATTTGTT
ACCATGGGTTAATGGTGCATATGCCTCAACATTTGATACCTTTACTTAAACACCAAGTAGTAAATCCTGTCTCATACACCAAGGACTAATTTCA
ATTTGATTGACAGCTGGAGGGATCGTTGCATTTGGTCAACAATTTCTCAATATGATGTTTACCATAATTAGAAACCCCAATGTTTTTAAATCCATC
CTTTTTCCACAGCATCCGCAAACTTTCCAGCTTTCTAAACGTTTGGTCTTACCTGGTAAATGGAGAATGAATCAATAATAAATCAATATATTT
TAATTTACCCCAATTTAGGCTAAGCTTGTGAAGTGGTGTGTTTACTGTTGAGCAATTTGATTTTCCAAAGCTAATTTGCTGCTGAAAGAAA
AACTCAGATCGTGGTATATTGGGGTCTCTCGTAAGAATTTACTTATACTTCAATGACTTCTTCTCGTTTCCATATAACACTCGAGTATCAA
AATGACGATATCCAATTTACAAGCTTATAAACTACCGAAACCGTTTTATTTCTGGGATATCATAACATCCTAATCCAATTTGATGAAATGGT
ATGACCGAATTTGAGTTGATTAATCGATATGACATTTTTCTTAAAGCAAAATTTAGCAATTTGAGTGAATATAAAGAGTATTTGAAATCTAGAG
AATTTGATAGTGTCCATGAAAAATACAAAGAGAGCCGTTGAATTTAACAATAATTTACTGTTGCAATTTTGGCTGGCAATTTCTTAAACCCCTAAT
AAAGCAATCTTTGTACAGTCTCAAACCTTCTTCTATTATCGTTCTTCTGTTAAAATCTGCACATTTGCATTTGCCAATTTTGTATTATATA
TCATTTCTGTTACAATGAATTTGACAGACGAGTATTTGGTTATAGTATTTGGACTATTTGGTCTTGTAGATCACCATTTACACTTATAATCAAAAT
TTCTCTGGAATTAAGATCAACTTTGAAACAATACAGACGATTTCCAGCCTGTTATTTCCCGGGATTGGATCTTTTTGGTTGCGTTAGTCCGAGGA
TATATGACGCTGAATTTGATGTTAAGCACTGTTGAGTGTACTGTTGAGCAATTTGATTTGAGCAATTTGATTTGAGCAATTTGATTTGAGCAAT
TGAGAAAAATAATAGATACTGTAGTGGTAGTAGTGGTATGATGCAAAATTTATTTGTTGATTTTTTTTTTTTGGTGTCTCTCGTCGACAACG
ACTGCTGATTTACACCACCACCCTTTGTAGTCAAAATTTAAATTCGTCGGTGGCAAAAAAACACAGACACACATACAGACAATTTGGGATA
TTTTATTTTAGGTTCAATTTGGAACGTCACCATACAGTATTTCAATGATTAATTTGACTTGCAAAATACAAATCGCGTGGTTCATTTCCGAAA
AATTTGATAGTGTCCATGAAAAATACAAAGAGAGCCGTTGAATTTAACAATAATTTACTGTTGCAATTTTGGCTGGCAATTTCTTAAACCCCTAAT
TTTTTTTCAATGCAATTTATTTTACGTAGAAGCTTATTTCTTAAACACTCGGTTATCCGAATATAATTTGCTTTTCAGAGCAATTTGACTGATAT
AATACCATCAATTTGAATAAATCAGTATCATCAATGCTAGTTTGGTTCATATAAAGGTATAATTCGGTGTAACTGAAAGGTATTGCTCAATTA
ATTAGGTTGGCGTTTTTGGATCAGCTGTTTCAATCCAGGCTCGTGGTGCACATTTTTTATTTTTTGTGTTGATTTTTTTCTTTTCTTTGCTT
AATAGTTAGTTAGTAAAATGGATAATGACGCAAAATTTGCTTCAATGGATGATAATGCCCGGGTATGGCGTGCCTGACAAATCATATTTAT
GCAAAAATAGCCAAAATAGCAAAAATAGTGGAAATTTGTTCAACCAACCCACTCAACCACTAAAATTTGCTTGTCAAAGCCAAATTTCAACG
AAAATTTGATTTTTTTTTGACTTAAATATATATAACCTTTGAAATTTCCCTTCAATTTGAAAAATTTTTTTAATTTATTTATTTCTTCTTTT
TTCTTTTTTCTTTTTCTTTTATTTATCATCACAATTTGAATTTCAATCAATTAACATCAACAACTTTACAATCAAATTAATAACAAATGGCTAT
TAAAATTTGGTATTTAACGGTTTTCCGGTAGAATCGGTAGATTAGTCTTAAAGATTGCTTTGGCGAGAAAAGACATTTGAAGTTGTCGCCGCTCAACGAT
CCATTCATTTGCTCCAGACTATGCTGCTTACATGTTCAAAATACGATTCTACTCACGGTAGATACAAGGGTGAAGTCACTGCTTCTGGTGCAGACT
TGGTCATTTGATGGTCACAAGATTTAAAGTTTTCCAAGAAAGAGACCCAGCTAACATTTCCATGGGGTAAATCTGGTGTGACTACGTTATTGAATC
CACCGGTGTTTTCAACAACTCGAAGGTGCTCAAAAACACATTTGATGCTGGTGCCAAAAAGGTTATCATCACTGCTCCATCTGCTGATGCCCCA
ATGTTTTGTTGTCGGTGTAAACGAGTAAACACAACTACACTCAGACTGAAAGATTATCTCAATGCTTTGTTGACCACCACTGTTGCTGCTCCACTTAG
CTAAAGTCGTCAACGATACTTTCCGGTATTGAAGAAGGTTTGTGACCACTGTCCACTCCATCACTGCTACCCAAAAGACCGTTGACGGTCCATC
CCACAAGGACTGGAGAGTGGTGAAGTCTTCTGGTAAACATTTCCCATCTTCCACTGGTGTGCTTAAAGCCGTTGGTAAGGTTATTTCCAGAA
TTGAACCGTAAATTTGACTGGTATGCTTTGAGAGTCCCAACCCAGGATTTCCGTTGTTGACTTGTGACTGTGAGTGAAGAAAGCTGCTTTCT
ACGAAAGAAATTTGCTCAAGTCTCAAGAAAGCTTCTGAAGTCCATTTGAAGGTTGTTTTGGGCTACACTGAAGATGCTGTTGCTGCTCCAGCAAT
CTTGGGTTCAAGCTACTCATCTATCTTTGATGAAAAAGCCGGTATCTTGTGTCGCCAACTTTCTGTCAAAATTTGATTTCTTGGTACGATAACGAA
TAGCGTTACTCCACAGAGTTGTTGACTTGTGGAACAGGTTGCTAAAGCTTTCTGCTTGAAGTAAAACAGACTTTGATTTGATTTTTTTAGTT
AATGAAGTTATATAATGATTTTTTGAATAAATATCTTACATTTGAAGAGAATATTGATGTTGTTTTTTTTTGGTTTTTATATAGGTTGTTGACG
TTATAAGTAAGACCAATATACATCTGGAATATATATAATTTCAAAAAAATAAATAATTTACAAGCGCTATAAAGTATTAGTTTGAATTTGAAAC
TGATTTTTTTTTTTCAAATATAAAACAAACACATCTTTCTTTTACTTCCATTTACCAATTTCCAGGATAGAGATATATCTGCTGTTGATAAATA
AATCAACATTTAAGATCTATAAATCCAATTTCACTATCTGATCTATAAACTCACTAAAAACAATTTGGAGAAATTTGCAATAACCTTAT
GTAATACTTTGACCAAGATATCAACAACTTTCAAAATAGAAGATGATTTACTAGTTCAATATGAATTTATATCGTGATTTGTACTGAACT

CACTATTATAACAATTCAATTGAAGAGCATTACAGTATAAAAATCCAATATCTAATAATCAAATGTGCCAATAATCGATTGATATCTCGTCAA
 GTGTTCAATTTGTTAGTAAATGATGATGATTTCACTTTGGTATTGAATAGAATTACCAATCACCTAGCATAAAATGAATATATTTGGAATTAT
 TAGAAGATATTAATGATATCCATTGATTATAAAACCCTTGATTTACCTGATTATCTAATACCAACTGGGGGATCAATTGGGTAATAAGTT
 GGATTCCTTTGGGTGATTACAATTAGTATATTCATCTTCTACATCTAATAGGTTGAGAAATTTTATAATTGATATCCGAAAAACGATTTACCA
 AAATTTGCTAGTGATGGGAAATATATCAAGATATTGTTAAATTCATGTATAATAATACCAAAAATAAAAATTTGAAAAATTAAGAAATAGAAAAAT
 TTATTAATAATTAATTAATATTGCTAGTGATGGGAAATTTAAATTAATAATTAATGATAATCAATTAATTTGGTTTTTATTGATTGAATCTATAAA
 ATCATCTTTACAATAAGTAAAGTACGTGGTCAATAAAGTAAATGATATATATGTGCGTGTACTGAGTGATGATTTTCTATTTTATCTCGCGC
 GTTGTATTTTTTGTGTTATTGTT
 ATTTTTTTTTTCTCTCTCTCTCCCACTTTCTACTCTTTGAACATGTGGTGAAAAAATAAATAAGACCAGATCTTTTTTATCCATATAT
 TTCAAACCGACTTGTTCCTTTTTTTCTTTTACAACCAATTAATACAAAAGAAAGACAACAATCATAATGTCTACTTCTGTTGAACCCAATGAA
 ACAGAAGCTTTGTTGAGAAAGCAGAATGATCTTTCCACAACCTGCCTCAATTGAAGAAAAATATCCTCACCAACAGGAGAGGCTGCAGAAGCG
 ATGACGACACTCTAAAAGAACCAATATGATGAAGCTAAAGAAACCGCTGAATCTTTAAAACAAGTTGAATCGATATTAGCACCTATTGTTTT
 CACTGCATGTCAATTTTCGTGAGATTTTATCGTATTTTCAAGTAAATGACCATGTTGTTGGGATGAAGCTCATTTTGGTAAATTTGGATCCTAT
 TATTTACGACACGAATTTTATCATGATGTTTCACTCTCCATTGGGTAATGTTAGTTGGTTTATCTGGTTATTTGGCTGGATACAATGGATCTT
 GGATTTCCCAAGTGGTAAAAATACCTGATTATATTGATTACTAAAAATGAGATTGTTAATGCCACTTTCTGCTGCTTGTGTACCATT
 GGCTTATTTCACTGGGAAAGAAGTTGGATTTTCCATGTTTACTACTTGGTTATTTACTTTGATGGTGGCTCTTGAATCAAGTTATGTCACTTTA
 GGTAATTCATTTGTTGGATTCAATGTTGTTATTTCTCACCGTTGCTACTGTTTCTGTTTTTCACGTTTCAACAATTTAACAATAAATCAC
 AAGAATTTCTAGAAAATGGTGGAAATGGATCTTTTAACTGGTGTTCATTGGTTGTTGTTGTTGTTGTTGTTGTTGTTGTTGTTGTTGTTGTTGTT
 CACATTTGGTCCGGATTTTCACTGTTGTTGACCTTTGGAATAAATGAGTGATAAATCTATTTTCATGGACAAAATACATTCAACATTTGGTTGCT
 AGAATTTGTTGCTTTGATTCTTGTCCCAATTTTCAATTTTCAATGCTTTTCAATTTAAAGTTCAATTTTGAATTTGTTGATAAATCGGGTACTGGTGATG
 CCAATATGTCATCACTTTTCCAAGTAATTTGGCTGGTTCCGATGTTGGTGGTGGCCACGTTGAAGTATCCATGTTCCACTCGGTTATCACTTT
 AAAGAATCAAGGTTAAGTGGTGGCCTTTTACTCTCCACGTTCAACATTTCCAGAAGGTTCAAAAACAACAAGTTACTACTTATGGTCCAC
 AAAGATTCAAAACAACAATTTGATTTTCCAAAGCTAGAGGACAACCTTATTATGATACTTCTGGTAAACACCACGACATGAATATATTTTTG
 ACGGTATGCATGTAAGATTGATGCATCCACAACTGGTAGAACTTACATACTCATGATATCCAGCTCCAGTGTCTAAATCTGAATATGAAGT
 TGCATGTTATGGTAATTTGACTATTGGTGATCCTAAAGATAATTTGACTGTTGAAATTTGGAACAAGCAAGTATGAAGATAAATAGATTA
 CATCTTTGACTTCGTCAATTTAGATTGAAGAATGAAGTGAATGTTATTTGGGGTCACTGGTACTACATTACCTCAATGGGGTTCCAGAC
 AAGGTGAAGTTGTTGTTTACAAGAACCATTAAAAAGACAAGAGAAGCTT

ÚKOL 3

Charakterizujte část genomu *Candida albicans* (kvasinka) rovněž pomocí heuristického modelu.

PREDIKCE GENŮ U MNOHOBUNĚČNÝCH EUKARYOT



Mnohobuněčná eukaryota se vyznačují komplexní organizací genomu, geny jsou separovány dlouhými intergenovými úseky, geny obsahují mnoho intronů, i velmi dlouhých. Exony/introny jsou identifikovány pomocí míst setřihu (GT na 5'konci intronu, AG na 3'konci). Vzniká velké množství chyb! Dlouhé introny jsou určeny jako intergenové úseky, krátké intergenové úseky jako introny, krátké exony nemusí být identifikovány.

ÚKOL 5

Analyzujte část genomu mnohobuněčného eukaryotického organismu také pomocí programu **GENSCAN** (<http://genes.mit.edu/GENSCAN.html>). Porovnejte s výsledky z úkolu 4.